

LEONARDO DIAS DA SILVA CABRAL

**BALANCEAMENTO DE MÁQUINAS ROTATIVAS
UTILIZANDO REDES NEURAIS**



UNIVERSIDADE FEDERAL DE UBERLÂNDIA

FACULDADE DE ENGENHARIA MECÂNICA

2023

LEONARDO DIAS DA SILVA CABRAL

**BALANCEAMENTO DE MÁQUINAS ROTATIVAS UTILIZANDO REDES
NEURAIS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal de Uberlândia, como parte dos requisitos para obtenção do título de **MESTRE EM ENGENHARIA MECÂNICA**.

Área de concentração: Mecânica dos Sólidos e Vibrações

Orientador: Prof. Dr. Aldemir Aparecido Cavallini Junior

UBERLÂNDIA – MG

2023

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

C117 Cabral, Leonardo Dias da Silva, 1995-
2023 Balanceamento de Máquinas Rotativas Utilizando Redes
Neurais [recurso eletrônico] / Leonardo Dias da Silva
Cabral. - 2023.

Orientador: Aldemir Aparecido Cavallini Junior.
Dissertação (Mestrado) - Universidade Federal de
Uberlândia, Pós-graduação em Engenharia Mecânica.
Modo de acesso: Internet.
Disponível em: <http://doi.org/10.14393/ufu.di.2023.377>
Inclui bibliografia.
Inclui ilustrações.

1. Engenharia mecânica. I. Cavallini Junior, Aldemir
Aparecido, 1983-, (Orient.). II. Universidade Federal
de Uberlândia. Pós-graduação em Engenharia Mecânica.
III. Título.

CDU: 621

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:
Gizele Cristine Nunes do Couto - CRB6/2091
Nelson Marcos Ferreira - CRB6/3074



UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Coordenação do Programa de Pós-Graduação em Engenharia Mecânica
Av. João Naves de Ávila, nº 2121, Bloco 1M, Sala 212 - Bairro Santa Mônica, Uberlândia-MG, CEP 38400-902
Telefone: (34) 3239-4282 - www.posmecanicaufu.com.br - secposmec@mecanica.ufu.br



ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Engenharia Mecânica				
Defesa de:	Dissertação de Mestrado Acadêmico, nº 639, PPGEM				
Data:	19/07/2023	Hora de início:	08:00	Hora de encerramento:	10:45
Matrícula do Discente:	12112EMC003				
Nome do Discente:	Leonardo Dias da Silva Cabral				
Título do Trabalho:	Balanceamento de Máquinas Rotativas utilizando Redes Neurais				
Área de concentração:	Mecânica dos Sólidos e Vibrações				
Linha de pesquisa:	Dinâmica de Sistemas Mecânicos				
Projeto de Pesquisa de vinculação:					

Reuniu-se por meio de videoconferência a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Engenharia Mecânica, assim composta: Professores Doutores: Marcus Antônio Viana Duarte - FEMEC/UFU; Arinan De Piemonte Dourado - Louisville/EUA; e Aldemir Aparecido Cavallini Junior - FEMEC/UFU, orientador do candidato.

Iniciando os trabalhos o presidente da mesa, Dr. Aldemir Aparecido Cavallini Junior, apresentou a Comissão Examinadora e o candidato, agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor(a) presidente concedeu a palavra, pela ordem sucessivamente, aos(às) examinadores(as), que passaram a arguir o(a) candidato(a). Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o(a) candidato(a):

Aprovado.

Esta defesa faz parte dos requisitos necessários à obtenção do título de Mestre.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Aldemir Aparecido Cavalini Junior, Professor(a) do Magistério Superior**, em 19/07/2023, às 10:33, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Marcus Antonio Viana Duarte, Professor(a) do Magistério Superior**, em 19/07/2023, às 10:37, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Arinan De Piemonte Dourado, Usuário Externo**, em 19/07/2023, às 10:43, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **4602118** e o código CRC **86D68DA0**.

AGRADECIMENTOS

Agradeço primeiramente à Deus por tudo que Ele me proporcionou durante minha jornada, pelos momentos de alegria que me motivaram e pelos momentos de tristeza que fortaleceram para seguir.

Agradeço aos meus pais, Maria Helena e Claudio, à minha namorada, Maria, e toda minha família, pelo imensurável apoio, instrução e amor.

Ao meu orientador, professor Aldemir, pelo suporte nas dificuldades encontradas e contribuição para minha evolução e aprendizado.

Ao professor Arinan, pelo apoio e contribuição ao longo de toda a realização da pesquisa.

Aos meus amigos, pela ajuda e construção de momentos de alegria e boas experiências, em especial, aos membros do *LMEst*, que me acompanharam desde o início do programa.

Ao Programa de Pós-graduação de Engenharia Mecânica e à Universidade Federal de Uberlândia, pela oportunidade de estudar em um ambiente diferenciado para aprender e criar experiências de vida.

Por fim, agradeço à CAPES, Petrobrás e às demais agências de fomento, pelo investimento concedido durante a realização deste trabalho.

CABRAL, L. D. S. **Balaceamento de Máquinas Rotativas Utilizando Redes Neurais**. 2023. 100 f. Dissertação de Mestrado – Universidade Federal de Uberlândia, Uberlândia, MG.

RESUMO

Conforme os estudos e as necessidades avançaram ao longo dos anos, metodologias foram propostas para minimizar uma das principais causas de vibração observadas em máquinas rotativas, o desbalanceamento. O balanceamento visa, de forma geral, uniformizar a distribuição de massa ao longo do rotor, o que permite reduzir as forças induzidas por tais irregularidades e, conseqüentemente, suas respostas de vibração. Dessa forma, o balanceamento proporciona uma melhor condição de operação da máquina, com seu maior desempenho e satisfazendo os limites de segurança previstos por normas técnicas. As técnicas de balanceamento desenvolvidas ao longo do tempo se diversificaram em alternativas que buscam utilizar a relação do comportamento dinâmico observado na máquina rotativa com suas características físicas e geométricas, com a finalidade de prever as massas de correção e suas respectivas posições no rotor. Entre tais técnicas, é possível destacar desde abordagens mais tradicionais como o Método dos Coeficientes de Influência (onde se utiliza de massas de teste), até as mais recentes, com o advento e popularização das técnicas de inteligências artificiais. Este trabalho apresenta como proposta uma abordagem de balanceamento de máquinas rotativas sem o uso de massas de teste, utilizando redes neurais. De maneira geral, a rede neural proposta visa estabelecer uma relação entre as respostas de vibração obtidas na máquina com as possíveis massas e posições de correção, através de seu treinamento com um banco de dados prévio. Neste trabalho são abordadas seis configurações, onde nas quatro primeiras utilizam-se do modelo de elementos finitos (*MEF*) para a formação do banco de dados (a título de ensaio numérico). As duas últimas configurações são de natureza experimental (ou seja, o banco de dados da rede é proveniente dos dados da bancada experimental). Também é proposto nesta dissertação uma abordagem de expansão de dados que reduz a quantidade de condições de desbalanceamento necessárias para o treinamento da rede, sendo utilizada para configurações de rede neural numéricas e experimentais. Cada configuração de rede neural é implementada e avaliada e seus resultados se mostram promissores.

Palavras-chave: *Dinâmica de rotação. Balanceamento de máquinas rotativas. Rede neural. Ausência de massa de teste.*

CABRAL, L. D. S. **Balancing of Rotating Machines Using Neural Networks**. 2023. 100 p.
Master's Dissertation – Federal University of Uberlândia, Uberlândia, MG.

ABSTRACT

As studies and needs have progressed over the years, methodologies have been proposed to minimize one of the main causes of vibration observed in rotating machines, which is unbalanced. Balancing aims, in general, to equalize the mass distribution along the rotor, which allows reducing the forces induced by such irregularities and, consequently, their vibration responses. Thus, balancing provides a better operating condition for the machine, with improved performance and compliance with safety limits specified by technical standards. The balancing techniques developed over time have diversified into alternatives that seek to utilize the relationship between the observed dynamic behavior of the rotating machine and its physical and geometric characteristics, in order to predict the correction masses and their respective positions on the rotor. Among these techniques, it is possible to highlight more traditional approaches such as the Influence Coefficients Method (which utilizes trial weights) and more recent ones, with the advent and popularization of artificial intelligence techniques. This work proposes an approach to balance rotating machines without using trial weights, employing neural networks. In general, the proposed neural network aims to establish a relationship between the vibration responses obtained in the machine and the possible correction masses and positions through training with a previous database. This work addresses six configurations, where the first four use the finite element method (*FEM*) to form the database (as a numerical test). The last two configurations are experimental in nature (i.e., the network's database comes from experimental bench data). This dissertation also proposes a data expansion approach that reduces the amount of unbalance conditions required for network training, which is used for numerical and experimental neural network configurations. Each neural network configuration is implemented and evaluated, and the results show promise.

Keywords: *Rotation Dynamics. Balancing of Rotating Machines. Neural networks. Absence of Test Mass.*

LISTA DE FIGURAS

Figura 1.1: Exemplo de uma máquina rotativa.....	17
Figura 1.2: Exemplo de desequilíbrio de massa em um rotor.	18
Figura 2.1: Ilustração do “ <i>Aeolpile</i> ”.....	28
Figura 2.2: Motor de bomba a vapor proposta por James Watt, em 1788.	29
Figura 2.3: Turbina hidráulica de uma usina hidrelétrica.....	30
Figura 2.4: Estrutura de um rotor.	33
Figura 3.1: Comparação entre o neurônio da rede neural e uma célula nervosa.....	35
Figura 3.2: Conjunto de “ <i>Perceptrons</i> ”.	37
Figura 3.3: Processo do “ <i>Backpropagation</i> ” na rede.....	38
Figura 3.4: “ <i>Perceptron</i> ” de multicamada.	39
Figura 4.1: Condição de desbalanceamento.....	41
Figura 5.1: Bancada experimental.....	44
Figura 5.2: Diagrama do treinamento da rede neural simulada.....	47
Figura 5.3: Processo de transformação dos dados para as variáveis de entrada/saída da rede neural.....	48
Figura 5.4: Processo de treinamento da rede neural com base de dados numérica.....	52
Figura 5.5: Predição da rede neural para o conjunto de teste.....	53
Figura 5.6: Processo de expansão de amostras.	56
Figura 5.7: Processo de simulação da rede neural com o processo de expansão de amostras.....	58
Figura 6.1: Comparação entre os dados originais e preditos associados à massa.....	63
Figura 6.2: Comparação entre os dados originais e preditos associados à posição.	63
Figura 6.3: Comportamento da função de perda ao longo das épocas para a configuração #1.....	64
Figura 6.4: Comparação entre os dados originais e preditos associados à massa do primeiro disco.	66
Figura 6.5: Comparação entre os dados originais e preditos associados à posição do primeiro disco.	67

Figura 6.6: Comparação entre os dados originais e preditos associados à massa do segundo disco.....	67
Figura 6.7: Comparação entre os dados originais e preditos associados à posição do segundo disco.....	68
Figura 6.8: Comportamento da função de perda ao longo das épocas para a configuração #2.....	69
Figura 6.9: Comparação entre os dados originais e preditos associados à massa.....	72
Figura 6.10: Comparação entre os dados originais e preditos associados à posição.	72
Figura 6.11: Curva de acompanhamento dos erros para os dados numéricos de um disco.	73
Figura 6.12: Comportamento da função de perda ao longo das épocas para a configuração #3.	74
Figura 6.13: Comparação entre os dados originais e preditos associados à massa do primeiro disco.	76
Figura 6.14: Comparação entre os dados originais e preditos associados à posição do primeiro disco.	76
Figura 6.15: Comparação entre os dados originais e preditos associados à massa do segundo disco.....	77
Figura 6.16: Comparação entre os dados originais e preditos associados à posição do segundo disco.....	77
Figura 6.17: Curva de acompanhamento dos erros para os dados numéricos de dois discos.....	78
Figura 6.18: Comportamento da função de perda ao longo das épocas para a configuração #4.	79
Figura 6.19: Comparação entre os dados originais e preditos associados à massa.....	81
Figura 6.20: Comparação entre os dados originais e preditos associados à posição.	82
Figura 6.21: Curva de acompanhamento dos erros para os dados experimentais de um disco.	82
Figura 6.22: Comportamento da função de perda ao longo das épocas para a configuração #5.	84

Figura 6.23: Comparação entre os dados originais e preditos associados à massa do primeiro disco.	86
Figura 6.24: Comparação entre os dados originais e preditos associados à posição do primeiro disco.	86
Figura 6.25: Comparação entre os dados originais e preditos associados à massa do segundo disco.....	87
Figura 6.26: Comparação entre os dados originais e preditos associados à posição do segundo disco.....	87
Figura 6.27: Curva de acompanhamento dos erros para os dados experimentais de dois discos.....	88
Figura 6.28: Comportamento da função de perda ao longo das épocas para a configuração #6.	89

LISTA DE TABELAS

Tabela 5.1: Propriedades dos componentes da bancada	45
Tabela 6.1: Parâmetros obtidos para a rede numérica de um disco	62
Tabela 6.2: Variação da resposta ao desbalanceamento numérico antes e após a correção.....	65
Tabela 6.3: Parâmetros obtidos para a rede numérica de dois discos.....	66
Tabela 6.4: Variação da resposta ao desbalanceamento numérico antes e após a correção.....	69
Tabela 6.5: Parâmetros obtidos para a rede de condições numéricas e um disco	71
Tabela 6.6: Variação da resposta ao desbalanceamento numérico antes e após a correção.....	75
Tabela 6.7: Parâmetros obtidos para a rede de condições numéricas e dois discos	75
Tabela 6.8: Variação da resposta ao desbalanceamento numérico antes e após a correção.....	79
Tabela 6.9: Parâmetros obtidos para a rede de condições experimentais de um disco.	81
Tabela 6.10: Variação da resposta ao desbalanceamento experimental antes e após a correção.....	84
Tabela 6.11: Parâmetros obtidos para a rede de condições numéricas e dois discos ...	85
Tabela 6.12: Variação da resposta ao desbalanceamento experimental antes e após a correção.....	90

LISTA DE SÍMBOLOS E SIGLAS

Lista de símbolos:

C^G	Matriz global de amortecimento
D	Matriz de amortecimento
D_D	Matriz de amortecimento do disco devido ao efeito giroscópico
D_g	Matriz devido ao efeito giroscópico
D_p	Matriz de amortecimento proporcional
D_s	Matriz de amortecimento do eixo devido ao efeito giroscópico
e	Excentricidade
F_{ext}	Forças externas
F_m	Forças produzidas pelos mancais
F_o	Força axial
F_{unb}	Força de desbalanceamento
G^e	Matriz elementar giroscópica
G^G	Matriz global giroscópica
K	Matriz de rigidez
K_{Dt}	Matriz de enrijecimento do disco devido a rotação
K_{st}	Matriz de enrijecimento do eixo devido a rotação
K_s	Matriz de rigidez do eixo
K^e	Matriz elementar de rigidez

K^G	Matriz global de rigidez
M	Matriz de massa
M_D	Matriz de massa do disco
M_S	Matriz de massa do eixo
M_T	Matriz de massa devido ao efeito de inércia de rotação
M^e	Matriz elementar de massa
M^G	Matriz global de massa
N	Parâmetro normalizado
q	Vetor de deslocamento do sistema
\dot{q}	Vetor de velocidade do sistema
\ddot{q}	Vetor de aceleração do sistema
q_i	Coordenadas generalizadas do sistema
Q_i	Esforços generalizados do sistema
R	Parâmetro real
T	Energia cinética
U	Energia potencial
t	Tempo
W	Força peso

Lista de símbolos gregos:

α_p	Constante de amortecimento proporcional relativo à massa
β_p	Constante de amortecimento proporcional relativo à rigidez

δW	Trabalho virtual que atua nos mancais
$\delta\alpha$	Incremento da posição e fase para a expansão de amostras
\mathcal{L}	Lagrangeano
Ω	Velocidade de rotação
$\dot{\Omega}$	Aceleração de rotação

Lista de siglas e abreviaturas:

API	<i>Application Programming Interface</i>
LMEst	Laboratório de Mecânica de Estruturas Prof. José Eduardo Tannús Reis
LTU	<i>Linear threshold unit</i>
MAE	<i>Mean absolute error</i> (erro médio absoluto)
MBM	Método de Balanceamento Modal
MCI	Método de Coeficiente de Influência
MEF	Método dos Elementos Finitos
MLP	<i>Multi-layer perceptron</i>
MSE	<i>Mean square error</i> (erro médio quadrático)

SUMÁRIO

CAPÍTULO I - INTRODUÇÃO.....	16
1.1. Contextualização.....	16
1.2. Contribuições Prévias ao Estudo	23
1.3. Objetivos do Estudo	25
1.4. Justificativas.....	25
1.5. Organização desta Dissertação	26
CAPÍTULO II - MÁQUINAS ROTATIVAS.....	27
2.1. História.....	27
2.2. Aplicações.....	30
2.3. Modelagem	31
CAPÍTULO III - REDES NEURAS	35
3.1. Princípio de funcionamento de uma rede neural simplificada	37
CAPÍTULO IV - BALANCEAMENTO EM MÁQUINAS ROTATIVAS.....	40
CAPÍTULO V - METODOLOGIA	43
5.1. Máquina rotativa utilizada	43
5.2. Considerações gerais sobre as redes neurais	46
5.3. Arquitetura da rede neural via base de dados numérica.....	50
5.4. Condições de desbalanceamento e expansão de amostras.....	54
5.5. Arquitetura da rede via condições de desbalanceamento numéricos	57
5.6. Arquitetura da rede via condições de desbalanceamento experimentais	60
CAPÍTULO VI - RESULTADOS E DISCUSSÕES.....	61
6.1. Arquitetura da rede via base de dados numérica.....	61

6.1.1. Configuração #1 – Rotor com um disco.....	62
6.1.2. Configuração #2 – Rotor com dois discos	65
6.2. Arquitetura da rede via condições de desbalanceamento numéricos	70
6.2.1. Configuração #3 – Rotor com um disco.....	71
6.2.2. Configuração #4 – Rotor com dois discos	75
6.3. Arquitetura da rede via condições de desbalanceamento experimentais	80
6.3.1. Configuração #5 – Rotor com um disco.....	80
6.3.2. Configuração #6 – Rotor com dois discos	85
CAPÍTULO VII - CONCLUSÕES	91
7.1. Propostas para trabalhos futuros	93
REFERÊNCIAS BIBLIOGRÁFICAS.....	95

CAPÍTULO I

INTRODUÇÃO

Este capítulo aborda uma introdução desta dissertação. Sua estrutura é caracterizada pela contextualização acerca dos principais temas apresentados neste trabalho, os objetivos e justificativas. Por fim, uma organização do que será exposto em cada capítulo é realizada.

1.1. Contextualização

As máquinas rotativas se tornaram componentes fundamentais para o funcionamento de indústrias e serviços, abrangendo uma grande variedade de setores, desde uma plantação em uma fazenda ao lançamento de um foguete (a Fig. 1.1 ilustra um exemplo de máquina rotativa, no caso, uma turbina a vapor). Consequentemente, sua demanda por maior desempenho, eficiência e segurança operacional se torna maior a cada dia, o que acarreta o desenvolvimento de novas metodologias para elevar a produtividade da máquina, sem afetar sua segurança.

Enquanto ocorre tal desenvolvimento, diversas técnicas e estudos são realizados de modo a reduzir uma das principais falhas encontradas em uma máquina rotativa, o desbalanceamento. Altas amplitudes de vibração síncrona devido a tal falha podem ser observadas em turbinas de aviões, propulsão de navios, plantas de geração de energia, transmissões de motores de carro, exaustores, bombas de plantas de processos químicos entre diversas outras aplicações (PARKINSON, 1991).



Figura 1.1: Exemplo de uma máquina rotativa.

Fonte: Turbivap. Disponível em: <<https://turbivap.com.br/a-maior-turbina-a-vapor-do-mundo/>>

O desbalanceamento corresponde a uma das principais causas de vibrações em máquinas rotativas (LI et al., 2021), cuja falha é causada devido ao desalinhamento do centro de massa do sistema em relação ao seu eixo de rotação (JEFFCOTT, 1919). Tal comportamento é visto quando ocorre uma distribuição de massa não uniforme em determinadas regiões do rotor. Um exemplo de tal situação pode ser visto quando ocorrem desgastes de peças ou acúmulo de resíduos durante sua operação. A Fig. 1.2 apresenta um exemplo de desequilíbrio de massa ao longo da estrutura de uma bomba, sendo este ocasionado pelo desgaste e atrito com resíduos.



Figura 1.2: Exemplo de desequilíbrio de massa em um rotor.

Fonte: Belzona. Disponível em: <<https://www.belzona.com/pt/industries/power.aspx>>

Portanto, a alternativa encontrada para combater tal falha envolve realizar um processo de distribuição da massa, ao acrescentar ou retirar massa ao longo de específicas localizações da máquina rotativa, sendo esse processo denominado de balanceamento. Ao longo do tempo, inúmeras técnicas foram propostas com o objetivo de realizar o balanceamento de máquinas rotativas, reduzindo vibrações e garantindo a segurança operacional. Diversos parâmetros são abordados nas técnicas empregadas, destacando-se na realização de variações, por exemplo, no tamanho da massa de desbalanceamento, em massas do tipo modal, planos ótimos de balanceamento, posição angular das massas ou o número de planos de balanceamento requeridos (FOILES et al., 1998).

Segundo Zhang et al (2021), podem ser considerados dois tipos de metodologias clássicas para o balanceamento de rotores flexíveis. O primeiro é o Método do Balanceamento Modal (*MBM*), o qual utiliza os modos de vibrar do sistema para promover um balanceamento independente em cada modo, sendo apresentados os primeiros resultados de tal técnica por Bishop e Gladwell (1959). Sua operação envolve separar os principais modos de vibrar do sistema e realizar o processo de balanceamento para cada modo independente, de modo a alcançar o balanceamento (LI et al., 2021).

Segundo Li et al (2021), o *MBM* permite minimizar o número de paradas da máquina rotativa para velocidades de rotação mais elevadas, além de também ser bem caracterizado em altas velocidades e seu balanceamento em um modo não interferir no outro modo. Contudo, o *MBM* assume que os modos de vibrar do sistema são planos, o que pode ser ineficiente para condições com elevado amortecimento ou efeitos cruzados do mancal. Outro fator negativo envolve a necessidade de conhecer os modos de vibrar da máquina, sua rotação e seu comportamento para conhecer os planos de desbalanceamento. Os sensores habitualmente utilizados englobam específicos modos de vibrar, dificultando o balanceamento em outros modos.

A segunda técnica refere-se ao Método dos Coeficientes de Influência (*MCI*), que realiza o processo de balanceamento utilizando coeficientes calculados a partir das amplitudes de vibração medidas ao inserir massas de teste em planos específicos de balanceamento. Goodman (1964) aplica um procedimento de mínimos quadrados via computador para determinar as massas finais de correção e então minimizar as leituras de vibrações da máquina rotativa para diferentes planos de balanceamento, velocidades e carregamentos. Seu trabalho se tornou bem conhecido pela comunidade, onde incorpora o método dos mínimos quadrados ao *MCI*.

O *MCI*, conforme Li et al (2021), permite que seus coeficientes revelem influências nos modos de vibrar e nas rigidezes do sistema, além de não existir a necessidade de conhecimento prévio de sua resposta dinâmica. É um procedimento de fácil automação e que não requer domínio completo sobre dinâmica de rotação. Todavia, o método pode apresentar erros caso a medição apresente falhas, para velocidades de rotação maiores o método necessita de mais iterações e o uso de planos de balanceamento dependentes entre si podem afetar no resultado.

Novas técnicas são divulgadas pela comunidade acadêmica abordando diferentes formas de realizar o balanceamento, através de diversas ferramentas e parâmetros. Dentre essa variedade de estratégias, podem ser citadas metodologias que envolvem a independência do uso de massas de teste, o que reduz os passos necessários para o

balanceamento e, conseqüentemente, reduz o número de paradas do rotor (o que beneficia o lucro na produção).

Destacam-se atualmente como técnicas de balanceamento sem massas de teste o uso de modelos computacionais, processos de otimização em conjunto com modelos numéricos, metamodelos e o uso do “*machine learning*” para a predição e classificação do balanceamento. A seguir é abordado brevemente uma cronologia de trabalhos que desenvolvem algumas destas técnicas:

Xu et al (2000) propõem uma técnica de balanceamento sem o uso de massas de teste, baseado na otimização via algoritmo genético que busca reduzir o nível de vibração em locais de medição selecionados para diferentes velocidades de rotação da máquina.

Saldarriaga; Steffen Jr (2003) abordam uma técnica de balanceamento sem a utilização de massas de teste através do uso de duas estratégias, uma por otimização via algoritmo genético associada a modelo numérico e outra via redes neurais.

El-shafei et al (2004) utilizam um modelo numérico bem ajustado para resolver os problemas de modos e vibrações complexas. Eduardo et al. (2005) utilizaram a rede neural de multicamadas para realizar o balanceamento de um rotor com base nas amplitudes de vibração do sistema como variáveis de entrada.

Santos et al (2009) empregam a técnica de redes neurais artificiais juntamente com a separação de planos para realizar o balanceamento de máquinas rotativas ao prever a localização das massas de correção. Os dados que alimentam a rede se basearam em uma máquina rotativa de mancal hidrodinâmico cilíndrico, utilizando-se dos modelos analíticos de eixo rígido de Stodola-Green e da equação de Reynolds.

Walker et al (2014) trabalham com redes neurais artificiais para determinarem a localização do desbalanceamento. A identificação de características não lineares subsíncronas auxiliaram na determinação do desbalanceamento, principalmente em condições a qual o posicionamento do sensor é limitado. Além disso, condições que prejudicam a previsão da rede são adicionadas para avaliar o desempenho da técnica, como a adição de falhas de atrito e desalinhamento.

Silva et. al (2016) abordam um estudo de balanceamento que supera as limitações de metodologias frequentemente utilizadas. O modelo matemático da máquina é formado e seu desbalanceamento é determinado através da solução de problema inverso via algoritmo de otimização. Também são consideradas incertezas em parâmetros que podem afetar o desempenho do balanceamento e o procedimento de otimização utilizado é de caráter multiobjetivo e baseado em Lógica “*Fuzzy*”, onde as variáveis são tratadas como variáveis “*Fuzzy*”.

Carvalho et al (2019) apresentam o metamodelo do tipo “*Kriging*” para efetuar o balanceamento do rotor a partir da predição de suas massas de correção e respectiva posição angular, onde através da coleta de dados de desbalanceamento é possível gerar o metamodelo e realizar a predição. Zhang et al. (2021) abordam uma metodologia para balanceamento de rotores a altas velocidades de rotação, baseando-se na técnica de balanceamento modal.

Ak et al (2019) apresentam uma metodologia para o balanceamento em dois planos de rotores espirais. Tal estratégia é considerada em baixas velocidades de rotação, porém encontram-se resultados satisfatórios quando a velocidade de rotação se aproxima da primeira frequência natural do sistema.

Zou et al (2019) utilizam o Filtro de Kalman aumentado combinado ao modelo de elementos finitos do rotor para identificar forças de desbalanceamento. Esta metodologia é de natureza determinística-estocástica, insensível a erros de medição ou de modelagem e se mostra boa para a identificação do desbalanceamento em tempo real.

Zhang et al (2020) trazem o balanceamento da máquina rotativa baseado no modelo numérico, onde tal modelo identifica o desbalanceamento e sua correção é dada através de um processo de otimização via algoritmo de evolução diferencial.

Deng et al (2021) promovem uma abordagem de balanceamento de uma turbina de potência focada na filtragem da resposta de vibração do rotor. Por meio dos filtros *Butterworth* e *Chebyshev* realizou-se o processamento dos sinais de modo a reduzir ruídos externos ou demais influências e, posteriormente, os métodos de balanceamento

dinâmico transiente e o coeficiente de influência são empregados para a realização do balanceamento.

Ameen; Alsalaet (2021) apresentam um método de balanceamento sem o uso de massas de teste baseado no modelo matemático de uma máquina rotativa ajustado experimentalmente. O modelo é feito em elementos finitos combinado com a análise modal experimental, de forma a identificar a distribuição do desbalanceamento ao longo do rotor.

Zhao et al (2021) projetam um sistema de balanceamento dinâmico robusto baseado nas técnicas de balanceamento por característica transiente (para condições de operação transitória, quando o rotor acelera) e no coeficiente de influência (em regime estacionário).

Wang; Ding (2022) trazem como contribuição a realização do balanceamento modal integrado com os modos normais não lineares. Dessa forma, características não lineares de alguns sistemas rotor dinâmicos são incluídas aos efeitos do balanceamento, sendo os principais procedimentos divididos em três procedimentos. O primeiro consiste na transformação via séries de Fourier complexas da resposta ao desbalanceamento e do modo não linear, o segundo representa o cálculo dos coeficientes de correção de cada ordem de harmônico, como ressonâncias interna ou externa e, por fim, uma sobreposição dessas correções resultam na correção do desbalanceamento.

Li et al (2022) propõem uma abordagem de balanceamento modal otimizada para rotores flexíveis. Dessa forma, seus modos de vibração são determinados a partir da análise modal experimental e na resposta do rotor quando está acelerando, permitindo a determinação das massas de ensaio através da ortogonalidade de cada modo de vibrar e suas massas de correção utilizando o método do coeficiente de influência.

Quinz et al (2022) abordam uma nova metodologia de balanceamento para máquinas rotativas que utilizam mancais hidrodinâmicos através de uma metodologia chamada de Técnica de Montagem Numérica. A novidade desta contribuição está na extensão da Técnica de Montagem Numérica para o balanceamento e na determinação

do Diagrama de Campbell por meio de um algoritmo de busca. Seus resultados são comparados com o método de elementos finitos para verificar a precisão do procedimento.

Sun et al (2022) também propõem uma estratégia de balanceamento baseada na técnica modal, onde transforma o desbalanceamento do rotor em planos de balanceamento isolados e aplicam o método baseado em modelo numérico. Além disso, a técnica é aplicada em balanceamentos de baixa e de alta velocidades.

Zhong; Hou (2023) apresentam um método de balanceamento sem o uso de massas de teste, utilizando uma rede neural profunda com uma camada lagrangeana aplicada. Esta camada lagrangeana é aplicada para introduzir o conhecimento físico prévio à rede e identifica a força desequilibrada sem dados rotulados. A rede utiliza-se das coordenadas generalizadas de um problema inverso (deslocamento, velocidade e aceleração) para obter as possíveis forças.

1.2. Contribuições Prévias ao Estudo

Ao longo dos anos, diversas contribuições foram desenvolvidas no Laboratório de Mecânica de Estruturas “José Eduardo Tannús Reis” (*LMEst*), da Faculdade de Engenharia Mecânica da Universidade Federal de Uberlândia (*FEMEC – UFU*), destacando-se algumas que abordam o tema do balanceamento de máquinas rotativas em suas pesquisas. A seguir, são citados alguns destes trabalhos.

Saldarriaga (2002) aborda duas técnicas de balanceamento de rotores flexíveis sem a utilização de massas de teste. A primeira técnica é considerada como uma técnica de balanceamento modal, baseada na superposição dos modos flexíveis e de corpo rígido, sem a necessidade de conhecimento prévio das propriedades dos mancais. A segunda técnica envolve o uso de métodos pseudoaleatórios de otimização, utilizando algoritmo genético e redes neurais.

Saldarriaga (2007) trabalha com uma metodologia de atenuação das vibrações do rotor utilizando absorvedores viscoelásticos. Neste trabalho se utiliza do problema inverso de otimização, via algoritmo genético, para realizar a identificação das forças de desbalanceamento e sua correção.

Morais (2010) apresenta problemas relacionados a rotores inteligentes, no contexto de máquinas rotativas com características não lineares, destacando no último de seus três temas principais a realização da identificação do desbalanceamento da máquina rotativa por meio de técnicas de problemas inversos. Uma técnica de otimização heurística é realizada para o balanceamento da máquina em condição linear (sem o uso de atuadores eletromagnéticos) e um caso não linear, ao introduzir o efeito do atuador.

Cavallini Jr et al (2012) trazem uma metodologia de balanceamento com a proposta de superar as limitações encontradas no Método dos Coeficientes de Influência. Tal técnica necessita do modelo confiável da máquina e propõem a determinação do desbalanceamento via resolução de um problema inverso, utilizando o método de otimização via evolução diferencial.

Carvalho (2017) desenvolve uma abordagem de balanceamento baseada em modelo matemático. Nesta contribuição, a análise de incertezas é utilizada para avaliar as variações de parâmetros que afetam a resposta dinâmica da máquina rotativa, permitindo a manutenção dos níveis de vibração da máquina nos padrões previstos pelas normas técnicas por maiores faixas de tempo.

Dourado (2018) utiliza a Lógica “*Fuzzy*” como ferramenta para a análise de incerteza e robustez das máquinas rotativas. Em uma das aplicações da técnica, destacam-se processos de otimização robusta para elevar a robustez de dois tipos de balanceamento, um relacionado ao balanceamento via Coeficientes de Influência e o outro baseado em modelo matemático representativo.

Carvalho et al (2019) apresentam uma validação experimental de uma metodologia de balanceamento robusta baseada no modelo matemático representativo da máquina. Tal técnica utiliza-se da solução do problema inverso, obtido via otimização,

levando-se em conta parâmetros de incerteza que podem afetar o resultado do balanceamento.

Carvalho (2022) propõe uma metodologia de balanceamento via sinais de vibração através da técnica de metamodelagem “*Kriging*”. Neste caso, o metamodelo desenvolvido é alimentado por amostras de entrada (condições de desbalanceamento) e saída (massas e posições de correção) provenientes do Método do Coeficiente de Influência (*MCI*).

1.3. Objetivos do Estudo

O objetivo central desta dissertação visa implementar arquiteturas de redes neurais que permitam realizar a predição de massas de correção e suas respectivas posições angulares para a realização do processo de balanceamento de uma máquina rotativa sem uso de massas de teste e sem a utilização de modelo matemático representativo. Além disso, outro objetivo é de reduzir o número de amostras necessárias para o treinamento da rede neural, de forma a manter uma condição de predição adequada para a realização do balanceamento.

1.4. Justificativas

No âmbito operacional, a proposta da metodologia de balanceamento por redes neurais possibilita que a máquina rotativa seja balanceada sem o uso de massas de teste (sendo estas necessárias em outras técnicas, tal qual o Coeficiente de Influência). Isso permite uma redução do número de paradas operacionais da máquina ao realizar o procedimento de balanceamento, o que reduz as perdas no lucro da empresa. Outro fator importante é que esta metodologia não depende de modelos matemáticos para realizar o balanceamento.

Com a proposta de expansão de dados, um menor banco de dados é necessário para o conjunto de treinamento da rede neural, o que viabiliza a utilização desta arquitetura no meio industrial, uma vez que não é necessário alimentar a rede com um extenso banco de dados.

1.5. Organização desta Dissertação

Esta dissertação é organizada em 7 capítulos, sendo estes apresentados conforme se segue:

O primeiro capítulo trata-se da introdução do tema balanceamento em máquinas rotativas, sua contextualização e importância, além dos objetivos e justificativas do tema proposto.

O segundo capítulo aborda sobre máquinas rotativas, sua história, aplicações e modelagem.

O terceiro capítulo apresenta a técnica de redes neurais, seu princípio de funcionamento e o tipo de rede neural utilizado nesta dissertação.

O quarto capítulo comenta-se brevemente sobre o balanceamento de máquinas rotativas.

O quinto capítulo propõe a metodologia utilizada para o uso das redes neurais no balanceamento, estabelecendo etapas e assumindo condições.

O sexto capítulo divide as etapas propostas na metodologia em configurações e traz os resultados e avaliações das simulações das redes neurais para cada configuração.

O sétimo capítulo finaliza esta dissertação com as conclusões observadas e propostas para trabalhos futuros.

CAPÍTULO II

MÁQUINAS ROTATIVAS

Este capítulo aborda uma breve descrição acerca de máquinas rotativas, sistema este que representa o alvo da ação de balanceamento, um dos objetivos desta dissertação. Logo, tal seção apresenta o conceito de uma máquina rotativa, sua história e modelagem, além de exemplos de aplicações de tal equipamento.

2.1. História

A história por trás das máquinas rotativas pode ser contada, assim como descrito por Rao (2011), desde a Idade da Pedra, onde os homens da época descobriram que era mais fácil e rápido transportar objetos pesados através de estruturas redondas. Com isso, houve o surgimento dos primeiros esboços do que então seria chamado de roda.

Com o passar do tempo, a pedra arredondada foi adquirindo forma, ganhando outros componentes e criando-se ferramentas, desde rodas de olarias na Idade do Bronze, passando por eixos de carroças indianas e bigas romanas a rodas de moagem na Idade Média. Em Alexandria, no livro “Pneumática” é concebida a primeira ideia de turbina de reação a vapor no mundo, o “*Aeolpile*” (Fig. 2.1). Tal dispositivo consiste no aquecimento de água do reservatório em sua base, onde o vapor resultante é conduzido pela haste até a esfera giratória. O vapor então escapa por um dos bicos existentes na esfera, o que proporciona um impulso e, conseqüentemente, promove a rotação da esfera.

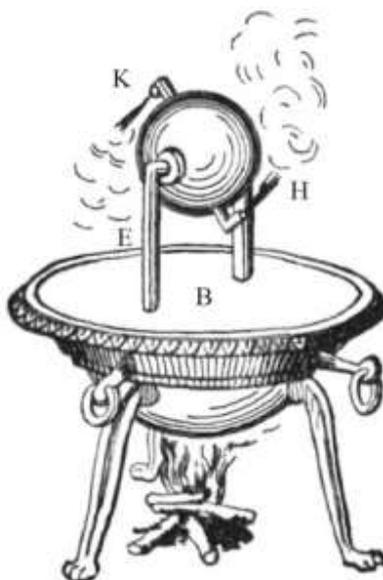


Figura 2.1: Ilustração do “Aeolpile”.

Fonte: (RAO, 2011).

Com a evolução da humanidade, a automatização de processos facilitou o crescimento das civilizações, o que culminou na busca por soluções que realizassem as mesmas tarefas, mas de forma mais rápida e de menor custo. O surgimento de rodas d'água e moinhos de vento exemplificam esse avanço tecnológico, pois a água e o vento são forças motoras que promovem a rotação do eixo conectado às pás de cada estrutura, o que possibilitou seu uso para aumentar a produção de moagem de grãos.

Ao longo da história, novas pesquisas e avanços na compreensão dos fenômenos da natureza permitiram a modelagem e invenção de diversos sistemas que até hoje apresentam relevância, desde os eventos da Renascença, com os projetos e detalhamento refinado de Leonardo da Vinci, a contribuições de grandes estudiosos como Newton. Vale destacar especificamente os trabalhos propostos por Euler e Bernoulli, aos quais possibilitaram a teoria de viga de Euler-Bernoulli, modelo este ainda citado atualmente para a modelagem de eixos de máquinas rotativas.

Com o advento da Revolução Industrial, no século XVIII, o vapor se tornou a nova fonte motora da máquina, pois ela disponibilizava uma maior potência para a rotação. Dessa maneira, as máquinas a vapor se espalharam ao redor do planeta, para os mais

diversos tipos de funcionalidade como, por exemplo, motores de bombas, indústrias têxteis, e trens (vide Fig. 2.2). O uso de máquinas rotativas aumentou significativamente em termos de aplicações e sofisticação do design (HAROLD, 1998).

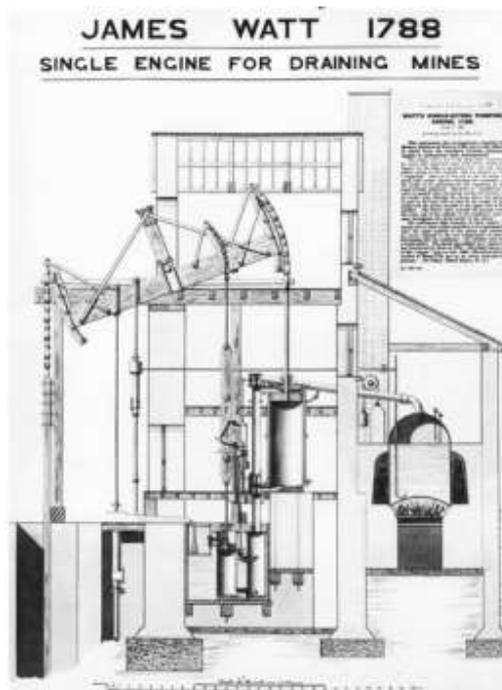


Figura 2.2: Motor de bomba a vapor proposta por James Watt, em 1788.

Fonte: (RAO, 2011).

A introdução da energia elétrica, com motores de corrente contínua e de corrente alternada proporcionou o aumento das velocidades de operação das máquinas, tornando-se mais importante a necessidade de modelos que melhor representam o comportamento do rotor. Atualmente, a alta demanda por tecnologia e energia tornou cada vez maior a necessidade por máquinas de alto desempenho e com baixa manutenção. É possível observar, por exemplo, geradores hidrelétricos de grandes dimensões (como observado na Fig. 2.3), que trabalham a altas velocidades de rotação com espaçamentos entre o estator e o rotor muito pequenos. Esses exemplos retratam o quão vasto é a capacidade humana para produzir máquinas formidáveis a partir de uma pedra arredondada inicial.



Figura 2.3: Turbina hidráulica de uma usina hidrelétrica.

Fonte: Lima. Disponível em: <<https://www.antoniolima.web.br.com/arquivos/turbinashidro.ht>>

2.2. Aplicações

Conforme citado anteriormente por Harold (1998), a máquina a vapor possibilitou uma maior diversificação das funcionalidades da máquina rotativa. Além das rodas d'água e moinhos de vento antes comentados (e que ainda são utilizados), podem-se destacar como alguns exemplos de máquinas rotativas:

- ✓ Bombas: Com o objetivo de transportar fluidos como água e óleo, as bombas necessitam rotacionar um conjunto de pás para realizar a movimentação do fluido;
- ✓ Compressores e turbinas: Atuam no processo de produção de energia e potência de máquinas, movimentando por meio de “*blades*” o ar, vapor ou gás (para o compressor) ou se movimentando através deles (para a turbina);
- ✓ Motores: Possuem em sua estrutura interna um eixo que rotaciona conforme a variação da corrente elétrica, permitindo a rotação para movimentar os mais variados tipos de dispositivos (como, por exemplo, carros, elevadores, trens);
- ✓ Tornos: Utilizados para usinar peças, seu mecanismo funciona por meio da rotação da peça ou da ferramenta de corte;
- ✓ Esteiras: Permitem o transporte de objetos ao utilizar a rotação de seus eixos internos para promover a movimentação;

- ✓ Giroscópios: Dispositivos que avaliam a orientação e conservam o momento angular através de uma roda que rotaciona ao longo de um eixo sustentado por um “*gimbal*”;
- ✓ Centrífugas: Ferramentas que se utilizam da rotação para separação de fluidos.

2.3. Modelagem

A modelagem de uma máquina rotativa se mostra cada vez mais importante, visto que as velocidades de rotação são maiores e as estruturas dos eixos são mais leves e flexíveis. Desse modo, fenômenos podem acontecer devido a tais parâmetros aos quais um modelo simplificado não representa.

Portanto, é necessário encontrar um modelo que represente o melhor possível o comportamento físico do rotor, conseguindo prever com certa precisão detalhes específicos. Além disso, é preciso estabelecer uma boa relação entre a representatividade e a complexidade do modelo, onde a melhor relação custo-benefício será um modelo bem representativo, mas que não seja complexo.

O primeiro artigo que apresenta relevância à modelagem e análise de rotores foi escrito por Macquorn Rankine (1869), onde se descreve (equivocadamente) a existência de uma velocidade máxima de rotação permitida. Desde então, muitas contribuições foram publicadas, elevando a predição das características dinâmicas do rotor. Nesta mesma época podem-se citar trabalhos de Dunkerley; Reynolds (1894), que denomina como velocidade crítica a velocidade citada por Rankine, de De Laval (1894), ao apresentar a operação de uma turbina a vapor com velocidade de rotação superior à crítica e de Föppl (em 1895).

Posteriormente, destacam-se trabalhos de Stodola (1916) e Holzer (1921), na Alemanha, Jeffcott (1919), Smith (1933) e Robertson (1932, 1933 e 1934), na Inglaterra e de Newkirk e Kimbal (ambos em 1924), nos Estados Unidos (HAROLD, 1998). Além disso, Campbell (1924) apresenta pela primeira vez o Diagrama de Campbell. No período

pós Segunda Guerra Mundial novos trabalhos foram realizados, destacando-se pelas contribuições de Yamamoto (1954), no Japão, Dimentberg (1961), pela antiga União Soviética, Tondl (1965), na antiga Tchecoslováquia e Gunter (1966) e Lundi (1967), pelos Estados Unidos (HAROLD, 1998).

É importante ressaltar que as redes neurais utilizadas neste trabalho não necessitam do modelo matemático para realizar o balanceamento. Contudo, o banco de dados utilizado para o treinamento da rede neural (principalmente para as configurações de validação numérica) pode ser construído a partir de um modelo numérico.

Outro ponto a ser considerado é que o balanceamento utilizando a metodologia proposta nesta dissertação independe do tipo de máquina rotativa. Ou seja, aplicações desde bombas a colunas de perfuração podem realizar o balanceamento com tal técnica, alterando-se para cada situação o banco de dados para o treinamento da rede neural.

Uma vez que apenas o banco de dados para o treinamento da rede é modificado, diversas técnicas podem ser utilizadas para compô-lo, sejam técnicas que utilizam massas de teste ou modelo matemático. A modelagem teórica utilizada nesta dissertação para a composição do banco de dados numéricos da rede neural é baseada no Método de Elementos Finitos (*MEF*) associado à teoria proposta por Lalanne; Ferraris (1990), a qual utiliza-se do Método de Rayleigh – Ritz e das equações de Lagrange para a determinação das equações do movimento do rotor.

A técnica do *MEF* permite discretizar os elementos do rotor de forma que, para cada elemento discretizado, são obtidas suas matrizes elementares de massa (M^e), giroscópica (D^e) e de rigidez (K^e). A partir da conexão dos nós de cada elemento, essas matrizes elementares são concatenadas (respeitando sua ordem na discretização) e então são obtidas as matrizes globais de massa (M^G), giroscópica (D^G), de rigidez (K^G) e de amortecimento (C^G).

Tais matrizes globais são utilizadas na solução das equações do movimento do rotor, de modo que por meio da solução de autovalor e de autovetor encontram-se as frequências naturais da máquina rotativa, acompanhada de seus modos de vibrar. Além

disso, utilizando-se da integração numérica é possível determinar a resposta do deslocamento do rotor em condições de desbalanceamento, recurso este que será utilizado neste trabalho para determinar as amplitudes de vibração.

Cavallini Jr (2013) desenvolve para os componentes eixo, disco e mancais de uma máquina rotativa as matrizes elementares utilizadas para compor as matrizes globais da equação do movimento do rotor, baseado no *MEF*. A Fig. 2.4 ilustra uma simplificação da estrutura do rotor.

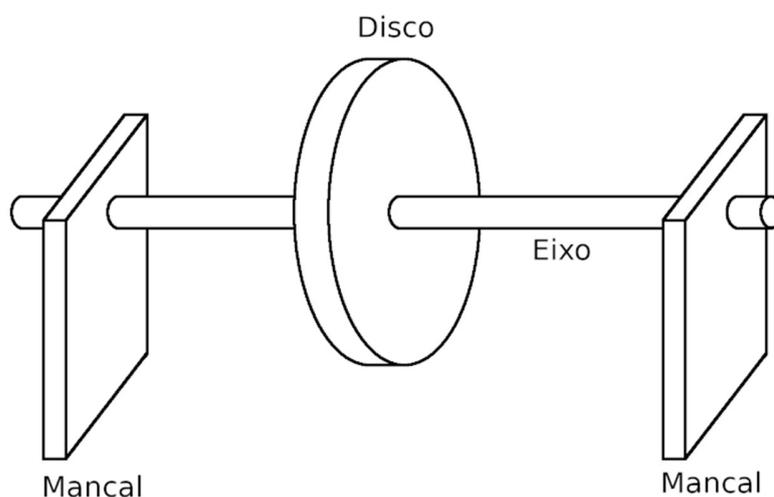


Figura 2.4: Estrutura de um rotor.

Dessa forma, cada componente da máquina rotativa pode ser modelada baseado nas equações de energia cinética, potencial ou trabalho virtual, de modo que todas estas equações são unificadas nas equações de Lagrange, onde o Lagrangeano (\mathcal{L}) representa a diferença da energia cinética (T) pela energia potencial (U), q_i são as coordenadas generalizadas do sistema e Q_i são os esforços generalizados. Reorganizando a equação, ao substituir nas equações de Lagrange o termo cinético e potencial, pode-se obter a eq. (2.1), que será utilizada na modelagem do rotor.

$$\mathcal{L} = T - U$$

$$\frac{\partial}{\partial t} \left(\frac{\partial T}{\partial \dot{q}_i} \right) - \frac{\partial T}{\partial q_i} + \frac{\partial U}{\partial q_i} = Q_i \quad (2.1)$$

Ao rearranjar a eq. (2.1) para o *MEF*, é possível obter a equação diferencial que representa o comportamento de grande parcela das máquinas rotativas (eq. (2.2)).

$$M\ddot{q} + (D + \Omega D_g)\dot{q} + [K + \dot{\Omega}(K_{Dt} + K_{St})]q = W + F_{unb} + F_m + F_{ext} \quad (2.2)$$

Nos termos à esquerda M representa a matriz de massa global do sistema, D a matriz global de amortecimento, D_g o termo devido ao efeito giroscópico, K a matriz global de rigidez, K_{Dt} e K_{St} promovem o enrijecimento do sistema durante a rotação da máquina. A velocidade de rotação da máquina é dada por Ω e sua aceleração, $\dot{\Omega}$, e q corresponde ao vetor de deslocamento da máquina para cada nó de discretização (enquanto \dot{q} é o vetor de velocidades). Os termos à direita estão relacionados aos vetores de força peso (W), devido ao desbalanceamento (F_{unb}), produzidas pelos mancais (F_m) e, por fim, forças externas (F_{ext}).

A matriz global de massa M é determinada a partir da soma das componentes de massa do eixo e de seu termo de massa devido à inércia (M_s e M_T), além do acréscimo de massa nas regiões da localização do disco (M_D). A matriz global de amortecimento D pode ser calculada como a soma de um amortecimento proporcional que relaciona as matrizes de massa e de rigidez a partir de constantes α_p e β_p ($D_p = \alpha_p M + \beta_p K$). O amortecimento devido ao efeito giroscópico D_g corresponde ao resultado da soma das matrizes de amortecimento giroscópicas do eixo (D_s) associada com o amortecimento giroscópico do disco (D_D) em seus específicos nós. A matriz global de rigidez K é composta pela rigidez do eixo (K_s).

CAPÍTULO III

REDES NEURAIS

Este capítulo trata de redes neurais, sua história, conceitos e funcionamento. Sua estrutura é caracterizada por uma breve introdução sobre redes neurais, abordando um pouco da cronologia da técnica. Em seguida é explicado sobre o funcionamento geral de uma rede neural básica (do tipo “*perceptron*”) e é comentado acerca da “*Multi-Layer Perceptron*” (ou *MLP*), rede neural utilizada nesta dissertação.

Tal qual existe a inspiração de diversos produtos em relação a comportamentos da natureza, com a rede neural não se fez diferente. Como o próprio nome sugere, a arquitetura da rede neural é baseada nos neurônios presentes no sistema nervoso humano, vide comparação entre um neurônio de rede (lado esquerdo da Fig. 3.1) com a célula humana neurônio (lado direito da Fig. 3.1).

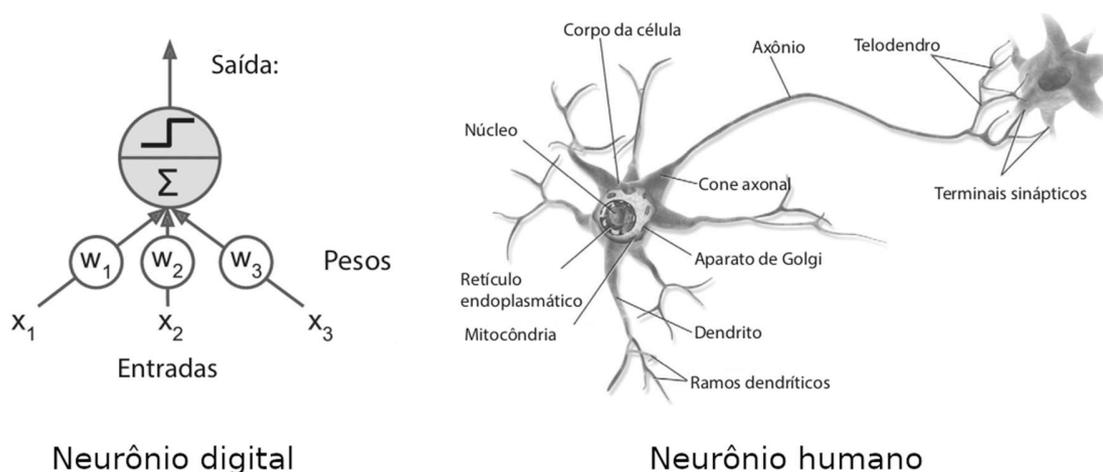


Figura 3.1: Comparação entre o neurônio da rede neural e uma célula nervosa.

Fonte: Adaptado de (GÉRON, 2019).

A proposta das redes neurais artificiais está alinhada com o conceito de aprendizado da máquina (“*Machine Learning*”), onde através de técnicas computacionais é possível detectar padrões e correlações entre dados, permitindo relacioná-los de forma a prever, agrupar, classificar os mesmos. Além disso, a habilidade das redes neurais permite que elas aprendam com o tempo (ao realimentar seu treinamento com novas informações), otimizando sua performance.

Os primeiros indícios de rede neural, segundo Géron (2019), foram introduzidos em 1943, pelo neurofisiologista Warren McCulloch e pelo matemático Walter Pitts, onde descreveram o funcionamento do neurônio e apresentaram um modelo simplificado de rede neural (o primeiro do tipo). Estudos de Hebb (1949) e de Rosenblatt (1958) contribuíram para modelos de auto-organização e “*perceptron*” de aprendizado supervisionado, respectivamente.

Após passar por um período em suspensão, estudos mais relevantes retornaram nos anos 80, com novas arquiteturas e técnicas de treinamento (GÉRON, 2019). Destacam-se nesta época trabalhos como os de Hopfield (1982), que apresenta redes simétricas para otimização, e estudos de Rumelhart, Hinton e Williams, que introduziram o conceito do “*Backpropagation*” (metodologia essencial para o desenvolvimento das redes neurais modernas, onde é calculado o gradiente da função erro e então retorna para atualizar os pesos).

Nos anos 90, técnicas mais avançadas (como Máquinas de Vetores de Suporte, por exemplo) favoreceram a metodologia com melhores resultados e teorias mais robustas. Atualmente, com a evolução dos computadores, as redes neurais se tornaram uma poderosa ferramenta para análise e predição com maiores precisões e um menor tempo de processamento. Exemplos de aplicação envolvem avaliações de grandes volumes de dados (o “*Big Data*”), classificação de imagens, ferramentas de tradução, predição de diagnósticos, dentre outros.

3.1. Princípio de funcionamento de uma rede neural simplificada

Uma das mais simples redes neurais, o “*Perceptron*” (inventada em 1957, por Frank Rosenblatt) baseia-se na manipulação matemática dos dados de entrada, de modo a se obter os resultados de saída os mais precisos possíveis. Para isso acontecer, o algoritmo utiliza a somatória da multiplicação das entradas por pesos e, após tal operação, o resultado é somado por vieses. Em seguida, o valor obtido passa por uma função de ativação, ao qual modifica o valor final conforme o tipo de dados inseridos e da função proposta (a função de ativação pode ser tratada como um processo de transformação não linear, onde capacita a execução de redes mais complexas).

Um exemplo ilustrativo do “*Perceptron*” é esquematizado pela Fig. 3.2, onde se apresenta à esquerda a Unidade Linear com “*Threshold*” (*LTU*), que realiza a multiplicação dos dados de entrada pelos pesos, faz a somatória e aplica a função de ativação. À direita, encontra-se o diagrama do “*Perceptron*”, que se constitui por uma composição de uma camada de entrada dos dados (acrescida de um “neurônio” de viés) e uma camada de saída, formada pelas *LTUs*.

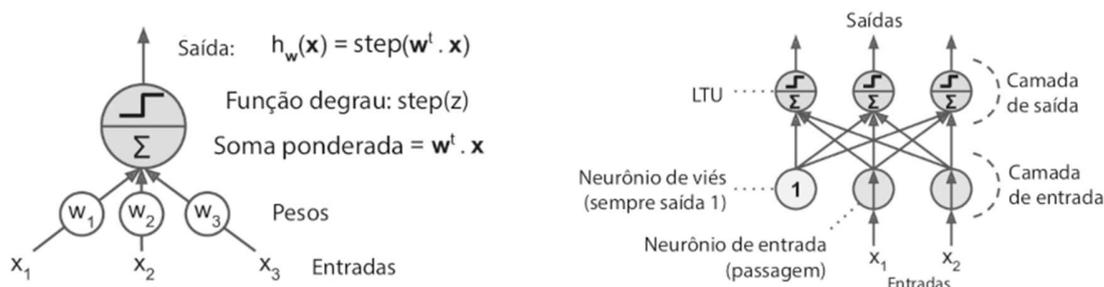


Figura 3.2: Conjunto de “*Perceptrons*”.

Fonte: Adaptado de (GÉRON, 2019).

O processo de manipulação matemática de multiplicação dos pesos e soma com vieses é passado de camada para camada, da entrada até a saída, sendo este processo conhecido como “*Feedforward*”, que representa um caminho direto da entrada para a saída. Em redes mais simplificadas este é o único passo para a realização do

treinamento, contudo, existe o processo de “*Backpropagation*”, que permite a atualização dos pesos e vieses ao longo do treinamento.

Este processo é realizado quando ocorre a avaliação dos dados de saída do banco de dados com a saída resultante da rede (essa avaliação resulta de uma função, denominado de função de perda, ou “*loss function*”). Em seguida, o resultado da função de perda permite atualizar os pesos e vieses de forma retrógrada (da camada de saída para a de entrada).

Portanto, o treinamento da rede neural é feito com a multiplicação dos pesos e soma dos vieses, avaliação da função de perda no final da rede e atualização dos pesos e vieses a partir da função de perda e o processo é retomado com a multiplicação dos pesos, fechando o ciclo de treinamento. A Fig. 3.3 indica o processo do “*Backpropagation*” na rede.

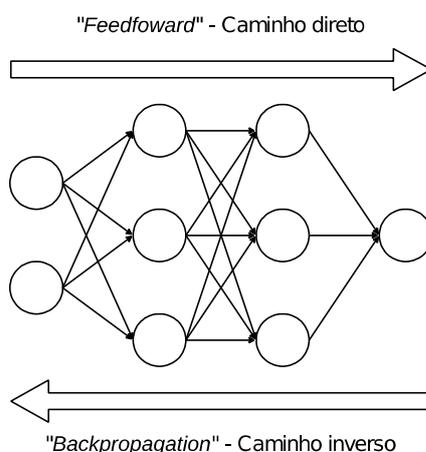


Figura 3.3: Processo do “*Backpropagation*” na rede.

Por fim, a rede pode ser avaliada via métricas de desempenho, onde é possível observar o grau de precisão e acurácia que a rede está entregando em sua saída. Alguns exemplos de métricas são o erro médio quadrático (*MSE*), o erro médio absoluto (*MAE*), a acurácia, entre outros.

Com o avanço dos estudos, as redes se tornaram mais complexas e novas camadas compostas por *LTUs* surgiram entre a camada de entrada e a de saída (as

denominadas camadas ocultas), surgindo assim o “*Perceptron*” de multicamada, ou “*Multi Layer Perceptron*” (*MLP*). Quando mais de uma camada oculta está presente no sistema, a rede é considerada do tipo profunda. A Fig. 3.4 apresenta um esquema ilustrativo de uma *MLP*, onde percebe-se maior complexidade da *MLP* quando comparada ao “*Perceptron*” simples, viabilizando a execução de trabalhos com maior dificuldade.

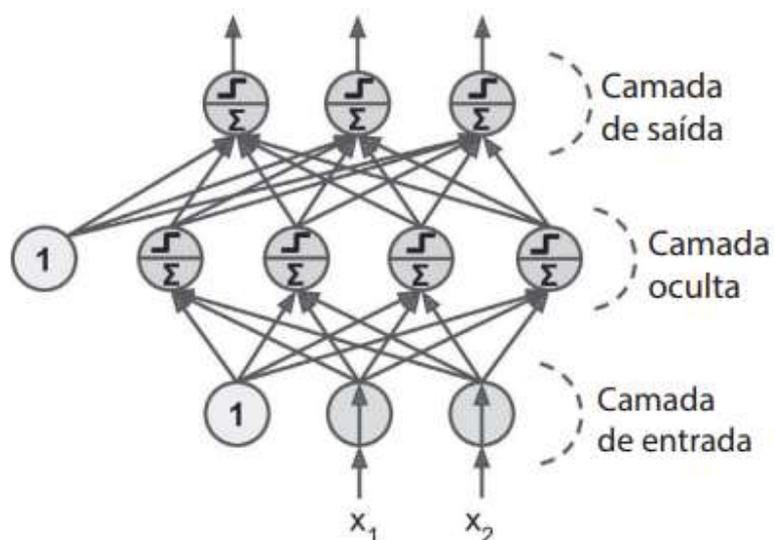


Figura 3.4: “*Perceptron*” de multicamada.

Fonte: (GÉRON, 2019).

CAPÍTULO IV

BALANCEAMENTO EM MÁQUINAS ROTATIVAS

Este capítulo descreve sobre o balanceamento de máquinas rotativas. Sua estrutura se caracteriza por uma breve introdução acerca do que é o desbalanceamento e, em seguida, é realizada uma breve definição sobre o balanceamento.

Uma vez visto o que é uma máquina rotativa, pode-se então abordar sobre o balanceamento dela. Porém, em primeiro lugar é necessário compreender o que significa o desbalanceamento. Conforme Ibraheem et al (2019), o desbalanceamento representa 35% dos problemas de máquinas rotativas, sendo citado por Li et al (2021) como uma das principais razões para a vibração delas.

A condição de desbalanceamento, conforme Ibraheem et al (2019) surge a partir do instante em que o eixo de rotação do rotor não coincide com o centro de massa dele (conforme ilustrado na Fig. 4.1, a uma distância denominada de excentricidade e). Esse desalinhamento de eixos é atribuído a uma concentração (ou ausência) de massas em determinadas regiões do rotor. Isso promove na máquina rotativa a presença de forças inerciais rotacionais, as quais são diretamente proporcionais à velocidade de rotação da máquina (vide modelagem no capítulo 2), à distância entre a massa de desbalanceamento e o eixo geométrico e ao valor da massa concentrada.

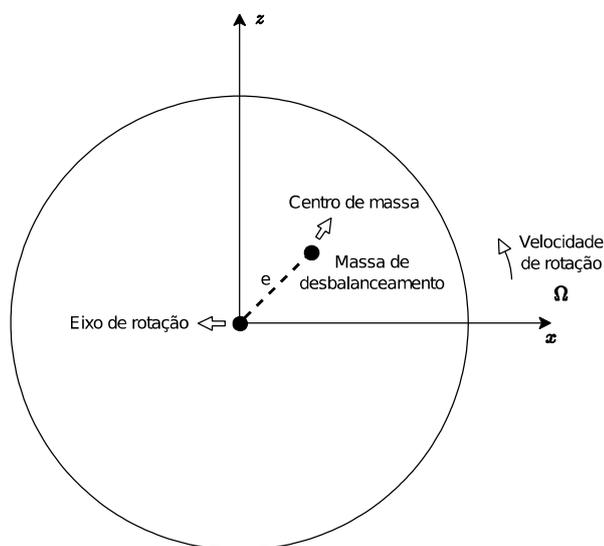


Figura 4.1: Condição de desbalanceamento.

Tais concentrações ou ausências de massas ao longo da estrutura da máquina rotativa ocorrem devido a diversos fatores, exemplos a serem comentados são os danos sofridos pela máquina em virtude de alguma colisão (tal qual cascalhos colidindo com pás de exaustores), desgaste devido a ação do tempo (ferrugem em componentes de usinas hidrelétricas), desgastes devido à operação (como a redução da pastilha de freio de uma roda de carro), acúmulo de resíduos em determinadas regiões da máquina, entre outros.

Portanto, é necessário realizar procedimentos aos quais promovem a uniformização da massa ao longo do rotor, de modo que seu centro de massa e eixo de rotação estejam alinhados e, conseqüentemente, reduzindo as forças centrífugas e suas amplitudes de vibração. Tais métodos são denominados de balanceamento, e devem ser utilizados de forma a garantir níveis de amplitude de vibração conforme padrões propostos por normas estabelecidas (tal qual divulgados via ISO 21940-11:2016, ISO 19499 e 21940-12, onde estabelece tolerâncias de balanceamento e apresenta os cálculos necessários que devem ser realizados, além de dar especificações para cada tipo de máquina e velocidade máxima de operação).

Balanceamento, segundo Foiles et al (1998), corresponde a adição ou remoção de quantidades de massa, em certas posições ao longo da máquina rotativa, que promovem forças ao sistema de modo a reduzir a ação das forças de desbalanceamento pertencentes ao próprio. Este procedimento é um processo importante para garantir a confiabilidade, operação e segurança da máquina.

Existe atualmente uma ampla variedade de técnicas de balanceamento para realizar o balanceamento de rotores, contudo, a realização do balanceamento de uma máquina rotativa se mostra custosa, uma vez que é necessário realizar a parada do rotor, o que deixa o processo de operação inerte, o que leva a tempo e dinheiro. Dessa maneira, novas metodologias de balanceamento aparecem ao longo dos anos de modo a reduzir tais interrupções e ainda garantir a redução das amplitudes de vibração, o que aumenta a produtividade da empresa.

CAPÍTULO V

METODOLOGIA

Este capítulo apresenta a metodologia proposta para o desenvolvimento desta dissertação. Sua estrutura caracteriza-se pela descrição da máquina rotativa utilizada e da abordagem dos processos de treinamento das redes neurais utilizadas. Em seguida, é citada a técnica para a expansão de dados e, posteriormente, descrito como serão construídas as arquiteturas das redes neurais para cada configuração de simulação.

Serão retratadas ao longo deste capítulo algumas considerações importantes para a composição da dissertação. A primeira delas é que a rede neural não requer o modelo de Elementos Finitos para realizar o balanceamento, o modelo matemático é empregado somente para a construção do banco de dados para o treinamento, com o propósito de realizar a validação numérica da rede neural. Posteriormente a rede neural trabalha apenas com dados experimentais. Em um ambiente industrial, históricos de balanceamento de empresas são utilizados para compor tal conjunto de amostras para o treinamento, sendo esses balanceamentos anteriores baseados em diversos tipos de técnicas.

5.1. Máquina rotativa utilizada

Vale destacar que este trabalho não realiza o processo de ajuste e otimização do modelo matemático do rotor. Contudo, foi utilizado o modelo de Elementos Finitos já ajustado em relação a bancada experimental vigente nesta dissertação (modelo este utilizado pelo Laboratório de Mecânica de Estruturas Prof. José Eduardo Tannús Reis, *LMEst*). Dessa forma, o modelo de Elementos Finitos permite gerar o banco de dados

necessários para a avaliação numérica da rede, enquanto a bancada fornece os dados para a verificação experimental.

De maneira geral, a bancada experimental utilizada neste trabalho pode ser observada na Fig. 5.1. Ela representa um conjunto constituído por motor (M), acoplamento (A), eixo (S), dois mancais de rolamento (um associado a um atuador eletromagnético, B_1 , e outro convencional, B_2) e dois discos (D_1 e D_2). Também é possível observar a presença de um encoder (transdutor que gera pulsos à medida em que uma rotação é realizada, E) e quatro sensores de proximidade (P_1 , P_2 , P_3 e P_4 , aos quais medem a variação do deslocamento do eixo em relação a seu centro de referência).

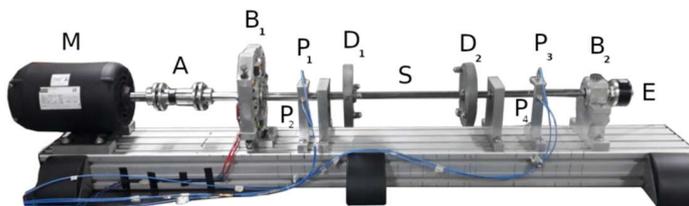


Figura 5.1: Bancada experimental.

As distâncias dos componentes B_1 , B_2 , D_1 , D_2 , P_1 , P_2 , P_3 e P_4 em relação ao motor (distância denominada de d_M) e as características geométricas e físicas de S e dos discos são disponibilizadas na Tabela 5.1. Estas distâncias são alimentadas no modelo de Elementos Finitos para obter uma maior representatividade do modelo numérico em relação à bancada.

Tabela 5.1: Propriedades dos componentes da bancada

Mancal B_1	
d_M [mm]	120
$k_{xx} / k_{xy} / k_{yx} / k_{yy}$ [N/m]	$2,18 * 10^7 / 0 / 0 / 3,64 * 10^9$
Mancal B_2	
d_M [mm]	915
$k_{xx} / k_{xy} / k_{yx} / k_{yy}$ [N/m]	$3,12 * 10^6 / 0 / 0 / 2,93 * 10^9$
Disco D_1	
d_M [mm]	345
Raio externo [mm]	75
Raio interno [mm]	8,5
Espessura [mm]	20
Massa [kg]	2,660
Disco D_2	
d_M [mm]	626
Raio externo [mm]	75
Raio interno [mm]	8,5
Espessura [mm]	20
Massa [kg]	2,674
Sensores P_1 e P_2	
d_M [mm]	244
Sensores P_3 e P_4	
d_M [mm]	765
Eixo S	
Comprimento total [mm]	1000
Raio externo [mm]	8,5
Raio interno [mm]	0
Módulo de Elasticidade [N/m ²]	$205 * 10^9$
Densidade [kg/m ³]	7850
Coefficiente de Poisson	0,29

A partir de suas propriedades e dimensões, tal rotor é modelado via Elementos Finitos. Neste trabalho, as simulações e rodadas da máquina rotativa (tanto na questão numérica como na experimental) estão relacionadas com uma velocidade de rotação de 14 Hz , ou 840 rpm .

5.2. Considerações gerais sobre as redes neurais

As simulações realizadas nesta dissertação envolvem a predição da massa de correção e sua respectiva posição angular. Para isso, modelos de arquitetura de rede serão obtidos em determinadas configurações, sendo que em todas as redes neurais resultantes as variáveis de entrada correspondem a valores relacionados com a amplitude de vibração e com a fase entre o sinal e o encoder (seja para a configuração de um ou dois discos), enquanto as variáveis de saída representam valores relacionados com as massas de correção e suas respectivas posições angulares (novamente, para um ou dois discos). Dessa forma, é possível determinar possíveis valores de correção ao desbalanceamento a partir dos sinais coletados na máquina rotativa. A Fig. 5.2 ilustra um diagrama de como a rede neural é treinada.

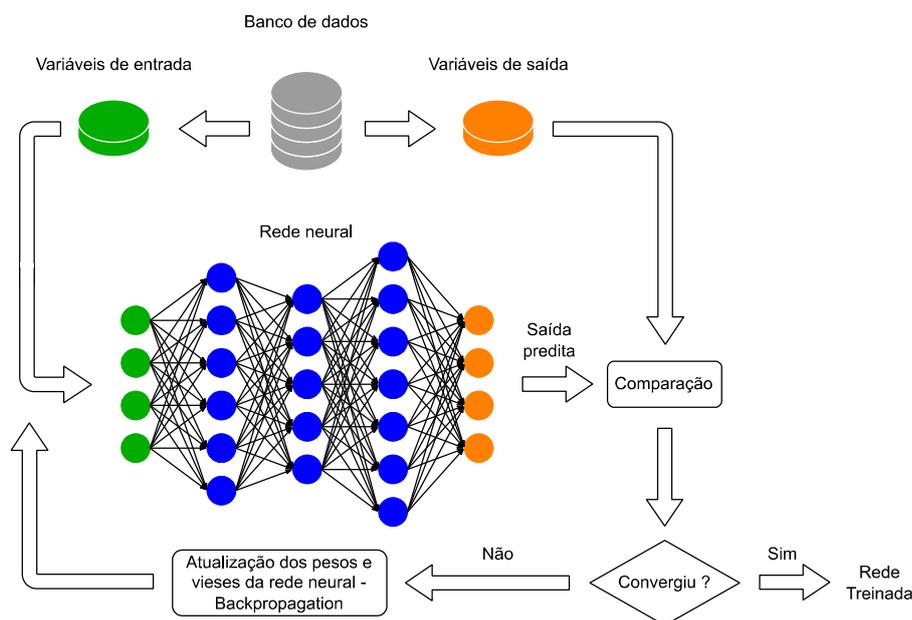


Figura 5.2: Diagrama do treinamento da rede neural simulada.

Ao observar a Fig. 5.2, percebe-se as variáveis de entrada no início da rede, onde percorrem um processo de combinações matemáticas através dos neurônios de cada camada, enquanto na saída, os valores resultantes desses procedimentos algébricos são confrontados com as variáveis de saída, de modo a avaliar o erro ao longo do treinamento e, conseqüentemente, permitir a atualização dos pesos e vieses de cada camada (processo de “*backpropagation*”).

A rede é então treinada, baseada em uma arquitetura de pesos e vieses, sendo atualizados para reduzir a função de perda, conforme comentado no capítulo 3. Após o treinamento, os valores dos pesos e vieses estão ajustados, permitindo que se realize o processo de predição e avaliação das métricas através de valores de entrada e de saída diferentes do conjunto de treinamento.

A título de consideração, os valores utilizados nas variáveis de entrada e de saída estão relacionados com as amplitudes/fases e massas/posições, respectivamente, porém não são seus valores concretos. Uma transformação dos dados para um “formato

exponencial de números complexos”, conforme visto na eq. (5.1), é realizada. De modo geral, através de duas variáveis (B e C) é possível obter o valor de A .

$$A = Be^{iC} \quad (5.1)$$

A variável A consiste em um número complexo, onde se utiliza das partes real e imaginária deste número complexo como variáveis para a rede. Dessa maneira, os valores de amplitude são associados à B enquanto os valores de fase, C . Realizando o cálculo da eq. (5.1), determinam-se os valores complexos de A , que são utilizados para obter as variáveis de entrada da rede, através das partes reais e imaginárias de A . Já para a saída, os valores de B correspondem às massas e C , posições. A Fig. 5.3 apresenta um diagrama da transformação dos valores de amplitude/fase e massa/posição para os valores de entrada e saída para a rede neural, respectivamente.

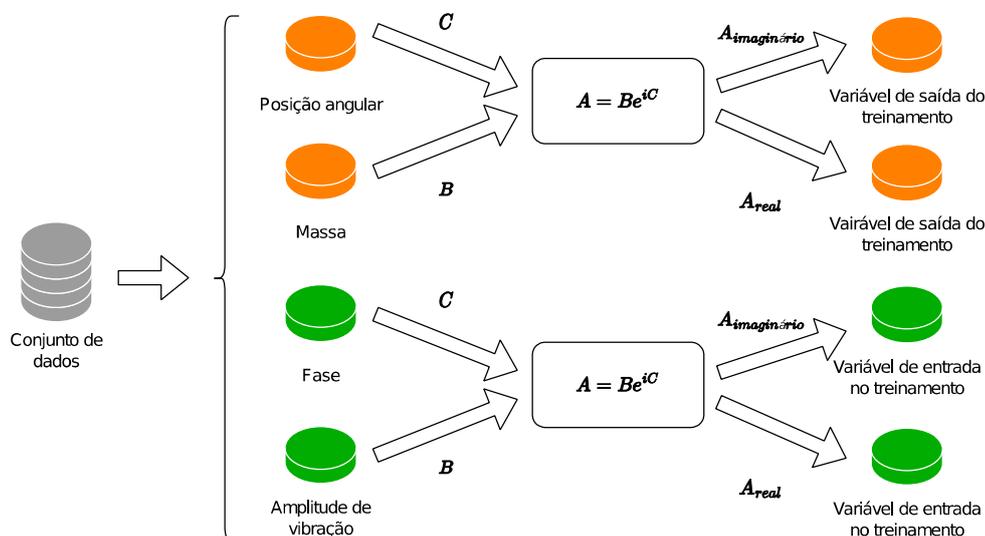


Figura 5.3: Processo de transformação dos dados para as variáveis de entrada/saída da rede neural.

A vantagem deste processo de transformação está na simplificação dos dados de treinamento, de forma que os dados apresentam uma melhor correlação e facilita para a predição dos resultados pela rede neural. Vale ressaltar que as variáveis de entrada e de saída da rede são normalizadas antes do treinamento, através da eq. (5.2) (SALDARRIAGA; STEFFEN JR, 2003), onde R representa o parâmetro não normalizado.

$$N = 2 \cdot \left(\frac{R - \min(R)}{\max(R) - \min(R)} \right) - 1 \quad (5.2)$$

É importante ressaltar que está sendo considerado nos modelos de rede neural que a massa de correção corresponde ao mesmo valor da massa de desbalanceamento, em módulo, porém com uma posição angular defasada em 180° . Essa premissa também é assumida quando se tem dois discos, ou seja, os valores das massas de correção em cada disco são considerados como o mesmo valor das massas de desbalanceamento, porém defasadas em 180° , respectivamente.

Além disso, assim como no modelo de Elementos Finitos e na bancada experimental, as massas de desbalanceamento utilizadas para coleta de dados são introduzidas na região dos discos. No entanto, a localização dos sensores virtuais e de proximidade estão dispostos no eixo (vide localizações dispostas na Tabela 5.1).

A rede neural foi confeccionada em ambiente de programação baseado na linguagem de programação *Python*. Para a construção da arquitetura da rede neural, é utilizado um módulo do *Python* denominado "*KerasTuner*". Segundo O'Malley et al. (2019), esta *API* permite realizar um ajuste da arquitetura da rede neural via hiper parâmetros. Ou seja, as características dos parâmetros do modelo da rede (como número de neurônios, número de camadas, tipo de função de ativação, por exemplo) são tratadas como variáveis de projeto que permitem obter, via processo de busca randômica, um modelo de rede com melhores métricas.

Através deste pacote, é possível configurar o número de tentativas (ou chamada de “*trials*”), que correspondem a quantidade de rodadas que serão avaliadas diferentes combinações de parâmetros na rede. Além disso, também pode ser adicionado ao processo de busca um número de execuções por tentativa, ou seja, quantas vezes os mesmos parâmetros serão avaliados na rede. A proposta deste recurso é reduzir a variância do modelo, ao executar o mesmo parâmetro em novas compilações de rede. O processo de busca randômica utilizado pelo módulo “*Keras Tuner*” (ou denominado de “*Random Search*”) é citado por Pellicer; Pait, (2020) como um processo de teste de combinações dos hiper parâmetros, sendo estes amostrados aleatoriamente dentro de um espaço de busca. Por fim, a arquitetura resultante é dada pela combinação dos hiper parâmetros que alcançam o menor erro possível, dentro da quantidade de iterações utilizada.

A principal métrica de avaliação e função de perda utilizada nesta dissertação é o erro médio quadrático (“*Mean Squared Error*” – *MSE*). Este tipo de função é conveniente para problemas de regressão, semelhante à proposta de rede abordada neste trabalho. Outro parâmetro na rede utilizado é chamado de parada antecipada (ou “*Early stop*”), ou seja, o treinamento da rede neural é encerrado quando em uma determinada quantidade de iterações apresenta pequena variação na função de perda.

5.3. Arquitetura da rede neural via base de dados numérica

Em uma primeira avaliação de como funciona uma rede neural, sua arquitetura e mecanismo de predição, a simulação realizada nesta etapa envolve construir um modelo de rede neural que consiga prever os dados de massa de correção numéricos. Ou seja, a partir dos dados de desbalanceamento gerados via modelo de Elementos Finitos a rede neural é treinada e testada, onde seus valores preditos são avaliados com os dados de saída de teste, calculando-se o erro.

Neste tipo de abordagem, o fato de os dados serem adquiridos numericamente permite realizar uma coleta maior de pontos, o que beneficia o aprendizado da rede

neural ao treinar com uma maior variedade de soluções. A Fig. 5.4 esquematiza o diagrama do processo de simulação da rede.

Por meio da figura, observa-se que uma maior quantidade de dados é adquirida do modelo de Elementos Finitos (uma quantidade arbitrária de valores n). Os parâmetros de massa e posição são introduzidos ao modelo numérico, resultando nos valores de amplitude e fase. Dos conjuntos de n valores de condições (massas e posições) e respostas (amplitudes e fases) uma parcela dos pontos é randomicamente retirada para se tornar o conjunto de teste a ser avaliado pela rede neural já treinada.

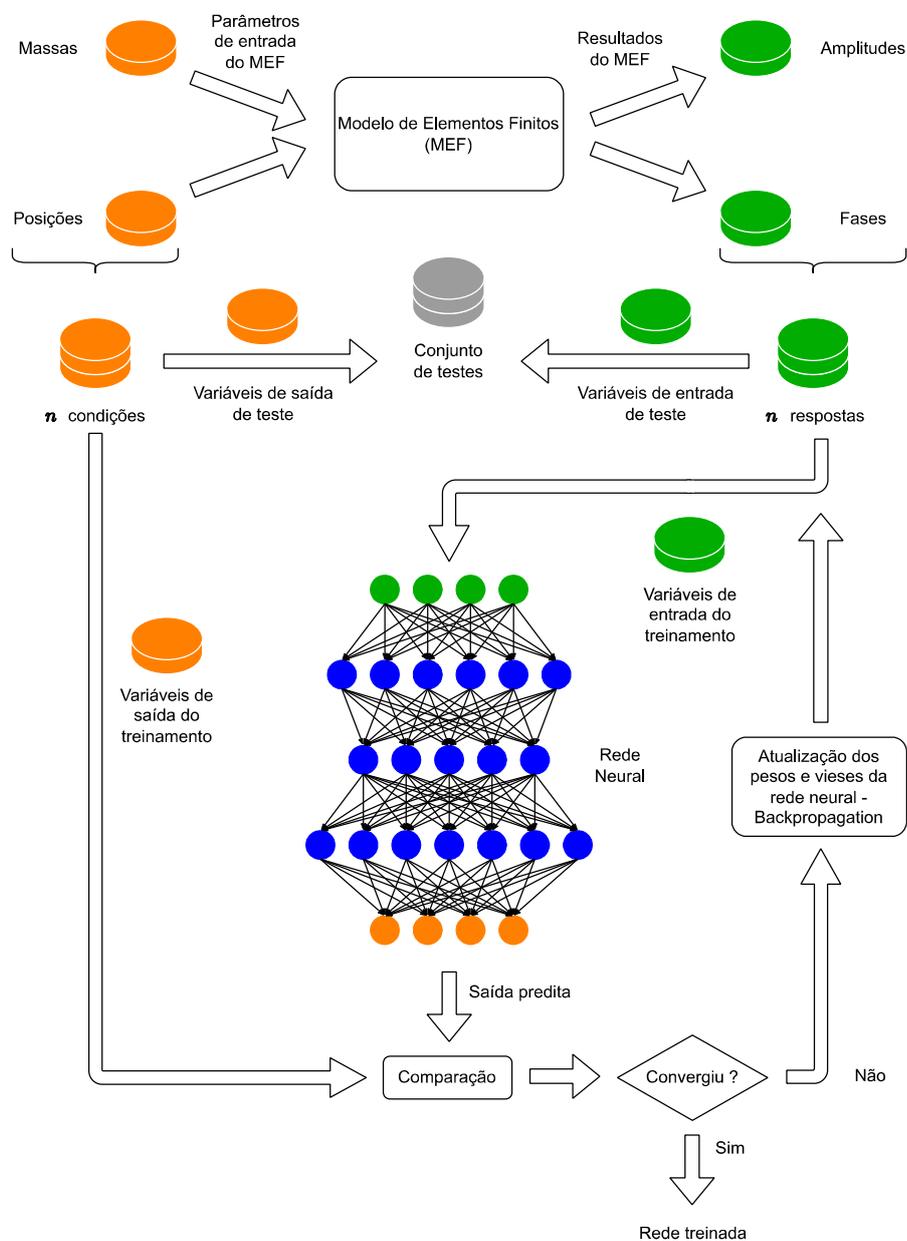


Figura 5.4: Processo de treinamento da rede neural com base de dados numérica.

Os demais dados representam o conjunto de treinamento, onde os valores de amplitude e fase são tratados (vide eq. (5.1)) e inseridos na rede neural como variáveis de entrada. A rede inicia o processo de treinamento ao calcular os pesos e vieses e os

atualizar conforme a avaliação do erro da saída predita com as variáveis de saída (que, no caso, são os valores de massa e posição tratados).

Após a rede neural treinada, é possível determinar o grau de precisão da rede através do conjunto de testes. Dessa forma, a rede irá prever, a partir dos dados de entrada do conjunto de teste, uma saída que é comparada com os dados de saída do conjunto de teste. É importante frisar que o conjunto de teste não apresenta os mesmos valores que o de treinamento. A Fig. 5.5 apresenta o esquema de predição da rede neural.

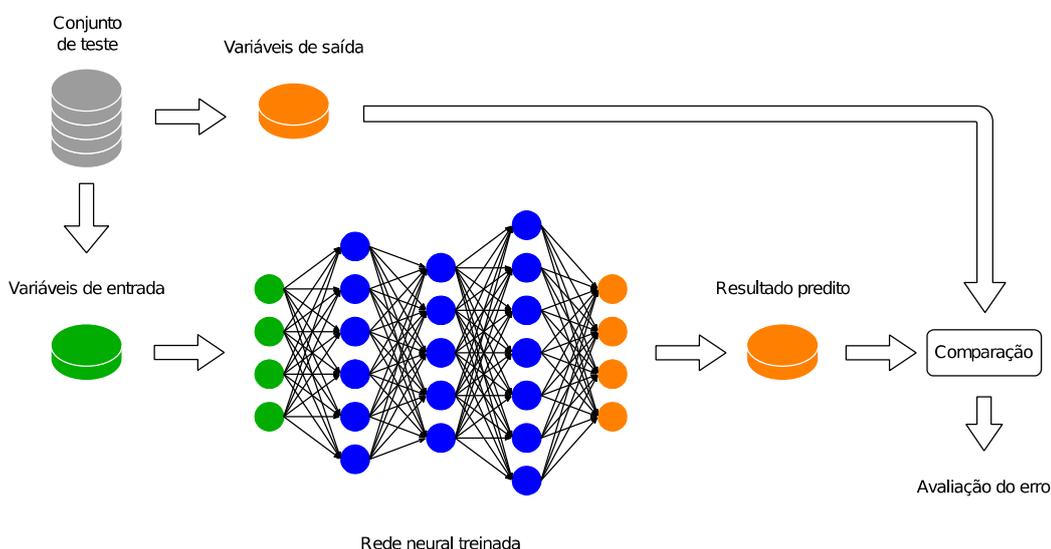


Figura 5.5: Predição da rede neural para o conjunto de teste.

Para as simulações com a arquitetura via banco de dados de treinamento somente numérico é considerado uma rede neural do tipo sequencial que apresenta apenas três camadas (entrada, oculta e saída), onde o número de neurônios nas camadas de entrada e de saída correspondem ao número de variáveis de entrada e de saída da rede para cada tipo de configuração (um disco ou dois). O otimizador utilizado é o “Adam” e é usado o pacote em *Python* do “Keras Tuner”, de forma a obter os melhores parâmetros de rede possível em uma configuração mais simplificada. Os parâmetros da arquitetura de rede que são avaliados são o número de neurônios na camada oculta e a taxa de aprendizado.

5.4. Condições de desbalanceamento e expansão de amostras

Uma vez que a rede neural se torna mais precisa ao introduzir mais pontos que representam melhor o comportamento almejado, é possível então estabelecer um novo procedimento para a formação do conjunto de dados de treinamento. A proposta consiste em formar amostras a partir de uma condição de desbalanceamento, ou seja, a partir de um dado coletado pode-se formar milhares de dados. Neste caso é considerado uma condição de desbalanceamento como sendo uma amostra de amplitude de vibração/fase e sua respectiva massa/posição resultante.

Este processo de formação é visto em processos de expansão de amostras para bancos de imagens, ao alterar características como contraste, cor, orientação, por exemplo. Neste caso, o procedimento realizado neste trabalho é baseado em um comportamento físico, considerando que a massa de correção corresponde ao mesmo valor da massa de desbalanceamento, mas defasada em 180° . Dessa maneira, a massa de desbalanceamento pode estar em qualquer posição angular que a massa de correção será a mesma, mas a 180° de diferença.

Logo, a ideia de formar um novo dado surge da manutenção do valor da massa de correção, mas com uma variação $\delta\alpha$ na posição angular. Dessa forma, a amplitude de vibração do sistema não é afetada em módulo (visto que a massa de desbalanceamento permanece constante), mas sua fase é modificada, de modo que a variação da fase é proporcional ao $\delta\alpha$ acrescido.

Portanto, considerando uma condição de desbalanceamento, ao adicionar um valor de um grau para a posição angular e para a fase do sinal (mantendo constante os valores da massa e da amplitude), pode-se formar um novo dado. Ao realizar este procedimento 360 vezes, consegue-se encontrar 360 amostras (uma para cada posição angular do disco). Reduzindo-se o $\delta\alpha$ permite aumentar ainda mais o número de dados obtidos.

Todavia, é importante destacar que não é apenas a quantidade de dados que promoverá uma rede neural mais precisa. Novamente, a precisão será aprimorada

quando o conjunto de dados de treinamento apresentar uma diversidade de soluções que bem representam o problema.

A proposta da técnica é adotar uma condição de desbalanceamento (amplitude de vibração/fase – massa/posição angular), formar mais amostras e treinar a rede neural para observar o erro resultante. Em seguida, uma nova condição de desbalanceamento (com valores de massa e de amplitude diferentes da primeira condição) é adicionada ao processo, de forma a produzir novas amostras que são adicionadas ao conjunto de treinamento e uma nova rede é treinada para avaliar seu erro. Este procedimento se repete, de modo que o erro da previsão da rede neural se reduz ao longo do aumento de condições. A Fig. 5.6 esboça uma esquematização do processo de expansão de amostras.

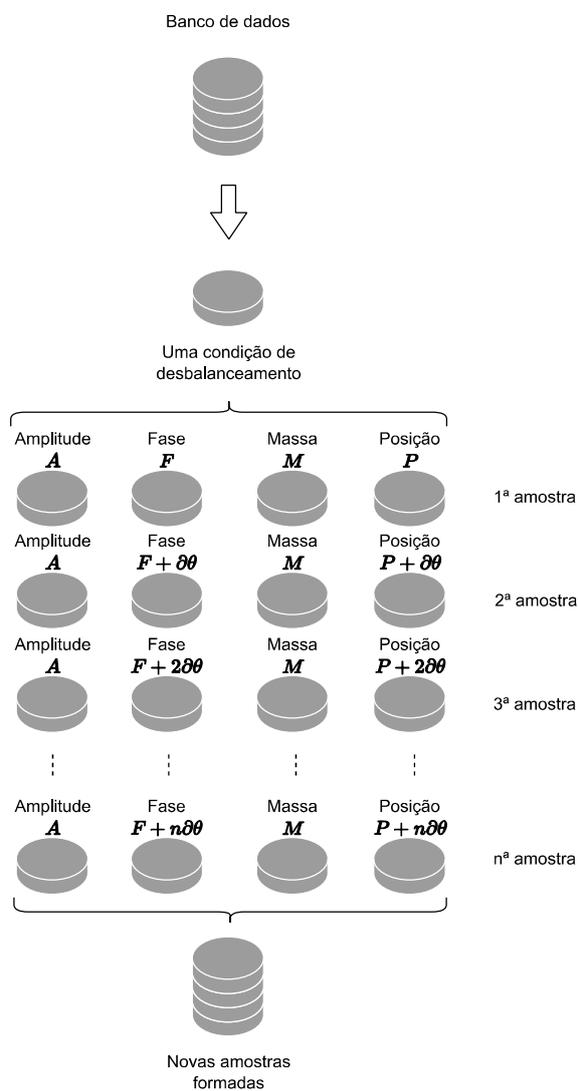


Figura 5.6: Processo de expansão de amostras.

Embora este procedimento permita a construção de um grande conjunto de amostras, o fato de a variação ser apenas nos valores de posição e fase induz o conjunto de dados apresentar uma disparidade entre os parâmetros, o que pode acarretar problemas na rede como, por exemplo, um processo de sobre ajuste (ou chamado de “*overfitting*”), onde a rede treinada se ajusta apenas para os dados de treino, enquanto em demais dados (diferentes dos dados de treinamento) sua performance cai.

5.5. Arquitetura da rede via condições de desbalanceamento numéricos

Ao aplicar a metodologia de expansão de amostras, uma nova arquitetura de rede é gerada. Nesta etapa, alguns dados numéricos (obtidos via modelo de Elementos Finitos) são utilizados como condições de desbalanceamento, enquanto os demais são separados para formarem o conjunto de teste. Conforme citado anteriormente, tais condições de desbalanceamento permitem formar diversas quantidades de amostras, que são adicionadas ao conjunto de treinamento da rede a cada iteração de execução da rede neural.

Neste caso, assim como na primeira etapa, as amostras são coletadas numericamente, o que facilita a obtenção de amostras mais variadas e uniformemente distribuídas. Dessa forma, estima-se que a rede neural resultante apresentará um erro menor que a rede treinada via dados experimentais, visto que os dados experimentais podem não apresentar a mesma dispersão de valores. A Fig. 5.7 apresenta o diagrama do processo de simulação.

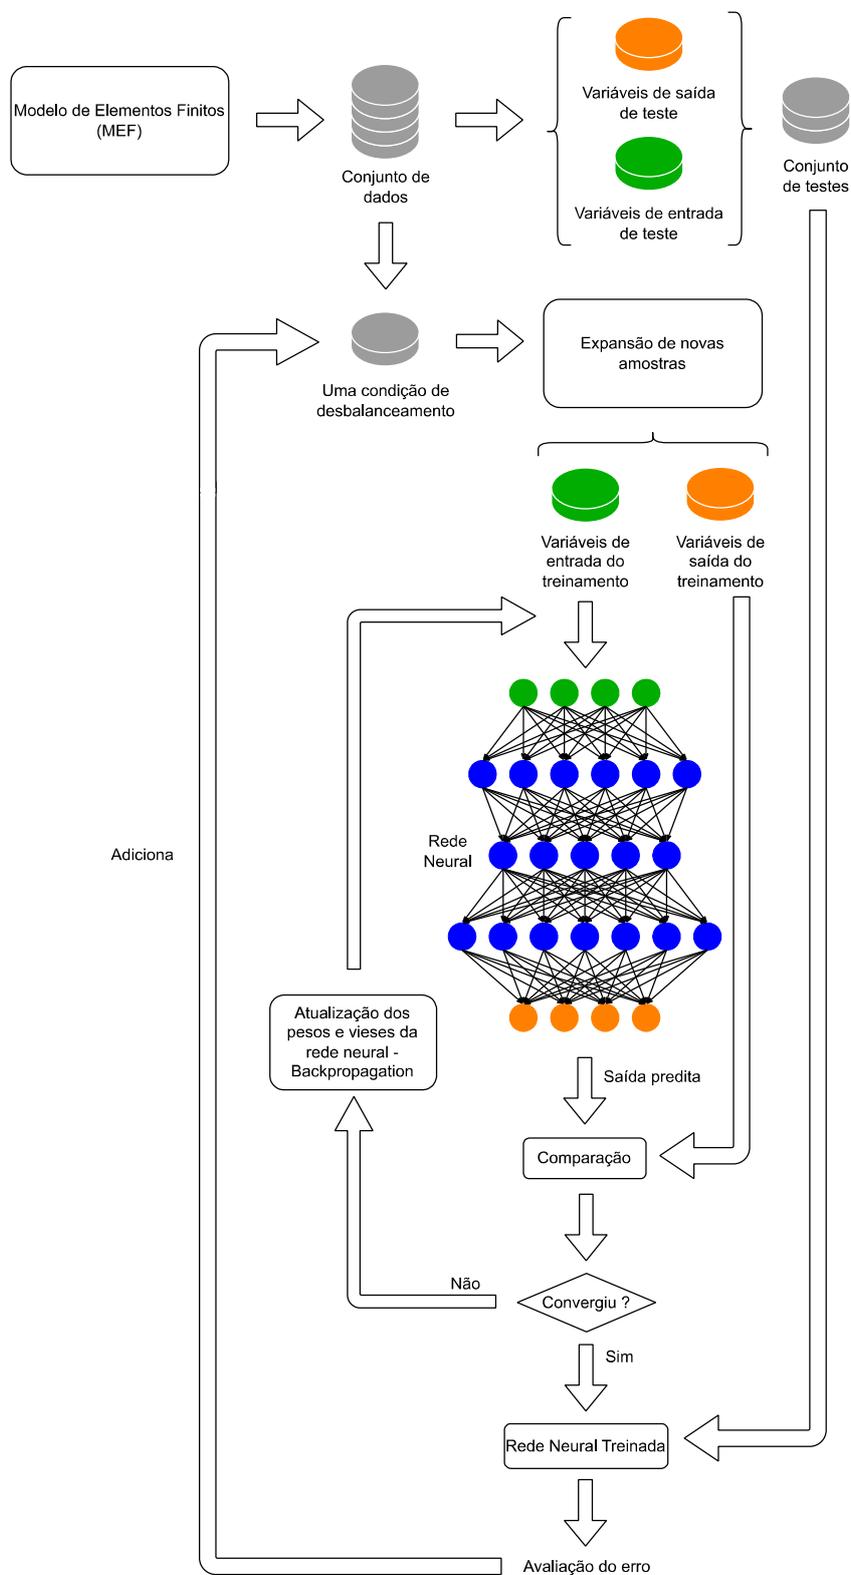


Figura 5.7: Processo de simulação da rede neural com o processo de expansão de amostras.

Conforme visto na Fig. 5.7, o processo de simulação da rede é feito de forma iterativa. Este processo se inicia pela separação do banco de dados adquirido via modelo de Elementos Finitos (lembrando que o *MEF* é utilizado apenas para a construção do banco de dados, nas configurações experimentais os dados são obtidos da bancada experimental). Logo, o banco de dados divide-se em um conjunto de testes e os demais dados, diferentes do conjunto de testes, são utilizados no treinamento, onde apenas uma condição de desbalanceamento é utilizada (a condição de desbalanceamento é dada por uma amostra de amplitude de vibração/fase e respectiva massa/posição angular).

Com o processo de expansão de amostras, uma condição de desbalanceamento resulta em n amostras, compondo o conjunto de dados de treinamento da rede neural. O processo de treinamento da rede é realizado, de forma que é avaliado com o conjunto de testes a rede neural treinada e obtida seu erro. Uma vez que o erro da rede neural é determinado, o ciclo da simulação se repete, ao introduzir uma nova condição de desbalanceamento (ou seja, um novo valor de amplitude de vibração/fase e sua respectiva massa/posição, sendo estes valores diferentes da primeira condição inserida).

Portanto, uma nova expansão de amostras é feita, obtendo-se outras n amostras que são adicionadas às n amostras anteriores, formando um conjunto de treinamento de $2n$ amostras. A rede neural é treinada novamente e um novo erro é obtido quando avaliado com o conjunto de testes. Este ciclo de adição de condições de desbalanceamento é feito até o erro da rede neural convergir ou então alcançar um valor considerado satisfatório.

Neste trabalho são utilizadas 5 condições de desbalanceamento para a realização da simulação (tanto nas configurações numéricas como nas experimentais), enquanto na avaliação do erro o banco de testes é composto por um conjunto de 1000 amostras. Vale ressaltar que, de forma a promover uma dispersão mais uniforme dos dados, são mantidas no conjunto de treinamento as amostras que se mostram mais variáveis, enquanto as demais ficam no conjunto de teste.

Para as configurações envolvendo a estratégia de expansão de amostras, sejam baseadas em bancos de dados de treinamento numéricos ou experimentais, os

parâmetros de arquitetura da rede neural estão relacionados com os obtidos nas redes neurais para banco de dados de treinamento somente numérico e sem o uso da técnica de expansão. Dessa forma, são atribuídas três camadas de uma rede neural do tipo sequencial, sendo uma camada de entrada, uma oculta e outra de saída. O número de neurônios em cada camada é dado pela quantidade de variáveis de entrada e de saída para as camadas de entrada e saída, respectivamente, e na camada oculta é dado pelo resultado obtido pelo módulo “*Keras Tuner*” (assim como a taxa de aprendizado da rede).

5.6. Arquitetura da rede via condições de desbalanceamento experimentais

Por fim, a última etapa envolve a simulação de redes neurais utilizando a técnica de expansão de amostras, porém agora com dados experimentais. Isso significa que outros efeitos que a máquina rotativa pode apresentar na hora da coleta (tal qual ruído, possível desalinhamento, influências externas, entre outros) prejudicam no treinamento da rede em comparação ao sinal numérico, o que pode dificultar na convergência da rede neural.

Da mesma forma que na etapa anterior, são realizados o procedimento para a expansão de amostras, a adição ao conjunto de treinamento e a avaliação do erro da rede. Neste caso também são separados pontos experimentais do banco de amostras para formar o conjunto de testes, onde são mantidas no conjunto de treinamento as amostras mais distribuídas, enquanto as demais passam para o conjunto de teste.

O diagrama do processo de simulação é semelhante ao exposto na Fig. 5.7, porém com amostras reais. Nesta etapa também são consideradas 5 condições de desbalanceamento para a expansão das amostras e composição do conjunto de treinamento, enquanto o conjunto de testes é formado por 5 condições diferentes das utilizadas no treinamento.

CAPÍTULO VI

RESULTADOS E DISCUSSÕES

Este capítulo apresenta os resultados obtidos após as simulações das redes para cada configuração e uma breve análise delas. Sua estrutura é caracterizada pelos resultados da simulação da rede neural para uma base de dados numérica, depois são abordados os resultados da simulação com a técnica de condições de desbalanceamento e expansão de amostras para dados numéricos e, em seguida, experimentais. Vale ressaltar que cada simulação é indicada por um número de configuração.

Também é importante mencionar que foi realizada mais de uma simulação para cada configuração. Dessa forma, foi possível avaliar se o comportamento da rede neural se mantém mesmo rodando novas simulações, além de possibilitar a determinação de um modelo com menor erro. Contudo, os resultados dispostos neste trabalho estão relacionados com a melhor previsão de rede em cada configuração.

6.1. Arquitetura da rede via base de dados numérica

Para o primeiro tipo de simulação, a rede neural foi treinada com um conjunto de dados de treinamento obtido via modelo de Elementos Finitos. Uma parcela das amostras do banco de dados foi separada para a formação do conjunto de testes e o erro da rede foi avaliado através delas.

É importante mencionar que o processo de obtenção das amostras via Elementos Finitos consiste na obtenção dos valores de amplitude de vibração e respectiva fase associadas ao nó do sensor a partir da inserção de valores de massa e posição angular

no nó do disco. Tais valores de massa e de posição são gerados randomicamente, via método de amostragem do hipercubo latino.

Nestas duas primeiras configurações os parâmetros de arquitetura da rede neural são obtidos via processo de busca randômica do módulo “*Keras Tuner*”, de modo a obter a rede neural com menor erro médio quadrático possível em suas execuções (métrica utilizada como função de perda e de avaliação do erro da rede neste trabalho).

6.1.1. Configuração #1 – Rotor com um disco

Com relação à configuração da máquina rotativa para apenas um disco, a Tabela 6.1 apresenta a arquitetura da rede obtida após o processo de execução da busca randômica pelos hiper parâmetros.

Tabela 6.1: Parâmetros obtidos para a rede numérica de um disco

Parâmetros	Obtido
Número de camadas	3
Número de neurônios por camada	[2 6 2]
Funções de ativação por camada	[<i>linear linear linear</i>]
Taxa de aprendizado	$5 * 10^{-5}$

Após o treinamento e predição dos resultados, uma curva que relaciona os dados originais com os resultados preditos é confeccionada e disposta nas Figs. 6.1 e 6.2 (a Fig. 6.1 relacionada à massa de correção e a Fig. 6.2, à posição angular). Em cada figura, percebe-se que existe uma reta com exatos 45° de inclinação, a qual corresponde à melhor condição de operação (onde os dados preditos são iguais aos dados originais).

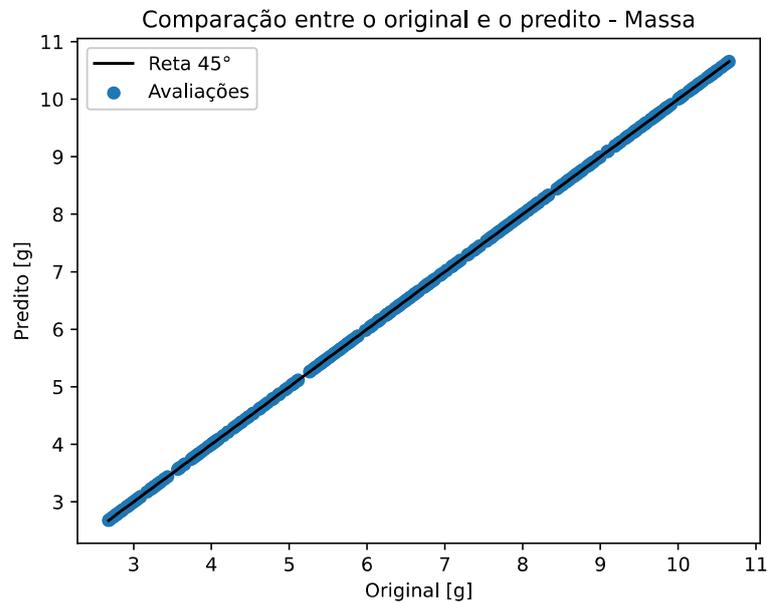


Figura 6.1: Comparação entre os dados originais e preditos associados à massa.

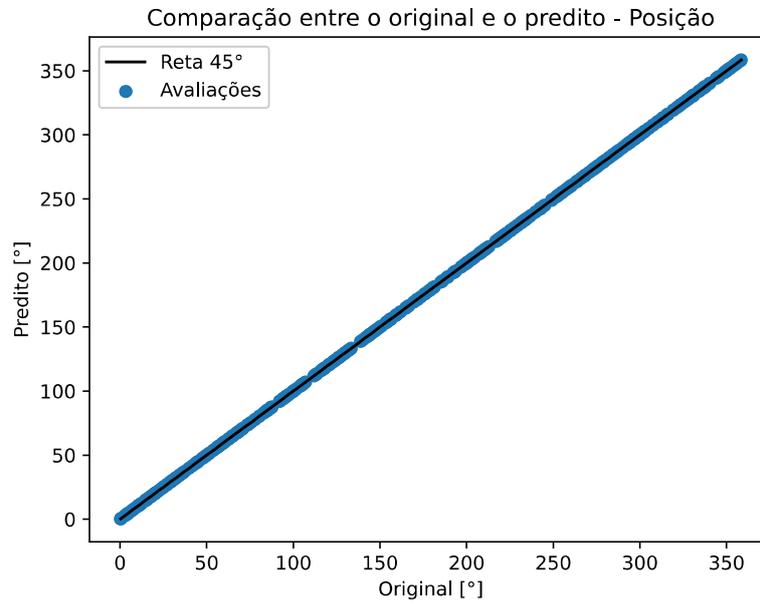


Figura 6.2: Comparação entre os dados originais e preditos associados à posição.

Como esta configuração envolve dados provenientes do modelo de Elementos Finitos, percebe-se o bom ajuste dos dados preditos com os de teste, tanto para massa

como para posição angular, uma vez que tais dados não estão sujeitos a perturbações ou desvios que dados experimentais podem apresentar.

Além disso, o fato de seu banco de dados ser elevado (em virtude do modelo de Elementos Finitos propiciar tal capacidade), ocorre um melhor treinamento da rede neural ao trazer para o treinamento maior variabilidade dos dados, promovendo uma rede adaptada para prever uma banda maior de possibilidades.

De modo a avaliar a função de perda no treino e na validação da rede neural, a Fig. 6.3 ilustra o comportamento de tais curvas, indicando uma redução na função de perda ao longo do avanço das épocas, de forma que não ocorre um aumento.

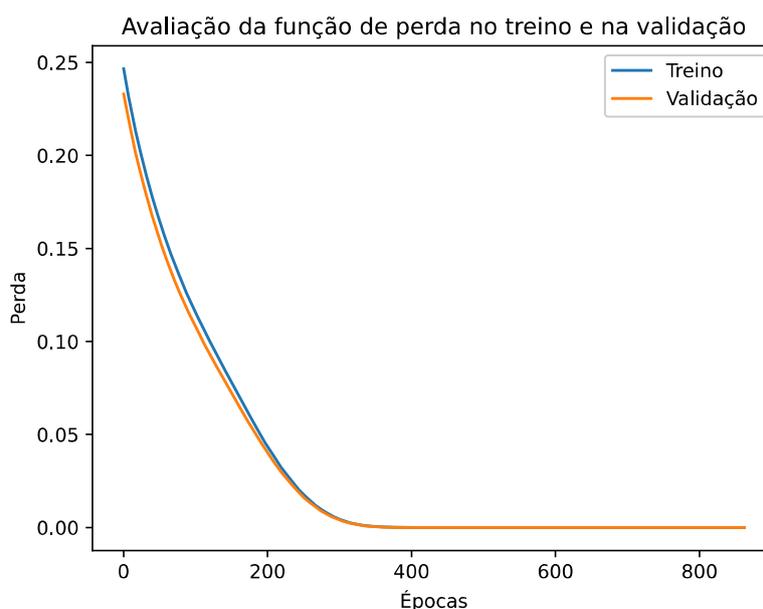


Figura 6.3: Comportamento da função de perda ao longo das épocas para a configuração #1.

De forma a avaliar a diferença entre os resultados preditos e os de teste, foi realizado um processo de balanceamento virtual utilizando o modelo de Elementos Finitos, introduzido no modelo duas condições de correção ao desbalanceamento, uma considerada a melhor amostra prevista pela rede, e outra como a pior previsão. O processo de determinação da melhor e pior condição foi realizado através do cálculo da

soma das distâncias entre os pontos preditos e de teste para massa e posição, sendo a pior condição àquela que apresenta maior valor, enquanto a melhor para o menor valor.

No modelo numérico, portanto, realizou-se a simulação para a condição de desbalanceamento e para a condição de balanceamento (quando acrescentado a massa de correção no sistema) e seus resultados estão dispostos na Tabela 6.2.

Tabela 6.2: Variação da resposta ao desbalanceamento numérico antes e após a correção

Configuração #1 – Numérica – 1 Disco			
Condição	Resposta ao desbalanceamento [μm]	Resposta ao balanceamento [μm]	Redução percentual [%]
Pior	262	0,00018	99,99993
Melhor	270	0,00000	100,00000

Pela Tabela 6.2 percebe-se como a rede conseguiu prever a massa de correção de forma a reduzir quase que por completo a resposta ao desbalanceamento, onde na pior condição (quando a rede neural tem a pior previsão de massa e posição) a redução percentual é muito próxima da melhor condição.

Vale ressaltar que tal rede construída é baseada em dados numéricos e com apenas um disco no sistema, essa combinação contribui para que a rede neural apresente uma boa previsão, visto a linearidade da configuração de um disco associado a um conjunto de treinamento com maior diversidade de dados.

6.1.2. Configuração #2 – Rotor com dois discos

Ao adicionar o segundo disco, uma nova rede é estabelecida, uma vez que é incluída uma segunda massa e sua respectiva posição angular. Após o processo de treinamento e busca dos melhores parâmetro, a construção da rede neural é apresentada na Tabela 6.3.

Tabela 6.3: Parâmetros obtidos para a rede numérica de dois discos

Parâmetros	Obtido
Número de camadas	3
Número de neurônios por camada	[4 6 4]
Funções de ativação por camada	[<i>linear linear linear</i>]
Taxa de aprendizado	$5 * 10^{-5}$

Da mesma forma que foi realizada para a configuração de um disco, uma curva de comparação entre os dados originais e os preditos é feita. Assim, as Figs. 6.4 e 6.5 correspondem às curvas para a massa de correção e de posição angular do primeiro disco, respectivamente, enquanto as Figs. 6.6 e 6.7 referem-se massa e posição do segundo disco, respectivamente.

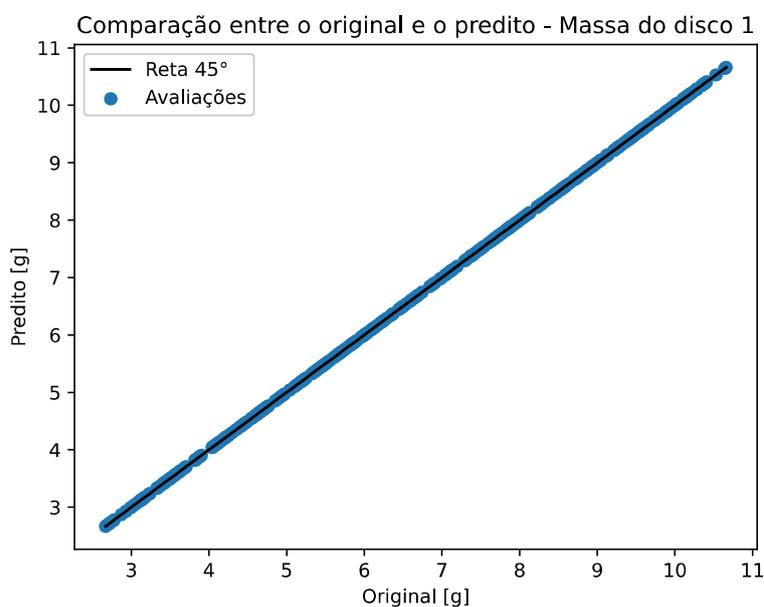


Figura 6.4: Comparação entre os dados originais e preditos associados à massa do primeiro disco.

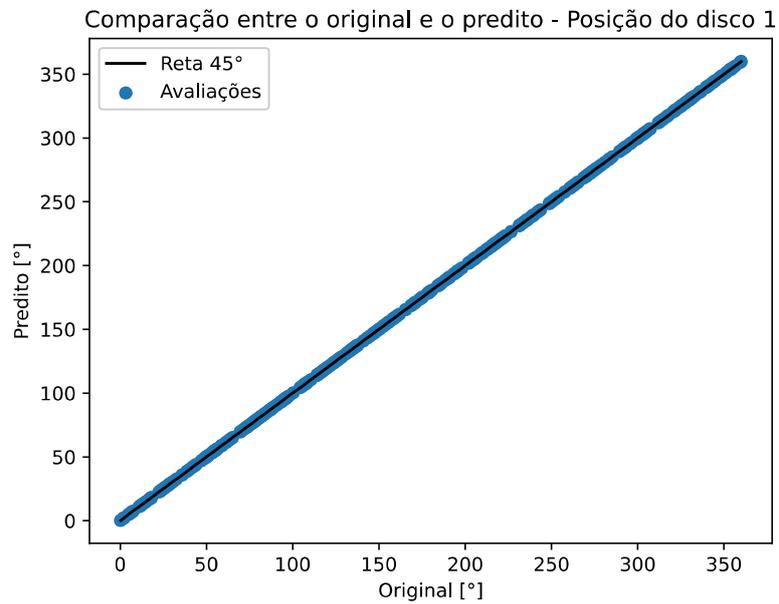


Figura 6.5: Comparação entre os dados originais e preditos associados à posição do primeiro disco.

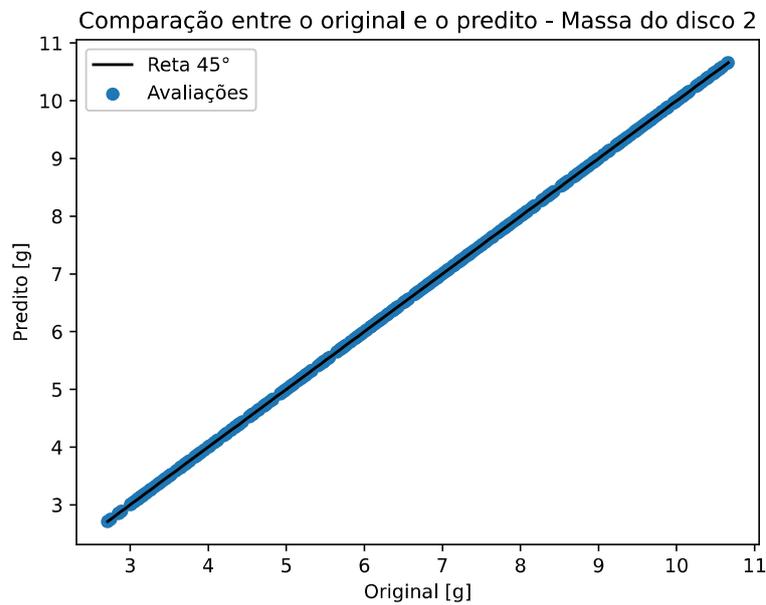


Figura 6.6: Comparação entre os dados originais e preditos associados à massa do segundo disco.

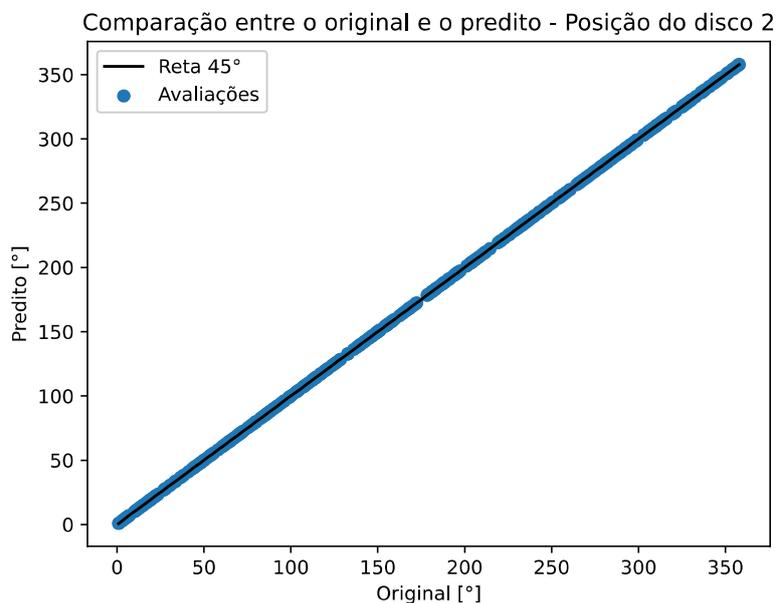


Figura 6.7: Comparação entre os dados originais e preditos associados à posição do segundo disco.

A presença do segundo disco proporciona ao sistema uma nova componente de força, o que promove na máquina rotativa uma resultante de força. Todavia, essa resultante de força pode ser obtida a partir de várias combinações entre massas e posições, tornando mais complexa a caracterização dos valores reais de massa e posição, o que faz a rede neural de dois discos ser mais complexa que a de apenas um.

Contudo, por meio do processo de transformação dos dados descrito no capítulo 5, a rede neural recebe como variáveis de entrada e de saída valores que permitem caracterizar tais combinações, o que facilita seu processo de treinamento ao estabelecer uma melhor correlação entre a amplitude/fase do que é realmente a massa/posição. Portanto, ao visualizar as Figs. 6.4 a 6.7, é possível observar novamente um bom ajuste da rede, uma vez que a correlação entre as variáveis de entrada e de saída se tornaram melhores.

A curva de avaliação da função de perda em relação ao treinamento e à validação também foi realizada e disposta na Fig. 6.8, onde percebe-se a queda da função de perda ao longo das épocas, sem apresentar aumento.

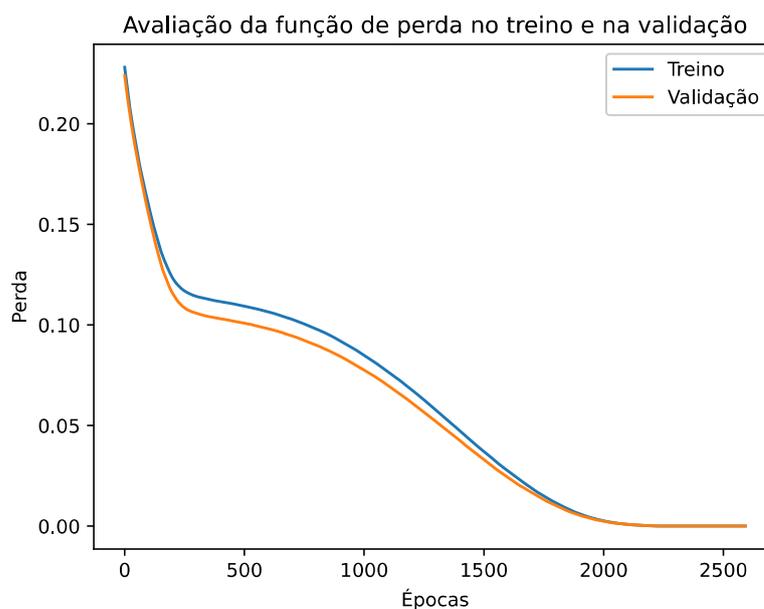


Figura 6.8: Comportamento da função de perda ao longo das épocas para a configuração #2.

Assim como na condição de um disco, também foi proposto avaliar a melhor e pior condição de previsão da rede, ao introduzi-las no modelo numérico e simular a resposta ao desbalanceamento antes e depois da correção via rede neural. Dessa forma, a Tabela 6.4 pontua tais resultados.

Tabela 6.4: Variação da resposta ao desbalanceamento numérico antes e após a correção

Configuração #2 – Numérica – 2 Discos			
Condição	Resposta ao desbalanceamento [μm]	Resposta ao balanceamento [μm]	Redução percentual [%]
Pior	222	0,00010	99,99996
Melhor	158	0,00000	100,00000

A redução da amplitude de vibração para dois discos também apresentou uma queda considerável, com percentuais que praticamente igualam ao resultado de um disco. Novamente nota-se que a variação entre a pior e a melhor condição foram pequenas, o que condiz com as avaliações próximas da reta de 45° ilustrada nas Figs. 6.4 a 6.7. Esse comportamento também é justificável devido a rede ser treinada via banco de dados numérico, com grande quantidade e diversidade dos dados.

6.2. Arquitetura da rede via condições de desbalanceamento numéricos

Nesta etapa, a técnica de expansão de amostras é implementada, onde novas condições de desbalanceamento permitem formar novas amostras e alimentá-las no conjunto de treinamento da rede. Como os dados de treinamento ainda são provenientes do modelo de Elementos Finitos, os dados do conjunto de teste são gerados a parte para garantir valores diferentes do treinamento (lembrando que a banda de coleta é a mesma que a utilizada pelo conjunto de treinamento, permanecendo com a coleta de amostras randômicas).

Vale destacar que nessa abordagem uma curva de acompanhamento do erro da rede neural para cada aumento de condição de desbalanceamento pode ser estabelecida. Logo, é possível verificar como o erro varia ao longo do acréscimo das amostras.

Outro ponto a ser abordado é que, neste caso, condições de desbalanceamento são tratadas como o acréscimo de uma condição de amplitude/fase de desbalanceamento que fornece uma massa/posição de correção, sendo essas diferentes da condição anterior. Dessa forma a rede neural recebe um conjunto de treinamento com maior diversidade de amostras e, conseqüentemente, permite reduzir seu erro.

Por fim, as arquiteturas utilizadas nessas configurações apresentam os mesmos parâmetros que as redes utilizadas nas anteriores, com a diferença de seus pesos e bias serem próprios para cada configuração, dependendo do treinamento realizado.

6.2.1. Configuração #3 – Rotor com um disco

Para a configuração de um disco, os parâmetros da rede são dispostos na Tabela 6.5.

Tabela 6.5: Parâmetros obtidos para a rede de condições numéricas e um disco

Parâmetros	Obtido
Número de camadas	3
Número de neurônios por camada	[2 6 2]
Funções de ativação por camada	[<i>linear linear linear</i>]
Taxa de aprendizado	$5 * 10^{-5}$

Em seguida, a curva da comparação entre os dados originais e os preditos foi confeccionada de modo a observar o comportamento dos dados preditos ao longo do aumento das condições de desbalanceamento. Portanto, a Fig. 6.9 representa a comparação para a massa enquanto a Fig. 6.10, para a posição. Em seguida, uma curva de acompanhamento do erro ao longo de cada condição é ilustrada na Fig. 6.11.

É importante mencionar que os valores de condição apresentados nas legendas das Figs. 6.9 e 6.10 representam as etapas de acréscimo de uma condição de desbalanceamento no conjunto de treinamento. Ou seja, a “Condição 1” vista na legenda representa a previsão da rede neural para um treinamento com um banco de dados expandido para uma apenas uma condição de desbalanceamento (um valor de amplitude de vibração/fase – massa/posição).

Já a “Condição 2” indica a previsão da rede neural em um treinamento com o banco de dados expandido para duas condições de desbalanceamento, uma a condição anterior e outra a nova inserida no conjunto (ambas expandidas para aumentar o conjunto de treinamento). A “Condição 3” acrescenta-se a terceira condição de desbalanceamento e o ciclo se segue até a “Condição 5”, onde se adiciona a quinta condição de desbalanceamento (última condição inserida considerada neste trabalho).

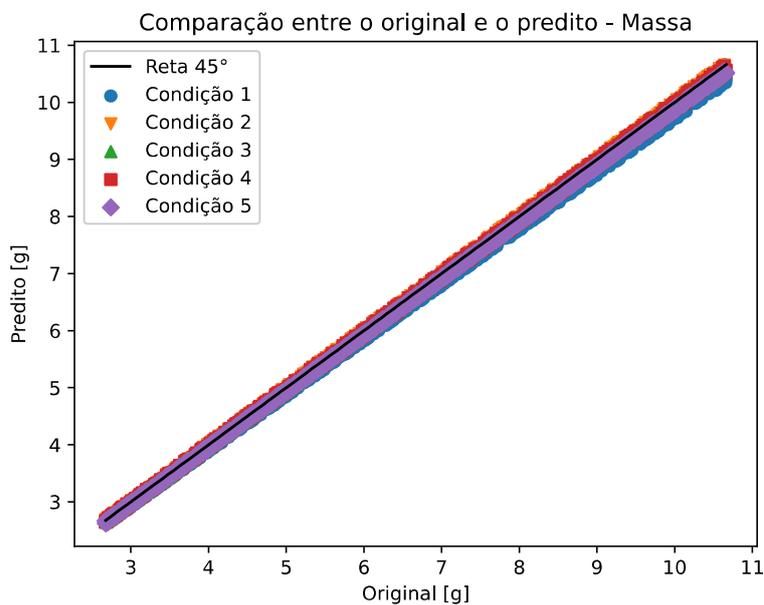


Figura 6.9: Comparação entre os dados originais e preditos associados à massa.

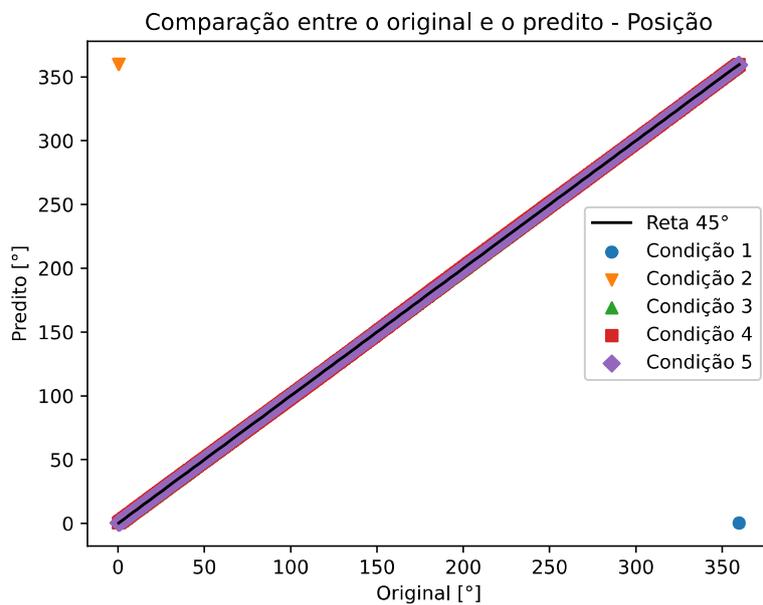


Figura 6.10: Comparação entre os dados originais e preditos associados à posição.

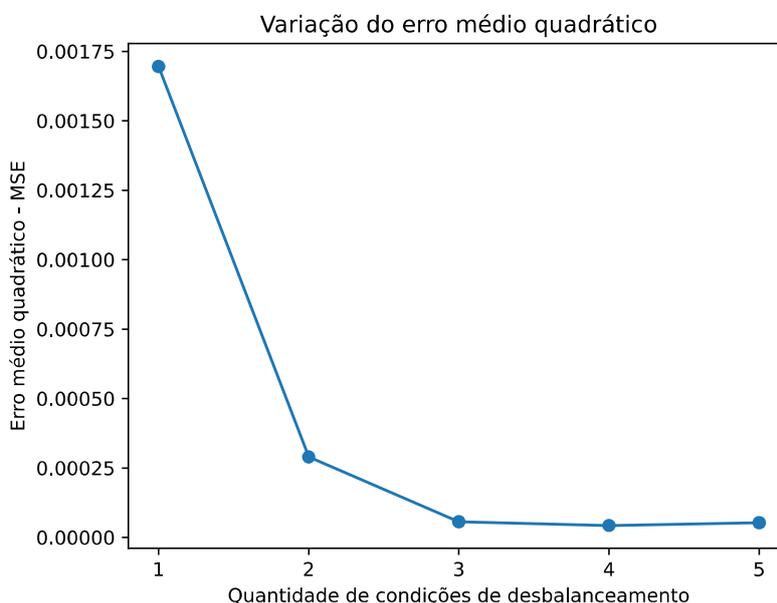


Figura 6.11: Curva de acompanhamento dos erros para os dados numéricos de um disco.

Pelas curvas de comparação, nota-se que o comportamento da previsão é alterado em relação aos anteriores. Esse fenômeno condiz com o esperado, visto que o treinamento da rede permanece com um banco de dados de mesmo tamanho que o formado via Elementos Finitos, porém os dados agora são expandidos a partir de condições de desbalanceamento.

Isso significa que, mesmo a rede neural apresentando um conjunto de treinamento adequado, em termos de quantidade de amostras, é deficitário em termos qualitativos de amostras, pois não irá apresentar a mesma variedade de massas e de amplitudes de vibrações que o modelo anterior fornecia. Portanto, é verificado que uma boa escolha das amostras de massa e amplitude são necessárias para melhor caracterizar a probabilidade de opções que a máquina rotativa pode apresentar.

Na curva de predição de massa, percebe-se que nas primeiras condições de desbalanceamento o resultado da predição não alcança a reta de 45°, ou seja, apresentam um desvio entre as amostras preditas e as de teste. Destaca-se na curva dos valores de posição (Fig. 6.10) que na primeira condição e no acréscimo da segunda

existe a presença de pontos fora da tendência (denominados de “*outliers*”), esses pontos são preditos pela rede, porém estão relacionados ao ângulo de 360° e não ao ângulo de 0° (o que fortalece a ideia das combinações entre posições e massas para alcançar a mesma condição). Todavia na inserção das demais condições tais amostras retornam para o padrão. Essa evolução indica que o aumento da variabilidade de amostras do conjunto de treinamento da rede aperfeiçoou sua predição.

Ao observar a Fig. 6.11 confirma-se a redução do erro ao longo da inserção de condições de desbalanceamento, o que significa a inserção de dados dispersos e qualitativamente adequados para prever mais amostras. A Fig. 6.12 apresenta a evolução da função de perda ao longo das épocas, mantendo a tendência de queda tanto no treino como na validação.

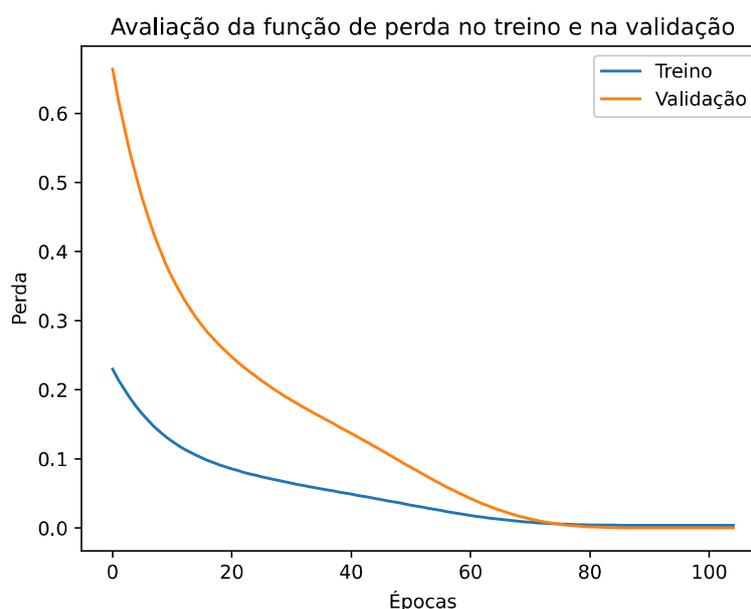


Figura 6.12: Comportamento da função de perda ao longo das épocas para a configuração #3.

Avaliando a pior e melhor condições de previsão da rede neural, considerando a última condição de desbalanceamento inserida na rede (Condição #5 na legenda das Figs. 6.9 e 6.10), a Tabela 6.6 informa os resultados obtidos.

Tabela 6.6: Variação da resposta ao desbalanceamento numérico antes e após a correção

Configuração #3 – Condições Numéricas – 1 Disco			
Condição	Resposta ao desbalanceamento [μm]	Resposta ao balanceamento [μm]	Redução percentual [%]
Pior	114	2,31716	97,95939
Melhor	125	0,96510	99,22648

Conforme esperado, a previsão da rede neural para as condições numéricas em relação às configurações anteriores apresentou uma queda. Contudo, essa diminuição não se mostrou elevada, com uma redução percentual permanecendo acima de 97%. Esse comportamento permanece sendo resultado da presença de um único disco no sistema, o que promove um caráter mais linear e que facilita o treinamento da rede.

6.2.2. Configuração #4 – Rotor com dois discos

Com o acréscimo do segundo disco, os parâmetros da rede são atualizados e apresentados na Tabela 6.7.

Tabela 6.7: Parâmetros obtidos para a rede de condições numéricas e dois discos

Parâmetros	Obtido
Número de camadas	3
Número de neurônios por camada	[4 6 4]
Funções de ativação por camada	[<i>linear linear linear</i>]
Taxa de aprendizado	$5 * 10^{-5}$

Novamente, as curvas de comparação são geradas e dispostas nas Figs. 6.13 e 6.14 (para o primeiro disco) e nas Figs. 6.15 e 6.16 (para o segundo disco). A curva de acompanhamento do erro também é formada e visualizada na Fig. 6.17.

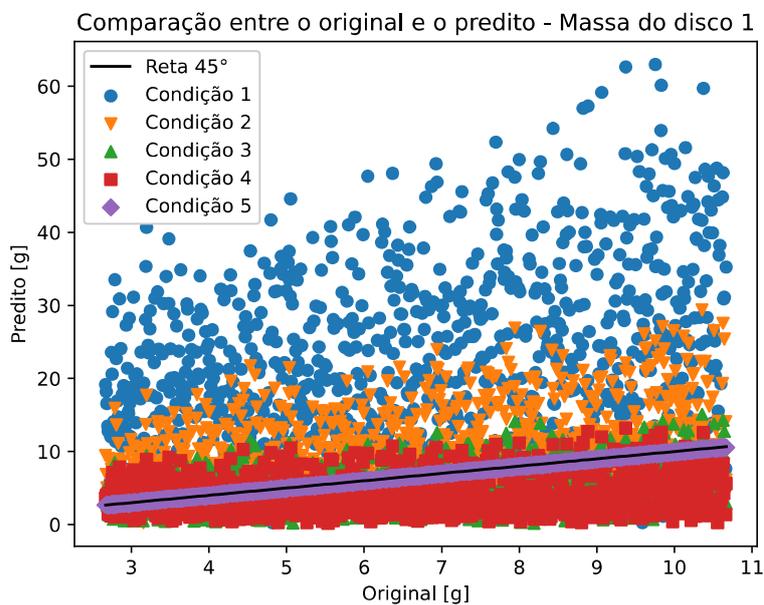


Figura 6.13: Comparação entre os dados originais e preditos associados à massa do primeiro disco.

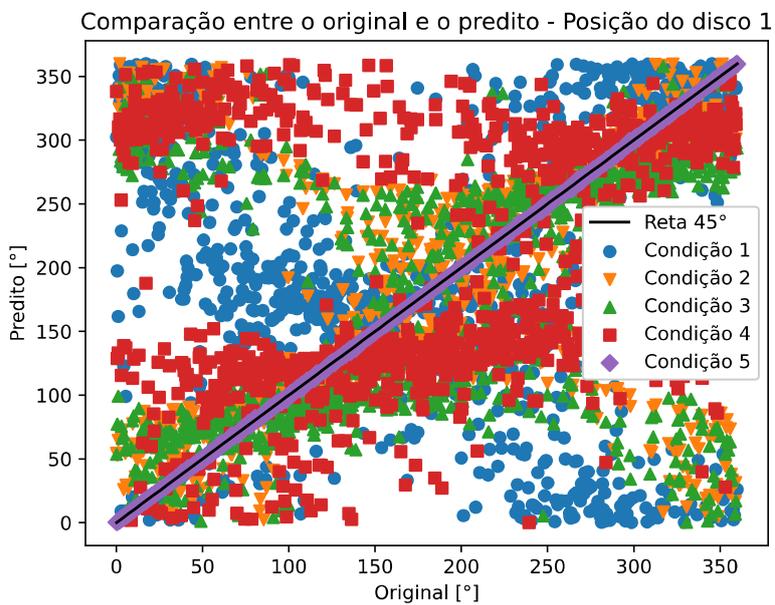


Figura 6.14: Comparação entre os dados originais e preditos associados à posição do primeiro disco.

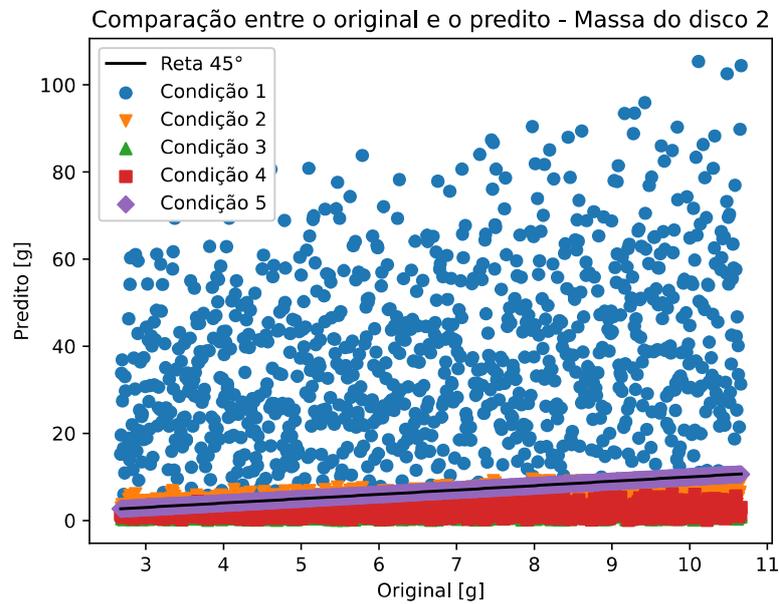


Figura 6.15: Comparação entre os dados originais e preditos associados à massa do segundo disco.

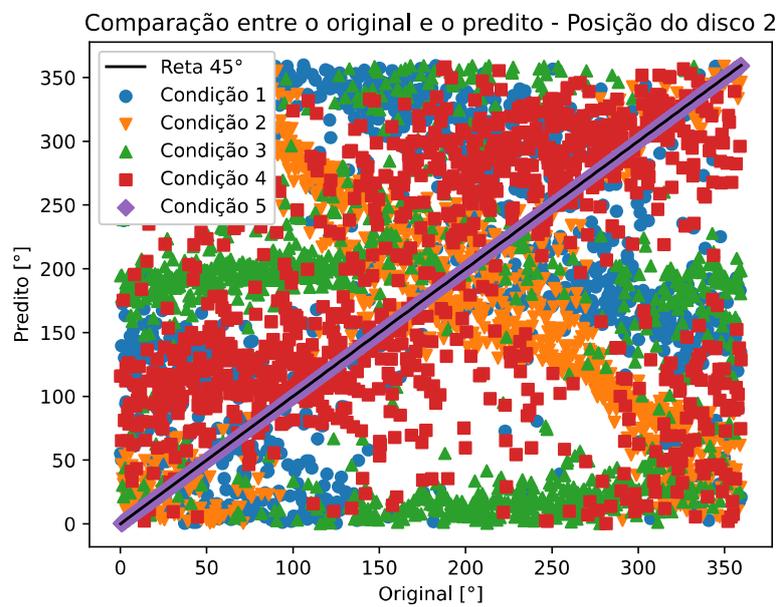


Figura 6.16: Comparação entre os dados originais e preditos associados à posição do segundo disco.

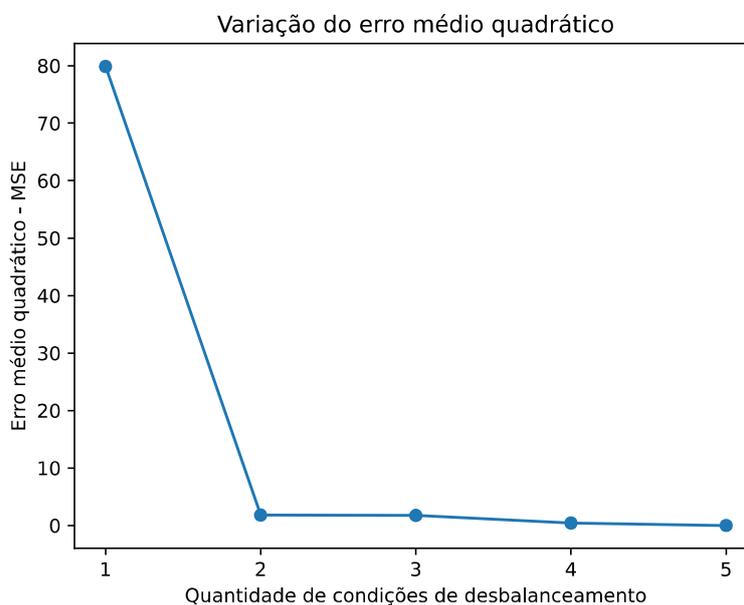


Figura 6.17: Curva de acompanhamento dos erros para os dados numéricos de dois discos.

Tal qual abordado anteriormente, o acréscimo do segundo disco implicou na maior complexidade do problema, o que resultou em um maior desvio da previsão se comparado com a configuração de um disco (Configuração #3). Além disso, fica evidente que nas primeiras condições de desbalanceamento ocorre uma perda de previsão pela rede, com resultados dispersos. Contudo, a rede neural consegue se ajustar conforme são acrescentadas novas condições de desbalanceamento, o que permitiu reduzir seu erro.

A Fig. 6.18 indica a evolução da função de perda para o treino e a validação da rede neural, mostrando uma queda em ambas as situações.

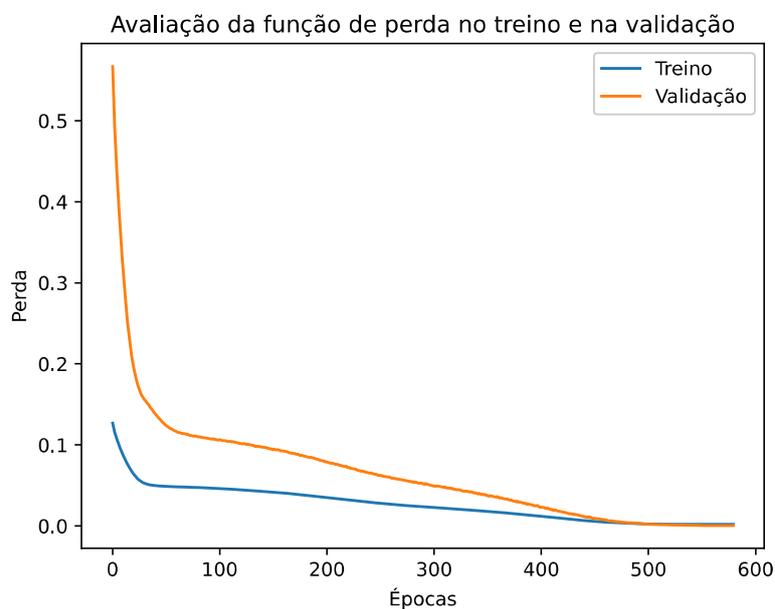


Figura 6.18: Comportamento da função de perda ao longo das épocas para a configuração #4.

Da mesma maneira que é feita nas configurações anteriores, duas condições são simuladas via modelo numérico de modo a observar a redução da amplitude de vibração do rotor ao incluir a massa de balanceamento, sendo avaliadas a pior e a melhor condição que a rede neural foi capaz de prever. Logo, a Tabela 6.8 apresenta os resultados das respostas de vibração antes e depois do balanceamento.

Tabela 6.8: Variação da resposta ao desbalanceamento numérico antes e após a correção

Configuração #4 – Condições Numéricas – 2 Discos			
Condição	Resposta ao desbalanceamento [μm]	Resposta ao balanceamento [μm]	Redução percentual [%]
Pior	103	1,15530	98,87867
Melhor	200	1,95171	99,02515

Neste caso, a configuração da rede obtida permitiu obter um resultado de redução percentual melhor que o alcançado pela configuração de um disco. Contudo, o valor da redução percentual entre ambas as configurações (um e dois discos) se mostraram próximos. Além disso, ao comparar o comportamento do erro médio quadrático para as configurações (Figs. 6.11 e 6.17), percebe-se o elevado erro na configuração de dois discos em relação às primeiras condições de desbalanceamento, o que é esperado devido ao acréscimo do outro disco.

6.3. Arquitetura da rede via condições de desbalanceamento experimentais

A etapa final corresponde a construção da rede neural com a metodologia da expansão de amostras para dados experimentais. A substituição dos dados coletados por dados experimentais implica no aumento de complexidade para a rede neural, visto a variedade de fatores que influenciam nos valores dos dados, como a presença de ruídos, por exemplo.

Como os dados agora são experimentais, dez amostras foram coletadas, sendo utilizadas cinco amostras como condições de treinamento e as demais como amostras de testes para verificação do erro. Também são utilizados os mesmos parâmetros de construção da rede neural abordados nas configurações anteriores.

6.3.1. Configuração #5 – Rotor com um disco

Na configuração de um disco, os parâmetros da rede estão contidos na Tabela 6.9.

Tabela 6.9: Parâmetros obtidos para a rede de condições experimentais de um disco

Parâmetros	Obtido
Número de camadas	3
Número de neurônios por camada	[2 6 2]
Funções de ativação por camada	[<i>linear linear linear</i>]
Taxa de aprendizado	$5 * 10^{-5}$

Com o mesmo procedimento utilizado na etapa anterior, as curvas da comparação entre os dados originais e os preditos foram confeccionadas e incluídas na Fig. 6.19 (para a massa) e na Fig. 6.20 (para a posição). A curva de acompanhamento do erro ao longo de cada condição é disposta na Fig. 6.21. Vale destacar que, assim como nas configurações #3 e #4, os termos de condições abordados nas legendas das Figs. 6.19 e 6.20 correspondem ao acréscimo de condições de desbalanceamento (um valor de amplitude de vibração/fase – massa/posição) no conjunto de treinamento da rede.

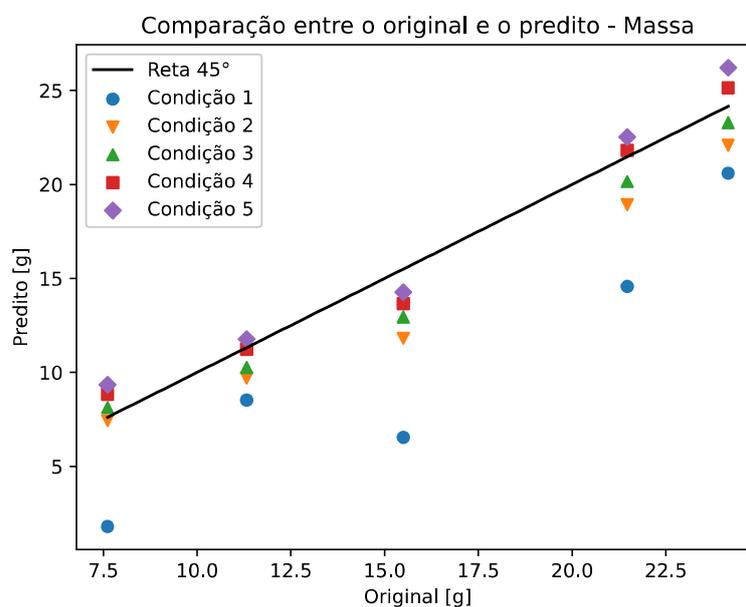


Figura 6.19: Comparação entre os dados originais e preditos associados à massa.

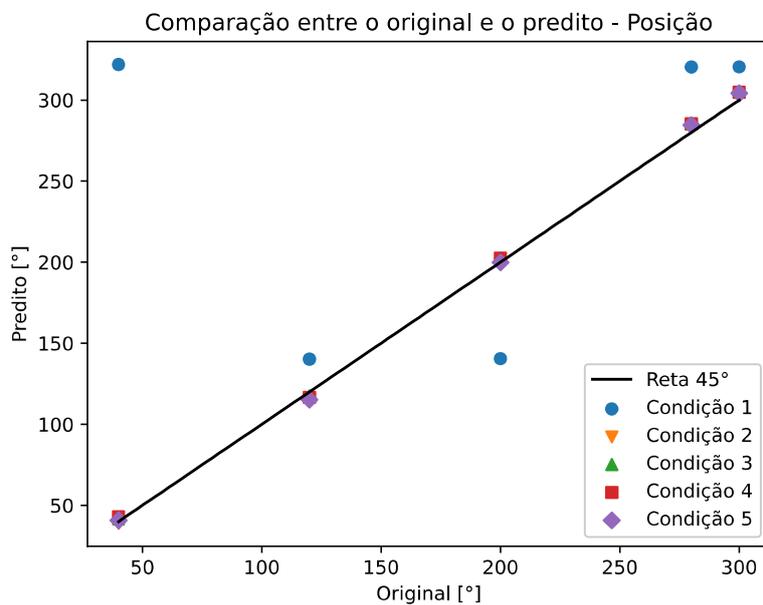


Figura 6.20: Comparação entre os dados originais e preditos associados à posição.

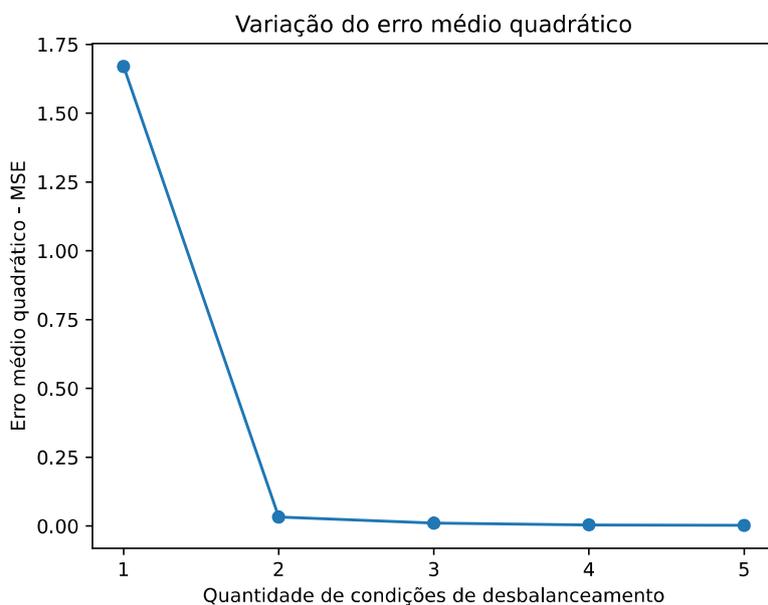


Figura 6.21: Curva de acompanhamento dos erros para os dados experimentais de um disco.

Nesta etapa, os dados deixam de serem numéricos e passam para o âmbito experimental. Em uma primeira constatação, nota-se a discrepância do experimental em relação ao numérico, com o erro entre o predito e o teste sendo maior em relação às configurações anteriores. Essa diferença se mostra mais evidente ao observar as condições de desbalanceamento introduzidas, onde nas primeiras condições o desvio em relação à reta de 45° é maior quando comparadas às primeiras condições do numérico (Configuração #3).

Todavia, ao acrescentar mais condições ao conjunto de treinamento ocorre uma evolução da predição, viabilizando uma melhor previsão das amostras. Isso é perceptível ao observar nas Figs. 6.19 e 6.20 a tendência das amostras em se aproximar da reta de 45° quando aumentam as condições, e na Fig. 6.21 pela redução do erro.

Neste caso o efeito da grande diversidade de dados em relação à posição com a carência nos valores de massa resulta na melhor previsão da rede neural para a posição, enquanto a massa permanece mais afastada da reta de 45° , o que é confirmado pelas Figs. 6.19 e 6.20. A Fig. 6.22 mostra o comportamento da função de perda para a arquitetura de rede obtida. Novamente percebe-se uma queda na função de perda ao longo das épocas, em ambas as situações (treino e validação).

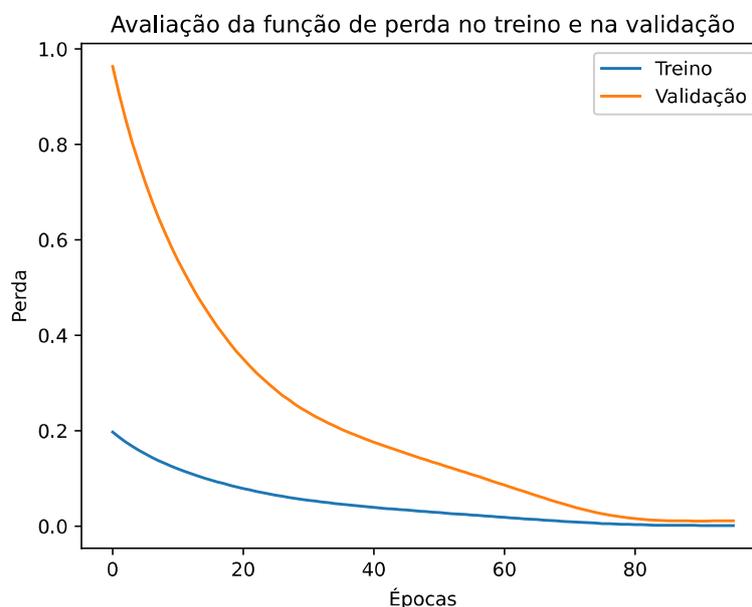


Figura 6.22: Comportamento da função de perda ao longo das épocas para a configuração #5.

Conforme as configurações anteriores, também é realizado uma avaliação da redução da amplitude de vibração do sistema para a pior e melhor condição de predição da rede neural. Neste caso, são realizadas avaliações para a simulação experimental, ou seja, é avaliado na bancada experimental quanto de redução percentual ocorreu na resposta ao desbalanceamento. A Tabela 6.10 apresenta os resultados obtidos.

Tabela 6.10: Variação da resposta ao desbalanceamento experimental antes e após a correção

Configuração #5 – Condições Experimentais – 1 Disco			
Condição	Resposta ao desbalanceamento [μm]	Resposta ao balanceamento [μm]	Redução percentual [%]
Pior	36	7	80,55556
Melhor	87	6	93,10345

Ao observar a tabela, percebe-se que a redução percentual caiu em relação às anteriores. Este comportamento condiz com o esperado, visto que os dados

experimentais apresentam influência de fatores externos aos quais o numérico não está reproduzindo. Porém, a rede ainda permanece prevendo resultados acima de 80 % na redução. Outro fator ligado ao desempenho da rede, assim como na configuração numérica, é a simplicidade do sistema, uma vez que a máquina apresenta um disco apenas.

6.3.2. Configuração #6 – Rotor com dois discos

Com dois discos, a complexidade se eleva, pois além de encontrar diferentes combinações de massas e posições para a mesma resultante de forças, os dados são experimentais, o que pode deixar as correlações entre as variáveis de entrada e de saída menores. Os parâmetros da rede são apresentados na Tabela 6.11.

Tabela 6.11: Parâmetros obtidos para a rede de condições numéricas e dois discos

Parâmetros	Obtido
Número de camadas	3
Número de neurônios por camada	[4 6 4]
Funções de ativação por camada	[<i>linear linear linear</i>]
Taxa de aprendizado	$5 * 10^{-5}$

As curvas de comparação são indicadas nas Figs. 6.23 e 6.24 (para o primeiro disco) e nas Figs. 6.25 e 6.26 (para o segundo disco). A curva de acompanhamento do erro é apresentada na Fig. 6.27.

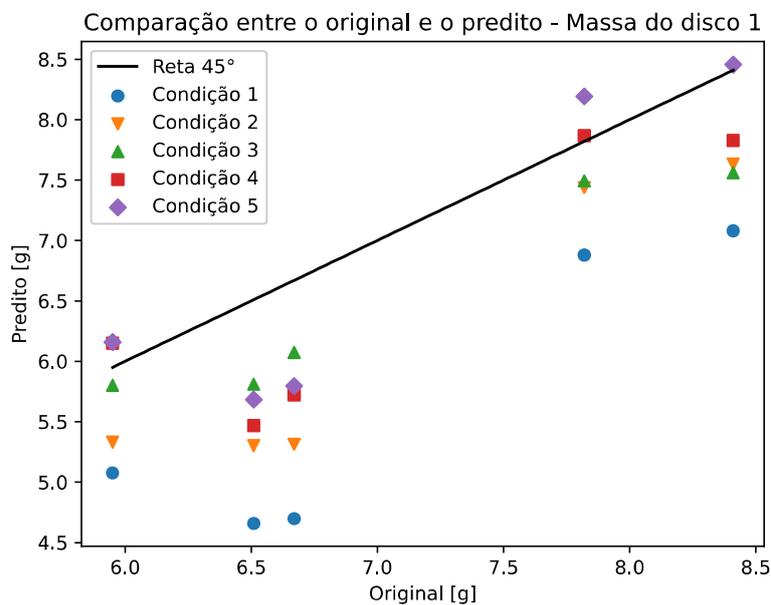


Figura 6.23: Comparação entre os dados originais e preditos associados à massa do primeiro disco.

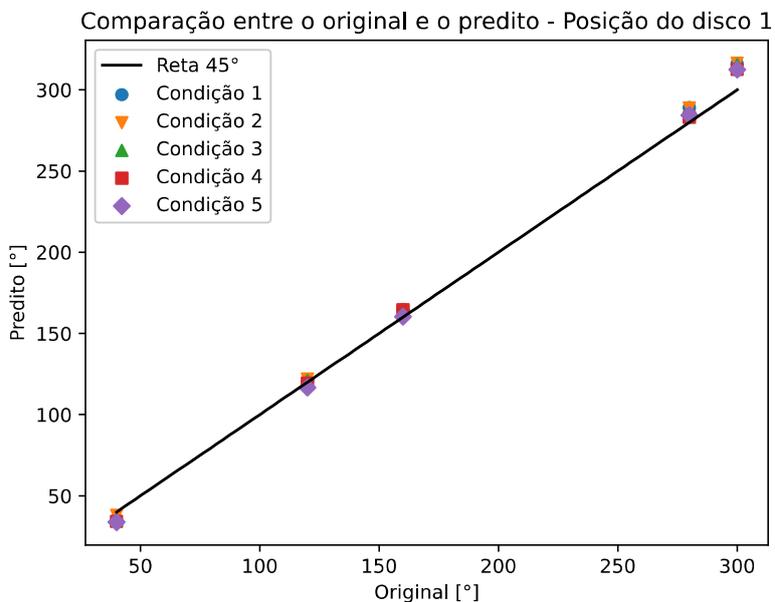


Figura 6.24: Comparação entre os dados originais e preditos associados à posição do primeiro disco.

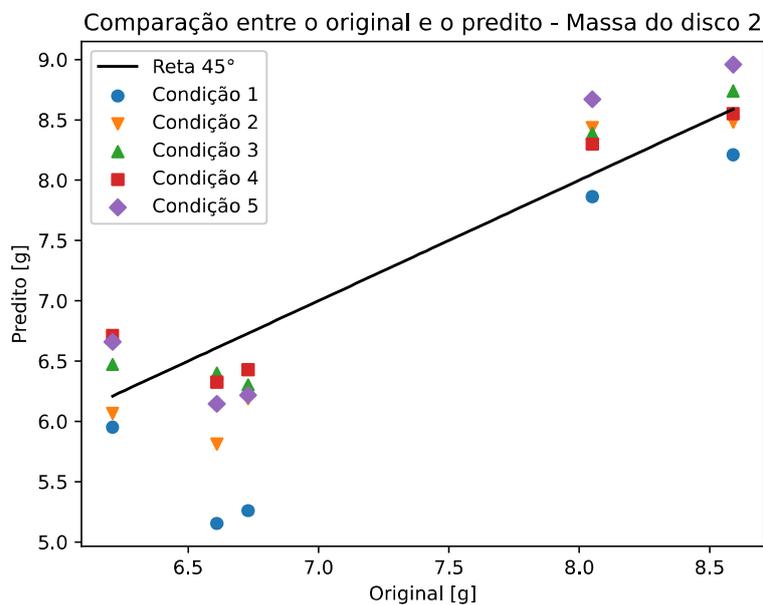


Figura 6.25: Comparação entre os dados originais e preditos associados à massa do segundo disco.

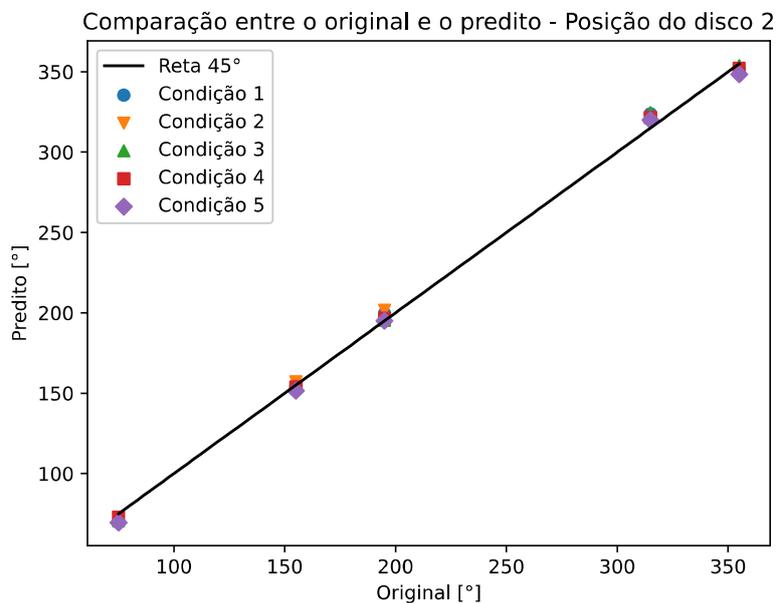


Figura 6.26: Comparação entre os dados originais e preditos associados à posição do segundo disco.

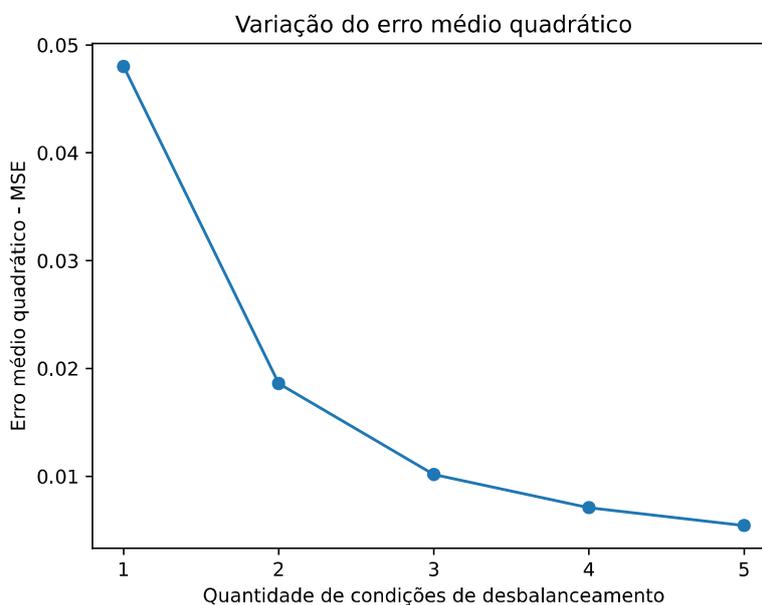


Figura 6.27: Curva de acompanhamento dos erros para os dados experimentais de dois discos.

Conforme mencionado anteriormente, a configuração de dois discos experimental se mostra a mais complexa dentre as configurações abordadas neste trabalho. Uma vez que são considerados poucos dados para a rede neural, associado com a combinação de massas e posições dos dois discos e a presença de imperfeições na coleta dos dados experimentais, a correlação entre as variáveis de entrada com as de saída se reduz.

Dessa forma, o que é apresentado pelas curvas das Figs. 6.23 a 6.26 condizem com o esperado. Contudo, novamente percebe-se que a rede promove uma evolução na predição das amostras, com a tendência de alcançar a reta de 45° à medida que as condições de desbalanceamento são incrementadas no conjunto de testes. Outra forma de notar que a rede evolui está na Fig. 6.27, onde o erro reduz ao longo do acréscimo de condições.

Outro ponto a ser comentado envolve o melhor grau de ajuste da predição da posição que da massa. Novamente, a possível justificativa para tal discrepância está relacionada com o método de expansão de amostras, onde o conjunto de treinamento da rede (mesmo aumentando as condições de desbalanceamento) não altera os valores das

massas. Isso significa que na formação das amostras tem-se n pontos formados com valores de posição e fase variados, mas de massa e de amplitude constantes, o que implica em uma rede neural com menos variabilidade de massas para predição, mas alta para posição.

Conforme observado nas configurações anteriores, a evolução da função de perda, tanto no treino como na validação, apresenta uma queda no erro. A Fig. 6.28 ilustra este comportamento.

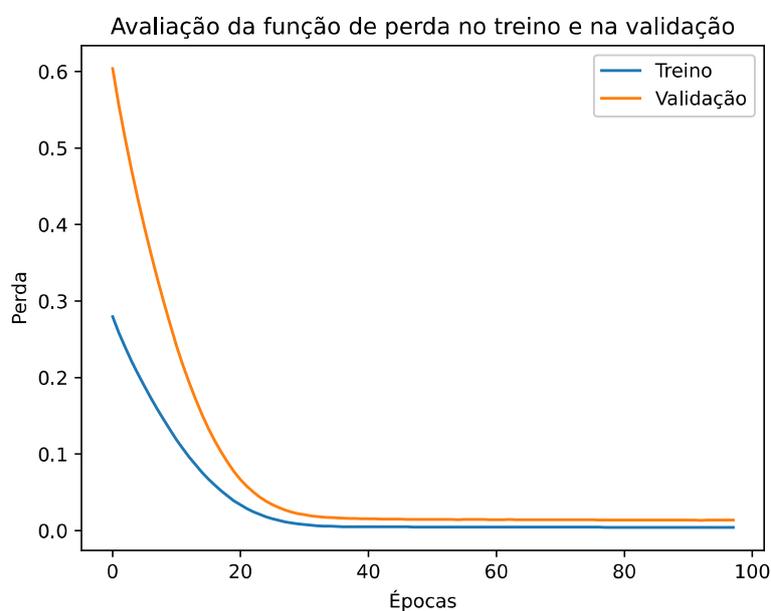


Figura 6.28: Comportamento da função de perda ao longo das épocas para a configuração #6.

Considerando a pior e melhores condições de previsão da rede, confecciona-se a Tabela 6.12 de modo a apresentar seus resultados de redução ao realizar o balanceamento.

Tabela 6.12: Variação da resposta ao desbalanceamento experimental antes e após a correção

Configuração #6 – Condições Experimentais – 2 Discos			
Condição	Resposta ao desbalanceamento [μm]	Resposta ao balanceamento [μm]	Redução percentual [%]
Pior	67	13	80,59701
Melhor	49	9	81,63265

Ao avaliar a Tabela 6.12, é possível notar que realmente houve uma queda na redução percentual da amplitude de vibração, porém, a pior predição da rede envolve uma redução de 80 %, o que ainda representa mais da metade da redução de amplitude.

CAPÍTULO VII

CONCLUSÕES

Este capítulo aborda as conclusões observadas neste trabalho, elaborando um passo a passo do que fora tratado ao longo do texto e comentando aspectos relacionados ao mesmo. No final, são apresentadas propostas para trabalhos futuros.

Esta dissertação apresentou a implementação de uma metodologia de balanceamento de máquinas rotativas através do uso de redes neurais artificiais, onde foi introduzido o uso de uma metodologia de expansão de amostras. Dessa forma, a proposta envolvia realizar o balanceamento do rotor sem a necessidade do uso de massas de teste, além de reduzir a quantidade de amostras necessárias para o treinamento da rede neural.

Ao longo do texto, foram abordados histórias, conceitos e aplicações do que representa uma máquina rotativa. Também fora apresentado um pouco de sua modelagem e remeteu ao procedimento de balanceamento, um dos principais problemas relacionados com a vibração do rotor. Brevemente foram citadas outras técnicas e trabalhos envolvendo relacionados ao balanceamento, aos quais também está inserida a rede neural, parte integrante deste trabalho.

Para realizar a implementação e, conseqüentemente, as simulações, seis configurações diferentes foram adotadas, de modo que a cada avanço de configuração representou uma maior complexidade para a rede neural. Uma estratégia de expansão de dados foi mencionada, onde n pontos podem ser adicionados ao conjunto de treinamento da rede neural de modo a variar os parâmetros de fase e posição angular e garantir a constância dos valores de amplitude e massa, o que permite grandes bancos de dados para a rede. Além disso, considerações foram estabelecidas, como a relação

linear presente no método de expansão de amostras, a transformação dos dados para o formato exponencial e sua normalização para facilitar a correlação entre as variáveis de entrada com as de saída.

Em seguida foram dispostos os resultados obtidos em cada configuração. Conforme o esperado, nas configurações em que o banco de dados era maior em quantidade e mais variado qualitativamente, configurações #1 e #2, os resultados chegaram em previsões que reduziram a amplitude de vibração do rotor em mais de 99 %. Esse alto grau de ajuste não somente foi possível pela grande quantidade de dados de treinamento gerados via modelo numérico. É importante mencionar que a arquitetura da rede neural sofreu por um processo de busca randômica de seus parâmetros, permitindo uma melhor configuração da rede neural, o que também contribui para a melhor previsão das amostras.

Nas configurações #3 e #4 empregou-se a metodologia de expansão de amostras. Pelos resultados foi possível enxergar uma queda no rendimento da rede, uma vez que agora é pouca a variabilidade dos dados introduzidos na rede neural, principalmente para os parâmetros de amplitude e massa (conforme se nota ao observar os gráficos de comparação um melhor ajuste na variável de posição e um desvio no de massa).

Todavia, a rede neural conseguiu apresentar uma evolução ao longo do acréscimo de condições de desbalanceamento no treinamento, o que permitiu reduzir seu erro e obter ainda reduções percentuais na amplitude de vibração do sistema em torno de 97 – 98 %. Portanto, a técnica proposta de aumentar a quantidade de dados se mostrou funcional, porém é importante destacar que a qualidade dos valores das condições de desbalanceamento é fundamental para um melhor ajuste da rede. Ou seja, alimentar a rede neural com condições de desbalanceamento próximas entre si não beneficia a previsão de dados mais esparsos. Logo, amostras de condições de desbalanceamento que conseguem representar o comportamento da máquina rotativa em uma maior variedade de situações permite uma melhor caracterização do problema, o que aumenta o leque de opções para a rede prever dados mais dispersos.

Por fim, as Configurações #5 e #6 abordaram a parte experimental, onde foram coletadas amostras na bancada do rotor e foi utilizado a estratégia da expansão de dados para montar uma rede de previsão das massas e posições de correção ao desbalanceamento da bancada. Novamente conforme o esperado, houve uma queda no desempenho da rede neural, principalmente para a condição de dois discos.

Tal qual abordado no capítulo anterior, esse comportamento se deve aos dados experimentais sofrerem a ação de influências externas, tal qual erros de coleta, uma máquina com outros problemas de vibração, entre outros. Além disso, uma coleta de dados que representem melhor a máquina rotativa se mostra fundamental novamente, onde valores mais dispersos e combinações variadas entre massa e posição resultam em novas amplitudes e fases.

Contudo, a rede realizou uma redução considerável na amplitude de vibração, chegando no pior caso de predição a uma redução de 80 %, reduzindo amplitudes de vibração de 67 μm para 13 μm . O fato de a bancada experimental ser pequena, poucas não-linearidades existem na relação entre a massa e a amplitude de vibração, o que pode contribuir para o melhor desempenho da rede neural.

Portanto, os objetivos desta dissertação foram considerados realizados, ao implementar e compreender o processo de balanceamento com o uso da ferramenta de rede neural, alcançando resultados esperados e adequados, além de permitir uma abertura para novas possibilidades de correção na metodologia e arquiteturas.

7.1. Propostas para trabalhos futuros

Durante a elaboração desta dissertação algumas ideias podem ser consideradas como sugestões para pesquisas futuras. Dentre elas, pode-se mencionar alguns tópicos:

- ✓ Modificar o método de transformação dos dados para o formato exponencial e avaliar como a rede se comporta;
- ✓ Alterar a forma de normalização dos parâmetros de entrada e saída e estudar variações que forneçam resultados melhores;
- ✓ Estudar a estratégia de escolha dos dados que servirão de conjunto de treinamento para a rede neural, como se comporta a relação entre a maior variabilidade contra a maior quantidade de dados;
- ✓ Compreender melhor como se comporta a técnica da expansão das amostras e se existe uma nova abordagem para aumentar a variabilidade das amostras de amplitude e massa no conjunto de treinamento.

REFERÊNCIAS BIBLIOGRÁFICAS

AK, A.; SARIOĞLU, A.; KARA, M.; SEÇGIN, A. Low Speed Balancing Procedure of Spiral Rotors Used for Wastewater Purification. *Em*: 2019, [s. l.], . **Anais [...]**. [S. l.: s. n.], 2019.

AMEEN, Y.; ALSALAET, J. Flexible rotor balancing without trial runs using experimentally tuned FE based rotor model-2021. [s. l.], v. 21, 2021. <https://doi.org/10.33971/bjes.21.1.4>

BISHOP, R. E. D.; GLADWELL, G. M. L. The Vibration and Balancing of an Unbalanced Flexible Rotor. **Journal of Mechanical Engineering Science**, [s. l.], v. 1, p. 66–77, 1959. https://doi.org/10.1243/JMES_JOUR_1959_001_010_02

CAMPBELL, W. The protection of steam-turbine disk wheels from axial vibration. *Em*: 1924, [s. l.], . **Anais [...]**. [S. l.: s. n.], 1924.

CARVALHO, V. N. **Balanceamento de Máquinas Rotativas com Eixos Flexíveis Utilizando Metamodelos Kriging**. 2022. Tese de Doutorado. - Universidade Federal de Uberlândia (UFU), Uberlândia 2022.

CARVALHO, V. N. **Balanceamento Robusto de Máquinas Rotativas com Eixos Flexíveis**. 2017. Dissertação de Mestrado. - Universidade Federal de Uberlândia (UFU), Uberlândia 2017.

CARVALHO, Vinícius N; DOURADO, A. D. P.; RENDE, B. R. F.; ALDEMIR AP CAVALINI, J.; VALDER STEFFEN, J. Experimental validation of a robust model-based balancing approach. **Journal of Vibration and Control**, [s. l.], v. 25, n. 2, p. 423–434, 2019. <https://doi.org/10.1177/1077546318783552>.

CARVALHO, V. N.; SICCHIERI, L. C.; REIS, M. F. S.; CAVALINI JR, A. Ap.; STEFFEN JR, V. Balancing of Rotating Machines using a Kriging Meta-Model. *Em*: 25TH INTERNATIONAL CONGRESS OF MECHANICAL ENGINEERING, 2019, Uberlândia, MG. **Anais [...]**. Uberlândia, MG: ABCM, 2019. <https://doi.org/10.26678/ABCM.COBEM2019.COB2019-0710>

CAVALLINI JR, A. A. **Deteção e Identificação de Trincas Transversais Incipientes em Eixos Horizontais Flexíveis de Máquinas Rotativas**. 2013. Tese de Doutorado. - Universidade Federal de Uberlândia (UFU), Uberlândia 2013.

CAVALLINI JR, A.; SANTOS, M.; STEFFEN JR, V.; MAHFOUD, J. Industrial Application of a Model Based Rotor Balancing Technique. [s. l.], 2012.

DE LAVAL, C. G. **Steam turbine**. 522066. Depósito: 1894. Concessão: 1894.

DENG, W.; TONG, M.; ZHENG, Q.; REN, X.; YANG, Y. Investigation on transient dynamic balancing of the power turbine rotor and its application. **Advances in Mechanical Engineering**, [s. l.], v. 13, 2021. <https://doi.org/10.1177/16878140211007325>

DOURADO, A. D. P. **Fuzzi Logic as a Tool for Uncertainty, Robustness and Reliability Analyses of Mechanical Systems**. 2018. Tese de Doutorado. - Universidade Federal de Uberlândia (UFU), Uberlândia 2018.

DUNKERLEY, S.; REYNOLDS, O. VIII. On the whirling and vibration of shafts. **Philosophical Transactions of the Royal Society of London. (A.)**, [s. l.], v. 185, p. 279–360, 1894. <https://doi.org/10.1098/rsta.1894.0008>.

EDUARDO, A. C.; SANTOS, F. L.; DUARTE, M. L. M. Balancing Methodology of a Rigid Rotor using Artificial Neural Network. *Em: 18TH INTERNATIONAL CONGRESS OF MECHANICAL ENGINEERING, 2005, Ouro Preto, MG. Anais [...].* Ouro Preto, MG: ABCM, 2005.

EL-SHAFEI, A.; EL-KABBANY, A.; YOUNAN, A. A. Rotor Balancing Without Trial Weights. **Journal of Engineering for Gas Turbines and Power-transactions of The Asme**, [s. l.], v. 126, p. 604–609, 2004. <https://doi.org/10.1115/1.1762903>

FOILES, W.; ALLAIRE, P.; GUNTER, E. Review: Rotor Balancing. **Shock and Vibration**, [s. l.], v. 5, p. 325–336, 1998. <https://doi.org/10.1155/1998/648518>

GÉRON, A. **Hands-on machine learning with Scikit-Learn and TensorFlow: concepts, tools, and techniques to build intelligent systems**. Sebastopol, CA: O'Reilly Media, 2019. 2019.

GOODMAN, T. P. A Least-Squares Method for Computing Balance Corrections. **Journal of Engineering for Industry**, [s. l.], v. 86, p. 273–277, 1964. <https://doi.org/10.1115/1.3670532>

HAROLD, D. N. Rotordynamic Modeling and Analysis Procedures: A Review. **JSME International Journal Series C**, [s. l.], v. 41, n. 1, p. 1–12, 1998. <https://doi.org/10.1299/jsmec.41.1>

IBRAHEEM, A. A.; GHAZALY, N. M.; JABER, G. T. A. et al. Review of Rotor Balancing Techniques. **American Journal of Industrial Engineering**, [s. l.], v. 6, p. 19–25, 2019.

JEFFCOTT, H. H. XXVII. The lateral vibration of loaded shafts in the neighbourhood of a whirling speed.—The effect of want of balance. **Philosophical Magazine Series 1**, [s. l.], v. 37, p. 304–314, 1919. <https://doi.org/10.1080/14786440308635889>

LALANNE, M.; FERRARIS, G. Rotordynamics prediction in engineering. *Em: 1990*, [s. l.], . **Anais [...]. [S. l.: s. n.]**, 1990.

LI, L.; CAO, S.; LI, J.; NIE, R.; HOU, L. Review of Rotor Balancing Methods. **Machines**, [s. l.], v. 9, n. 5, 2021. <https://doi.org/10.3390/machines9050089>

LI, L.; HOU, Y.; CAO, S. An Optimized Modal Balancing Approach for a Flexible Rotor Using a Vibration Response While the Rotor Is Speeding Up. **Shock and Vibration**, [s. l.], v. 2022, p. 1–13, 2022. <https://doi.org/10.1155/2022/5261279>

MACQUORN RANKINE, W. On the Centrifugal Force of Rotating Shafts. **The Engineer**, [s. l.], v. 1, 1869.

MORAIS, T. S. **Contribuição ao Estudo de Máquinas Rotativas Contendo Não-Linearidades**. 2010. Tese de Doutorado. - Universidade Federal de Uberlândia (UFU), Uberlândia 2010.

O'MALLEY, T.; BURSZTEIN, E.; LONG, J.; CHOLLET, F.; JIN, H.; INVERNIZZI, L.; OTHERS. **KerasTuner**. [S. l.: s. n.], 2019.

PARKINSON, A. G. Balancing of Rotating Machinery. **Proceedings of the Institution of Mechanical Engineers, Part C: Mechanical Engineering Science**, [s. l.], v. 205, p. 53–66, 1991. https://doi.org/10.1243/PIME_PROC_1991_205_091_02

PELLICER, L.; PAIT, F. BarySearch: Algoritmo de Tuning de Modelos de Machine Learning com o Metodo do Baricentro. *Em: ANAIS DO XIV BRAZILIAN E-SCIENCE WORKSHOP, 2020, Porto Alegre, RS, Brasil.* **Anais [...]**. Porto Alegre, RS, Brasil: SBC, 2020. p. 1–8. <https://doi.org/10.5753/bresci.2020.11175>

QUINZ, G.; KLANNER, M.; ELLERMANN, K. Balancing of Flexible Rotors Supported on Fluid Film Bearings by Means of Influence Coefficients Calculated by the Numerical Assembly Technique. **Energies**, [s. l.], v. 15, p. 2009, 2022. <https://doi.org/10.3390/en15062009>

RAO, J. S. **History of Rotating Machinery Dynamics**. Dordrecht: Springer Netherlands, 2011. 2011.v. 20. <https://doi.org/10.1007/978-94-007-1165-5>

SALDARRIAGA, M. V. **Atenuação de Vibrações em Máquinas Rotativas Flexíveis Usando Materiais Viscoelásticos nos Suportes**. 2007. Tese de Doutorado. - Universidade Federal de Uberlândia (UFU), Uberlândia 2007.

SALDARRIAGA, M. R. V. **Balanceamento de Rotores Flexíveis sem Usar Massas de Teste**. 2002. Dissertação de Mestrado. - Universidade Federal de Uberlândia (UFU), Uberlândia 2002.

SALDARRIAGA, M. V.; STEFFEN JR, V. Balancing of Flexible Rotors Without Trial Weights by using Optimization Techniques. *Em: 17TH INTERNATIONAL CONGRESS OF MECHANICAL ENGINEERING, 2003, São Paulo, SP.* **Anais [...]**. São Paulo, SP: ABCM, 2003.

SANTOS, F. L.; DUARTE, M. L. M.; FARIA, M. T. C. de; EDUARDO, A. C. Balancing of a rigid rotor using artificial neural network to predict the correction masses. **Acta Scientiarum. Technology**, [s. l.], v. 31, n. 2, p. 151–157, 2009. <https://doi.org/10.4025/actascitechnol.v31i2.3912>

SILVA ARINAN DOURADO GUERRA AND CAVALINI, A. A. and S. V. Model Based Robust Balancing Approach for Rotating Machines. *Em: MODEL VALIDATION AND UNCERTAINTY QUANTIFICATION, VOLUME 3*, 2016, Cham. **Anais** [...]. Cham: Springer International Publishing, 2016. p. 243–251. https://doi.org/10.1007/978-3-319-29754-5_24

SUN, X.; CHEN, Y.; CUI, J. A Balancing Method for Multi-Disc Flexible Rotors without Trial Weights. **Energies**, [s. l.], v. 15, p. 5088, 2022. <https://doi.org/10.3390/en15145088>

WALKER, R. B.; VAYANAT, R.; PERINPANAYAGAM, S.; JENNIONS, I. K. Unbalance localization through machine nonlinearities using an artificial neural network approach. **Mechanism and Machine Theory**, [s. l.], v. 75, p. 54–66, 2014. <https://doi.org/10.1016/j.mechmachtheory.2014.01.006>

WANG, T.; DING, Q. **Modal balancing of the nonlinear rotor-bearing system based on nonlinear normal modes**. [S. l.: s. n.], 2022. <https://doi.org/10.21203/rs.3.rs-2012693/v1>

XU, B.; QU, L.; SUN, R. THE OPTIMIZATION TECHNIQUE-BASED BALANCING OF FLEXIBLE ROTORS WITHOUT TEST RUNS. **Journal of Sound and Vibration**, [s. l.], v. 238, n. 5, p. 877–892, 2000. <https://doi.org/10.1006/jsvi.2000.3107>

ZHANG, Y.; LI, M.; HU, Y. Model-based Balancing Method of Rotors using Differential Evolution Algorithm. **IOP Conference Series: Materials Science and Engineering**, [s. l.], v. 751, p. 12046, 2020. <https://doi.org/10.1088/1757-899X/751/1/012046>

ZHANG, Y.; LI, M.; YAO, H.; GOU, Y.; WANG, X. A modal-based balancing method for a high-speed rotor without trial weights. **Mechanical Sciences**, [s. l.], v. 12, p. 85–96, 2021. <https://doi.org/10.5194/ms-12-85-2021>

ZHAO, S.; REN, X.; LIU, Y.; LU, K.; FU, C.; YANG, Y. A Dynamic-Balancing Testing System Designed for Flexible Rotor. **Shock and Vibration**, [s. l.], v. 2021, p. 1–17, 2021. <https://doi.org/10.1155/2021/9346947>

ZHONG, S.; HOU, L. Numerical and experimental studies on unsupervised deep Lagrangian learning based rotor balancing method. **Science China Technological Sciences**, [s. l.], v. 66, 2023. <https://doi.org/10.1007/s11431-022-2102-3>

ZOU, D.; ZHAO, H.; LIU, G.; TA, N.; RAO, Z. Application of augmented Kalman filter to identify unbalance load of rotor-bearing system: Theory and experiment. **Journal of Sound and Vibration**, [s. l.], v. 463, p. 114972, 2019. <https://doi.org/10.1016/j.jsv.2019.114972>