



EMC

UNIVERSIDADE FEDERAL DE GOIÁS
ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE COMPUTAÇÃO



UFG

PROGRAMA DE PÓS GRADUAÇÃO EM ENGENHARIA MECÂNICA - PPGMEC

Pedro Augusto Dias Rodrigues

UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL PARA ANÁLISE MODAL DE UMA
VIGA ENGASTADA SOB ESCOAMENTO EM TÚNEL DE VENTO

Goiânia
2022



UNIVERSIDADE FEDERAL DE GOIÁS
ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE COMPUTAÇÃO

TERMO DE CIÊNCIA E DE AUTORIZAÇÃO (TECA) PARA DISPONIBILIZAR VERSÕES ELETRÔNICAS DE TESES

E DISSERTAÇÕES NA BIBLIOTECA DIGITAL DA UFG

Na qualidade de titular dos direitos de autor, autorizo a Universidade Federal de Goiás (UFG) a disponibilizar, gratuitamente, por meio da Biblioteca Digital de Teses e Dissertações (BDTD/UFG), regulamentada pela Resolução CEPEC nº 832/2007, sem ressarcimento dos direitos autorais, de acordo com a [Lei 9.610/98](#), o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou download, a título de divulgação da produção científica brasileira, a partir desta data.

O conteúdo das Teses e Dissertações disponibilizado na BDTD/UFG é de responsabilidade exclusiva do autor. Ao encaminhar o produto final, o autor(a) e o(a) orientador(a) firmam o compromisso de que o trabalho não contém nenhuma violação de quaisquer direitos autorais ou outro direito de terceiros.

1. Identificação do material bibliográfico

Dissertação Tese Outro*: _____

*No caso de mestrado/doutorado profissional, indique o formato do Trabalho de Conclusão de Curso, permitido no documento de área, correspondente ao programa de pós-graduação, orientado pela legislação vigente da CAPES.

Exemplos: Estudo de caso ou Revisão sistemática ou outros formatos.

2. Nome completo do autor

Pedro Augusto Dias Rodrigues

3. Título do trabalho

UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL PARA ANÁLISE MODAL DE UMA VIGA ENGASTADA SOB ESCOAMENTO EM TÚNEL DE VENTO

4. Informações de acesso ao documento (este campo deve ser preenchido pelo orientador)

Concorda com a liberação total do documento SIM NÃO¹

[1] Neste caso o documento será embargado por até um ano a partir da data de defesa. Após esse período, a possível disponibilização ocorrerá apenas mediante:

a) consulta ao(à) autor(a) e ao(à) orientador(a);

b) novo Termo de Ciência e de Autorização (TECA) assinado e inserido no arquivo da tese ou dissertação.

O documento não será disponibilizado durante o período de embargo.

Casos de embargo:

- Solicitação de registro de patente;
- Submissão de artigo em revista científica;
- Publicação como capítulo de livro;
- Publicação da dissertação/tese em livro.

Obs. Este termo deverá ser assinado no SEI pelo orientador e pelo autor.



Documento assinado eletronicamente por **Marlipe Garcia Fagundes Neto, Professor do Magistério Superior**, em 22/03/2023, às 08:58, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Pedro Augusto Dias Rodrigues, Usuário Externo**, em 22/03/2023, às 09:03, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **3614339** e o código CRC **6B7A6014**.

Pedro Augusto Dias Rodrigues

UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL PARA ANÁLISE MODAL DE UMA
VIGA ENGASTADA SOB ESCOAMENTO EM TÚNEL DE VENTO

Dissertação apresentada ao Programa de Pós-Graduação *Stricto Sensu* em Engenharia Mecânica da Universidade Federal de Goiás, como requisito final para obtenção do Título de Mestre em Engenharia Mecânica. Área de Concentração: Ciências Mecânicas. Linha de Pesquisa: Dinâmica dos Fluidos e dos Sólidos.

Orientador: Prof. Dr. Marlipe Garcia Fagundes Neto

Coorientador: Prof. Dr. Sigeo Kitatani Junior.

Universidade Federal de Goiás
Escola de Engenharia Elétrica, Mecânica e de Computação
Programa de Pós Graduação em Engenharia Mecânica - PPGMEC

Goiânia
2023

Ficha de identificação da obra elaborada pelo autor, através do Programa de Geração Automática do Sistema de Bibliotecas da UFG.

Rodrigues, Pedro Augusto Dias
UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL PARA ANÁLISE
MODAL DE UMA VIGA ENGASTADA SOB ESCOAMENTO EM TÚNEL
DE VENTO [manuscrito] / Pedro Augusto Dias Rodrigues. - 2023.
CII, 102 f.: il.

Orientador: Prof. Dr. Marlipe Garcia Fagundes Neto; co-orientador
Dr. Sigeo Kitatani Junior.

Tese (Doutorado) - Universidade Federal de Goiás, Escola de
Engenharia Elétrica, Mecânica e de Computação (EMC), Programa de
Pós-graduação em Engenharia Mecânica, Goiânia, 2023.

Bibliografia. Anexos. Apêndice.

Inclui siglas, abreviaturas, símbolos, gráfico, tabelas, algoritmos,
lista de figuras, lista de tabelas.

1. Rede neural. 2. Túnel de vento. 3. Viga de Euler Bernoulli. 4.
Análise modal.. I. Fagundes Neto, Marlipe Garcia, orient. II. Título.

CDU 621



UNIVERSIDADE FEDERAL DE GOIÁS

ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE COMPUTAÇÃO

ATA DE DEFESA DE DISSERTAÇÃO

Ata nº **03** da sessão de Defesa de Dissertação de **Pedro Augusto Dias Rodrigues**, que confere o título de Mestre em **Engenharia Mecânica**, na área de concentração em **Ciências Mecânicas**.

Ao **vigésimo quarto dia do mês de fevereiro do ano de dois mil e vinte e três**, a partir das **14h00min.**, no **Laboratório de Mecânica Aplicada - Controle de Ruído e Acústica do prédio B5 do curso de Engenharia Mecânica da Escola de Engenharia Elétrica, Mecânica e de Computação**, realizou-se a sessão pública de Defesa de Dissertação intitulada **“UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL PARA ANÁLISE MODAL DE UMA VIGA ENGASTADA SOB ESCOAMENTO EM TÚNEL DE VENTO”**. Os trabalhos foram instalados pelo Orientador, Professor Doutor **Marlipe Garcia Fagundes Neto (UFG)** com a participação dos demais membros da Banca Examinadora: Professor Doutor **José Luiz Oliveira Pena (IFG)**, membro titular externo; Professor Doutor **Gino Bertolucci Colherinhas (UFG)**, membro titular interno e Professor Doutor **Sigeo Kitatani Júnior (UFG)**, Coorientador, membro titular interno. Durante a arguição os membros da banca **não** fizeram sugestão de alteração do título do trabalho. A Banca Examinadora reuniu-se em sessão secreta a fim de concluir o julgamento da Dissertação, tendo sido o candidato **aprovado** pelos seus membros. Proclamados os resultados pelo Professor Doutor **Marlipe Garcia Fagundes Neto**, Presidente da Banca Examinadora, foram encerrados os trabalhos e, para constar, lavrou-se a presente ata que é assinada pelos Membros da Banca Examinadora, **a vigésimo quarto dia do mês de fevereiro do ano de dois mil e vinte e três**.

TÍTULO SUGERIDO PELA BANCA



Documento assinado eletronicamente por **Gino Bertolucci Colherinhas, Professor do Magistério Superior**, em 24/02/2023, às 18:12, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Marlipe Garcia Fagundes Neto, Professor do Magistério Superior**, em 24/02/2023, às 18:13, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Sigeo Kitatani Júnior, Professor do Magistério Superior**, em 24/02/2023, às 18:14, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **José Luiz Oliveira Pena, Usuário Externo**, em 24/02/2023, às 19:42, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **3527810** e o código CRC **47D0D957**.

Referência: Processo nº 23070.002145/2023-11

SEI nº 3527810

UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL PARA ANÁLISE MODAL DE UMA VIGA ENGASTADA SOB ESCOAMENTO EM TÚNEL DE VENTO

Dissertação apresentada no Programa de Pós-Graduação *Stricto sensu* em Engenharia Mecânica da
Universidade Federal de Goiás, como requisito final para obtenção do Título de Mestre em
Engenharia Mecânica.

Área de Concentração: Ciências Mecânicas.

Orientador: Marlipe Garcia Fagundes Neto.

Coorientador: Sigeo Kitatani Junior.

Dissertação avaliada em 24 de fevereiro de 2023, pela seguinte Banca Examinadora:

Prof. Dr. Marlipe Garcia Fagundes Neto

Orientador - UFG

Prof. Dr. Sigeo Kitatani Junior

Coorientador - UFG

Prof. Dr. Gino Bertolucci Colherinhas

Avaliador Interno - UFG

Prof. Dr. José Luiz Oliveira Pena

Avaliador Externo - IFG

Este trabalho é dedicado às crianças adultas que, quando pequenas, sonharam em se tornar cientistas.

AGRADECIMENTOS

Agradeço aos professores e amigos Marlipe Garcia Fagundes Neto e Sigeo Kitatani Júnior pelo incentivo e pela motivação e orientação nesta caminhada acadêmica. Gostaria também de agradecer a toda minha família por todo o apoio e todo o incentivo nessa caminhada engrandecedora.

Gostaria de agradecer também a FURNAS Centrais Elétricas e ao Programa de Pesquisa e Desenvolvimento Tecnológico (P&D) da ANEEL pelo apoio financeiro e motivação no desenvolvimento do trabalho proposto.

Algumas pessoas estiveram comigo nessa jornada, gostaria de agradecer muito aos meus amigos Carlos Augusto Paes Lemes, Yuri Luiz de Almeida, Felipe Silveira, Joaquim Augusto Rodrigues e Luiz Carlos Michewski Junior. Essas pessoas me ajudaram muito ao longo dessa caminhada, apoiando-me e me incentivando sempre a crescer e me desenvolver.

“Conhecimento não é aquilo que você sabe, mas o que você faz com aquilo que você sabe”

Aldous Huxley

RESUMO

Os aerogeradores sofrem danos severos devido à carga de vento excessivas ou condições de manutenção inadequadas, e muitas vezes ocorrem falhas catastróficas causando prejuízos enormes. Uma estrutura, como o aerogerador, pode ser monitorada e avaliada por meio de suas características modais, onde as frequências naturais, por exemplo, são características que independem das condições de operação. Elas sofrem alterações somente em caso de danos, isto é, quando a rigidez e a massa sofrem alterações. No entanto, para aplicação da análise modal são necessários vários sensores distribuídos na estrutura, o que envolve custos elevados de instrumentação. Diante disso, é proposto a utilização de técnicas de análise modal integradas a sensores virtuais, que diferente dos sensores reais/físicos são obtidos por meio de modelos. Neste trabalho, os sensores virtuais são determinados por utilização de uma inteligência artificial do tipo rede neural, que em conjunto com a análise modal permite obter as características modais: frequências naturais, formas modais e amortecimento. Para tanto, propõe-se estudar uma viga de Euler Bernoulli engastada, modelo de aproximação de um aerogerador, onde as cargas de escoamento são geradas por meio de um túnel de vento com controlador de velocidade. As velocidades de escoamento analisadas sobre a viga foram de 10 a 20 m/s. O sensor virtual para análise modal operacional foi modelado utilizando rede neural dinâmica onde foram investigadas configurações de número de atraso e número de neurônios na camada oculta. Em sequência, são comparadas as características modais da viga de Euler Bernoulli utilizando análise modal experimental, situação em que a entrada é conhecida e mensurada, e análise modal operacional, configuração onde a entrada é desconhecida e não mensurada. Para análise comparativa, as frequências naturais obtidas nas diferentes configurações e técnicas modais apresentaram bons resultados ao comparar com os valores da viga de Euler Bernoulli. Para as formas modas utilizou-se o critério *Modal assurance criterion* (MAC), onde ao analisar cada resultado independente o MAC retorna excelentes resultados modais, porém ao realizar uma análise comparativa das diferentes configurações e técnicas o MAC apresentou baixa correlação. Por fim, a razão de amortecimento apresentou um aumento para maiores velocidades de escoamento, mas maiores investigações devem ser realizadas em trabalhos futuros utilizando outras técnicas de análise modal operacional.

Palavras-chaves: Rede neural, túnel de vento, viga de Euler Bernoulli, análise modal.

ABSTRACT

Wind turbines suffer severe damage due to excessive wind loads or inadequate maintenance conditions, and catastrophic failures often occur causing huge losses. A structure, such as a wind turbine, can be monitored and evaluated through its modal characteristics, where natural frequencies, for example, are characteristics that are independent of operating conditions. They change only in case of damage, i.e. when stiffness and mass change. However, for the application of modal analysis, several sensors distributed in the structure are required, which involves high instrumentation costs. In view of this, it is proposed the use of modal analysis techniques integrated with virtual sensors, which, unlike real/physical sensors, are obtained through models. In this work, the virtual sensors are determined by using an artificial intelligence of the neural network type, which together with the modal analysis allows to obtain the modal characteristics: natural frequencies, modal shapes and damping. For this purpose, it is proposed to study a fixed Euler Bernoulli beam, an approximation model of a wind turbine, where the flow loads are generated through a wind tunnel with a speed controller. The flow velocities analyzed over the beam ranged from 10 to 20 m/s. The virtual sensor for operational modal analysis was modeled using a dynamic neural network where configurations of delay number and number of neurons in the hidden layer were investigated. In sequence, the modal characteristics of the Euler Bernoulli beam are compared using experimental modal analysis, situation in which the input is known and measured, and operational modal analysis, configuration where the input is unknown and not measured. For comparative analysis, the natural frequencies obtained in the different configurations and modal techniques showed good results when compared with the values of the Euler Bernoulli beam. For the modes, the Modal Assurance Criterion (MAC) was used, where when analyzing each independent result, the MAC returns excellent modal results, but when performing a comparative analysis of the different configurations and techniques, the MAC showed low correlation. Finally, the damping ratio showed an increase for higher flow velocities, but further investigations should be carried out in future works using other operational modal analysis techniques.

Keywords: Neural network, wind tunnel, Euler Bernoulli beam, modal analysis.

LISTA DE FIGURAS

Figura 1.1: Histórico da Evolução da Energia Eólica no Mundo.....	1
Figura 1.2: Distribuição da Geração de Energia Eólica no Mundo em 2022.....	2
Figura 1.3: Custo médio da Energia elétrica em centavos de Dólar por kW/h no mundo.	2
Figura 1.4: Exemplo de Aerogerador de Eixo Horizontal a esquerda e Aerogerador de Eixo Vertical a direita.....	3
Figura 1.5: Manutenção realizada nas pás do aerogerador da fabricante VESTAS.....	5
Figura 1.6: Relação entre os tempos de parada e as causas de parada de aerogeradores.	5
Figura 1.7: Mapa de correlação entre artigos.....	7
Figura 1.8: Mapa de correlação entre os artigos que da pesquisa por quantidade de citações.	7
Figura 2.1: Componentes de um aerogerador em esquema simplificado.	12
Figura 2.2: Destroços da queda de Aerogerador Eólica por vibração –França.....	13
Figura 2.3: Falha catastrófica de um aerogerador nos EUA	14
Figura 2.4: Falha catastrófica de uma Aerogerador na Suécia.....	14
Figura 2.5: Diagrama de blocos exemplificando o funcionamento do método de fusão de dados.....	16
Figura 2.6: Interseção das tecnologias.	16
Figura 2.7: Esquema de funcionamento de sensores virtuais.....	17
Figura 2.8: Processo de fermentação de biomassa e subprodutos. Em azul, são mostrados os sensores virtuais, e em vermelho os sensores reais.....	18
Figura 2.9: Fluxograma do processo de destilação de gás GLP. Em azul, são mostrados os sensores virtuais, e em vermelho os sensores reais.....	19
Figura 2.10: Fluxograma de Aplicação do Sensor Virtual a uma Destilaria. Em azul, são mostrados os sensores virtuais, e em vermelho os sensores reais.	20
Figura 2.11: Aplicação de Sensores Virtuais no Monitoramento de Pontes.....	20
Figura 2.12: Esquema com os principais elementos do <i>strain gauge</i>	21
Figura 2.13: Exemplo de um acelerômetro piezoelétrico.	22
Figura 2.14: Exemplo de um transdutor de deformação.	23
Figura 2.15: Exemplo de um sensor de flexão.....	23
Figura 2.16: Aplicação de <i>strain gauges</i> e outros sensores para monitoramento de aerogeradores.....	24
Figura 2.17: Ilustração de conjunto de torres eólicas <i>offshore</i> ancoradas.....	25
Figura 2.18: Aplicação de <i>strain gauges</i> (Q1 e Q2) e acelerômetros (S1, S2, S3, S4, S5 e S6) para Aerogeradores.	25
Figura 2.19: Curva de Vida a Fadiga obtida para os resultados.....	26
Figura 2.20: Posição dos sensores de medição instalados e a curva de potência da Aerogerador.....	27

Figura 2.21: <i>Strain gauge</i> montado no interior da torre do aerogerador para avaliação das deformações.....	27
Figura 2.22: ESR strain Sensor aplicado a Aerogeradores.	28
Figura 2.23: Posicionamento de <i>strain gauges</i> em aerogeradores (Serie ESR).....	28
Figura 2.24: <i>Strain gauge</i> posicionado no interior da torre de um aerogerador em construção.....	29
Figura 3.1: Gráfico de Evolução das Tecnologias Computacionais Inteligentes.....	30
Figura 3.2: Definição e caracterização do conceito de Inteligência Artificial, <i>Machine Learning</i> e <i>Deep Learning</i>	31
Figura 3.3: Modelo de rede neural para o tipo Perceptrons de Multicamadas.....	33
Figura 3.4: Esquema de Ligação esquemático que representa uma rede neural simples 5 entradas e 4 saídas.	34
Figura 3.5: Quadro esquemático mostrando o esquema básico das Redes Neurais mais conhecidas.	35
Figura 3.6: Esquema ilustrativo da arquitetura de uma rede neural.....	36
Figura 3.7: Princípio de funcionamento do neurônio da rede neural.	37
Figura 3.8: Modelo base de uma rede neural dinâmica.....	38
Figura 3.9: Topologia de PMC do exemplo.....	39
Figura 4.1: Exemplo de modelo do sistema MIMO.....	43
Figura 4.2: Ilustração do gráfico MAC.	47
Figura 4.3: Modelo de viga genérico com carregamento vertical.....	48
Figura 5.1: Túnel de vento mostrando a entrada de ar (1), região de ensaios (2), difusor (3) e o motor de sucção (4).	52
Figura 5.2: Posicionamento dos acelerômetros.....	53
Figura 5.3: Viga na posição de ensaio.....	53
Figura 5.4: Frequências naturais e modos de vibrar do modelo analítico.....	54
Figura 5.5: Acelerômetros B&K, modelo 4516, utilizados nas medições.	55
Figura 5.6: Célula de carga PCB, modelo 201B02, utilizados nas medições	55
Figura 5.7: Placa de aquisição, NI 9234 utilizada.....	56
Figura 5.8: Martelo de impacto utilizado.....	57
Figura 5.9: Viga e Martelo de Impacto.	58
Figura 5.10: Tubo de Pitot dentro do túnel de vento.....	59
Figura 5.11: Perfil de velocidades no túnel de vento.	59
Figura 5.12: Viga instrumentada dentro do túnel de vento.....	61
Figura 5.13: Fluxograma do sistema implementado na análise modal estrutural do modelo de viga.....	61
Figura 5.14: Arquitetura da Rede Neural adotada.....	62
Figura 6.1: Diagrama de estabilização obtido para os ensaios com o martelo.....	65
Figura 6.2: Modos de vibrar da viga pela análise modal experimental.....	66
Figura 6.3: Valores de correlação para os modos de vibrar da AME.	66
Figura 6.4: Resultados dos experimentos para a viga instrumentada no túnel de vento.	67
Figura 6.5: Coeficiente de correlação da rede neural dinâmica	68
Figura 6.6: Coeficiente de correlação da rede neural dinâmica	70

Figura 6.7: Coeficiente de correlação da rede neural dinâmica	71
Figura 6.8: Modos de vibrar da viga pela análise modal operacional.....	71
Figura 6.9: Comparativo entre os valores de correlação das frequências de vibração (diagonal principal).....	72
Figura 6.10: Comparativo entre as formas modais AME x Euler-Bernoulli	74
Figura 6.11: Comparativo entre as formas modais obtidas pela AME e AMO.	75

LISTA DE TABELAS

Tabela 1.1: Vantagens e desvantagens dos aerogeradores HAWT.....	3
Tabela 1.2: Vantagens e desvantagens dos aerogeradores VAWT.....	4
Tabela 3.1: Tabela contendo a quantidade de entradas para a Variável TDNN	39
Tabela 4.1: Condições de contorno para viga.	49
Tabela 5.1: Dados técnicos dos acelerômetros utilizados.	54
Tabela 5.2: Dados técnicos da placa de aquisição.	56
Tabela 5.3: Metodologia da AME.....	57
Tabela 5.4: Método de avaliação do perfil de velocidades do túnel de vento.....	59
Tabela 5.5: Metodologia da AMO	60
Tabela 5.6: Topologia da Rede Neural adotada	63
Tabela 6.1: Amortecimentos em função da frequência natural obtida pela AME.	67
Tabela 6.2: Amortecimentos em função da frequência natural obtida.....	73
Tabela 6.3: Comparativo entre as razões de amortecimento AME x AMO	76
Tabela 9.1: Resumo dos dados obtidos dos sensores no túnel de vento	84
Tabela 9.2: Avaliação do número ideal de neurônios da rede neural dinâmica.....	84

LISTA DE SÍMBOLOS

σ	Tensão.
E	Módulo de Elasticidade.
v	Velocidade do vento.
C_d	Coefficiente de Arraste do Vento.
F	Força de Arraste do Vento.
A	Área da viga.
I	Momento de Inercia.
ε	Deformação.
y	Braço de alavanca do momento fletor.
y_2	Distância até a linha neutra.
δ	Termo constante que se relaciona à média do processo estocástico.
ε_t	Erro aleatório em t .
ϕ_i	Coefficiente regressivo na posição i .
Y_{t-i}	Resultados obtidos nos instantes $(t - i)$.
$A(q)$	Polinômio arbitrário para estimar valores estatisticamente.
$y(k)$	Saída do sistema.
$B(q)$	Polinômio arbitrário para estimar valores estatisticamente.
$u(k)$	Entrada do sistema.
$v(k)$	Ruído ou erro do sistema.
$y(k)$	Saída do sistema.
r_d	Atraso de tempo.
F^l	Função não linear.
$y(k - i)$	Variável de interesse.
$u(k - r_d)$	Variável determinada externamente.
$A(z)$	Polinômio arbitrário para estimar valores estatisticamente.
$y(k)$	Saída do sistema.
$B(z)$	Polinômio arbitrário para estimar valores estatisticamente.
$u(k)$	Entrada do sistema.
$C(z)$	Polinômio interpolador do ruído.
$v(k)$	Ruído ou erro do sistema.
Net_k	Função Sinapse de uma rede neural.
S_j	Saída da Função de Ativação de uma rede neural.
e_j	Erro calculado para a Função Sinapse.
$\Delta\omega_{jk}$	Pesos para a função Taxa de Aprendizado de uma rede neural.
λ	Taxa de aprendizado de uma rede neural.
N_k	K - ésimo neurônio da rede neural.
Eq	Erro quadrático médio.
$\varphi(\cdot)$	Função de Ativação da rede neural.

SUMÁRIO

1.	INTRODUÇÃO	1
1.1.	Motivação	6
1.2.	Justificativa	9
1.3.	Objetivo do Trabalho	10
1.3.1.	Objetivo Geral	10
1.3.2.	Objetivos Específicos.....	10
1.4.	Estrutura do trabalho	11
2.	REVISÃO BIBLIOGRÁFICA	12
2.1.	Falhas em Aero geradores	12
2.2.	Técnicas de Monitoramento	14
2.2.1.	Método da fusão de dados multisensores	15
2.2.2.	Método do sensor virtual.....	16
2.3.	Sensores para monitoramento	21
2.3.1.	Strain gauge.....	21
2.3.2.	Acelerômetros	22
2.3.3.	Transdutor de deformação.....	22
2.3.4.	Sensor de flexão	23
2.4.	Monitoramento em aerogeradores	24
3.	REDE NEURAL	30
3.1.	Machine Learning (Aprendizado de Máquina)	31
3.2.	Deep Learning (Aprendizagem Profunda)	32
3.3.	Método de Rede Neural Artificial	32
3.4.	Estrutura básica de uma rede neural	33
3.5.	Algoritmo de uma rede neural	35
3.6.	Redes Neurais Dinâmicas	38
4.	ANÁLISE MODAL.....	40
4.1.	Sistema de 1 grau de liberdade	40
4.1.1.	Método de Identificação dos Picos	40
4.1.2.	Método do Círculo.....	41

4.3.	Análise Modal Experimental	42
4.3.1.	Método Exponencial Complexo de Mínimos Quadrados	43
4.3.2.	Método de Seleção de Pico	44
4.4.	Análise Modal Operacional	44
4.5.	Critério de Garantia Modal: MAC (<i>Modal Assurance Criterion</i>)	47
4.6.	Viga de Euler Bernoulli	47
5.	MATERIAIS E METODOLOGIA	52
5.1.	Materiais	52
5.1.1.	Túnel de vento.....	52
5.1.2.	Viga engastada	52
5.1.3.	Sistema de Aquisição.....	54
5.2.	Metodologia	57
5.2.1.	Análise Modal Experimental (AME).....	57
5.2.2.	Determinação das velocidades de escoamento do túnel de vento	58
5.2.3.	Análise Modal Operacional (AMO).....	60
5.2.4.	Determinação do sensor virtual por Rede Neural Dinâmica	62
	a) Quantidade de entradas.....	62
	b) Quantidade de Saídas da rede neural	62
	c) Estrutura Final da Rede Neural.....	62
6.	RESULTADOS	65
6.1.	Resultados da Análise Modal Experimental (AME)	65
6.2.	Resultados da Análise Modal Operacional (AMO)	67
6.3.	Comparativo entre os modos de vibrar	74
6.3.1.	AME x Euler-Bernoulli.....	74
6.3.2.	AME x AMO	75
7.	CONSIDERAÇÕES FINAIS	77
7.1.	Conclusões	77
7.2.	Sugestões de trabalho futuros	78
8.	REFERÊNCIAS	79
9.	APÊNDICE	84
9.1.	Resumo dos Dados Obtidos e Desvios Padrão – Túnel de vento	84
9.2.	Tabela de dados de Neurônios x R2 (correlação)	84

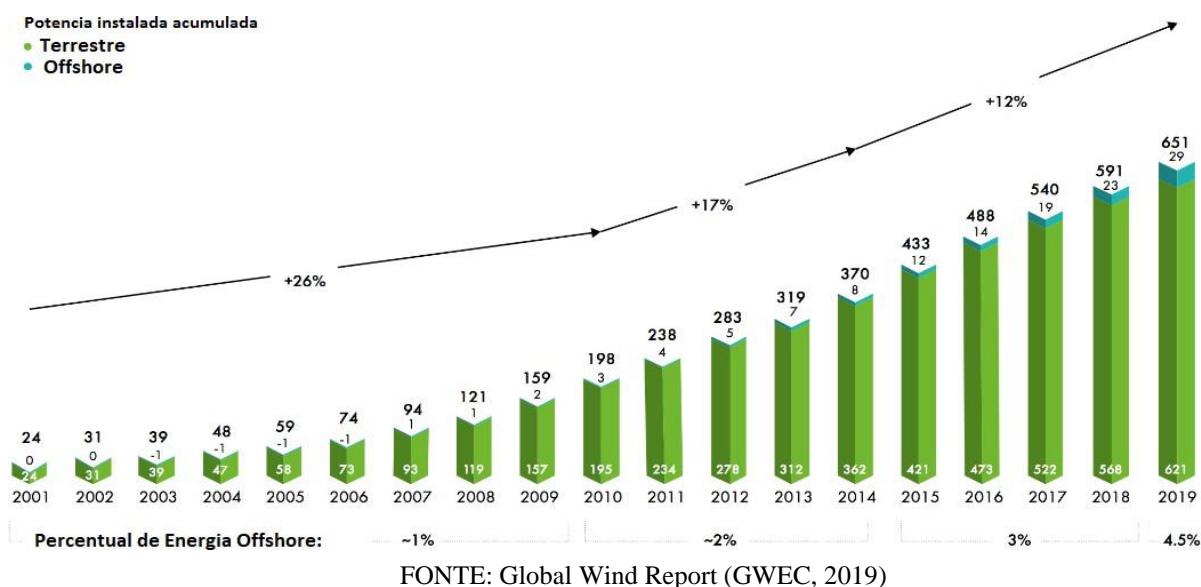
9.3. Códigos da Rede Neural	85
-----------------------------------	----

1. INTRODUÇÃO

A globalização tecnológica tem lançado o grande desafio de superação dos custos cada vez mais elevados de energia como insumo, fazendo com que se torne imperativo o desenvolvimento de tecnologias baseadas em fontes renováveis, inclinando o cenário ao surgimento de tecnologias eólicas, devido a sua elevada eficiência e baixo custo de geração. Os aerogeradores têm se tornado bastante populares no mundo, principalmente em regiões que não possuem muitas opções além do vento como potência motriz.


Os países líderes na utilização de energia eólica são China e Estados Unidos. O Brasil possui elevado potencial eólico nas regiões Nordeste, Sul e Sudeste do país, sendo pouco explorado devido à falta de incentivos a iniciativa privada, porém a participação dessa fonte de energia no setor elétrico tem aumentado com a criação do Programa de Incentivo às Fontes Alternativas de Energia Elétrica (PROINFA, 2002). Atualmente, a energia eólica vem ganhando destaque dentre as demais fontes de energia no mundo, e crescendo ao longo dos anos, conforme mostrado na Figura 1.1.

Figura 1.1: Histórico da Evolução da Energia Eólica no Mundo.



A Figura 1.1 mostra a evolução da potência instalada acumulada no mundo, comparando-se os aerogeradores de eixo horizontal terrestres com as *offshore*, observa-se que o desenvolvimento dessa fonte de energia está em constante crescimento. Atualmente, segundo a GWEC (*Global Wind Report*, 2022) tem-se que no ano de 2022 a distribuição da geração de energia eólica no mundo segue a distribuição mostrada na Figura 1.2:


Figura 1.2: Distribuição da Geração de Energia Eólica no Mundo em 2022.



FONTE: Global Wind Report (GWEC, 2022).

Pela Figura 1.2 observa-se que o país que mais investe em energia eólica é a China (gerando 55,91% de toda a energia eólica do mundo atualmente), sendo que o Brasil representa 2,47%. A energia eólica possui diversas vantagens, como por exemplo a não geração de dióxido de carbono, redução da dependência de combustíveis fósseis, geração de empregos e diversificação da matriz energética. Os impactos negativos dos aerogeradores são a geração de ruído (poluição sonora) proveniente do funcionamento dos aerogeradores (que pode ser perturbador para a população local) e as perturbações causadas na fauna da região onde são instaladas, devido ao choque de aves e morcegos com os aerogeradores, e perda de habitat pelos animais (MELO, 2013). Outra vantagem da energia eólica é o baixo custo em comparação a outros tipos de energia, como por exemplo a derivada de hidrelétricas como no Brasil. Segundo a CCE (Câmara de Comercialização de Energia Elétrica), o custo médio em 2021 da energia cuja fonte é hidrelétrica foi em torno de R\$ 186,88/MWh, enquanto a energia eólica possui um custo médio de R\$ 50,00/MWh. A Figura 1.3 ilustra o custo dos tipos de energia na última década, mostrando que há uma significativa redução dos custos em função de desenvolvimento de novas tecnologias e redução de custos de manutenção:


Figura 1.3: Custo médio da Energia elétrica em centavos de Dólar por kW/h no mundo.



FONTE: WNISR, Lazard. DW – Made for Minds, 2021. Conteúdos científicos e tecnológicos. Disponível em <https://www.dw.com/pt-br/>. Acesso em 07 de dezembro de 2022.

Com relação aos tipos existentes eles podem ser divididos em duas categorias diferentes: Aerogeradores de Eixo Horizontal (HAWT) e Aerogeradores de Eixo Vertical (VAWT). A Figura 1.4 ilustra os dois modelos:

Figura 1.4: Exemplo de Aerogerador de Eixo Horizontal a esquerda e Aerogerador de Eixo Vertical a direita.



FONTE: Adaptado de Melo, 2013.

Existem diferenças significativas entre os dois modelos, tanto em questão de volume de geração de energia, quanto em termos de espaço e eficiência. Os aerogeradores do tipo HAWT são utilizadas para geração de energia em larga escala, possuindo elevados tamanhos (podendo chegar a 200 m de altura) e eficiência elevada em relação aos aerogeradores do tipo VAWT, que são mais compactos (chegando a cerca de 3 a 17 m de altura no máximo). Um comparativo entre os dois modelos é apresentado nas Tabela 1.1 e Tabela 1.2:

Tabela 1.1: Vantagens e desvantagens dos aerogeradores HAWT.

AEROGERADORES HAWT	
VANTAGENS	DESVANTAGENS
Produção de energia em larga escala.	Investimento mais elevado
Elevada eficiência energética (40% a 56%).	Elevado custo de manutenção.
Energia de baixo custo.	Impactos ambientais sobre a fauna na região.
Produção de Energia renovável.	Poluição sonora e Visual.

Fonte: Autoria Própria.

Tabela 1.2: Vantagens e desvantagens dos aerogeradores VAWT.

AEROGERADORES VAWT	
VANTAGENS	DESVANTAGENS
Podem se adaptar a mudança na direção do vento muito bem.	Baixa Eficiência energética (10% a 15%).
Equipamentos compactos (3 m a 17 m de altura no máximo).	Produção de energia em pequena escala.
Fácil manutenção, pode ser instalado em locais de fácil acesso.	A altura mais baixa de instalação destes geradores torna esses dispositivos dependentes de ventos de nível baixo.
Podem ser utilizados em regiões de prédios e construções.	Quando submetidos a grandes cargas de vento esses aerogeradores podem parar de funcionar devido ao esforço excessivo.
Não há pressão sobre a estrutura de apoio (devido ao menor peso).	Baixa Eficiência energética (10% a 15%).
Não causam poluição sonora, devido ao seu menor comprimento.	Produção de energia em pequena escala.

Fonte: Autoria Própria.

Segundo Magalhaes A. (2016), os aerogeradores mais largamente utilizados são de eixo horizontal (HAWT) para produção de energia elétrica em grande escala, ainda que as de eixo vertical (VAWT) tenham sido as primeiras usadas para aproveitar a força motriz do vento, os pesquisadores modernos perderam o interesse por elas devido a percepção inicial de não conseguirem gerar energia em volume considerável. Assim a maioria das pesquisas foram focadas nas de eixo horizontal. Estes sistemas eólicos possuem vários campos que ainda são objetos de estudos pelo mundo, como o desenvolvimento de tecnologias para sua própria conservação, visto que algo que onera muito o custo dessas energias renováveis são os custos de manutenção e conservação. A manutenção dos sistemas eólicos é dividida em dois tipos principais: corretiva e preventiva.

Segundo R. Brandão (2011), manutenções baseadas em tempo de utilização não são nem um pouco eficazes. Em um mesmo parque eólico pode-se ter aerogeradores com regimes de funcionamento variáveis, sendo o desgaste não uniforme em todos os equipamentos, e, portanto, deve-se realizar manutenções com intervalos de tempo curtos, e sob acompanhamento constante, o que aumenta os custos operacionais devido ao maior tempo de máquina parada e de substituições desnecessárias muitas vezes. Segundo um estudo da IWES (*Fraunhofer Institute of Wind Energy Systems*), visando mais dados para mapeamento do comportamento dos aerogeradores de forma geral, foram analisados cerca de 193.000 relatórios de operação mensais e 64.000 relatórios de manutenção em 1.500 aerogeradores em parques na Alemanha durante 10 anos. Destes relatórios, a falha na torre do aerogerador eólico ainda continua uma incógnita de projeto e de operacionalização da manutenção, devido à ausência de dados sobre esse tipo de falha catastrófica. A Figura 1.5 mostra uma manutenção preventiva realizada nas pás da Aerogerador da fabricante VESTAS.

Figura 1.5: Manutenção realizada nas pás do aerogerador da fabricante VESTAS.




FONTE: RICHARD, Craig. Windpower, 2019. Conteúdos sobre energia eólica e novas tecnologias. Disponível no endereço eletrônico <https://www.windpowermonthly.com/article/1595597/vestas-tops-q2-orders-global-intake-hits-all-time-high>. Acesso em 08 de dezembro de 2022.

De acordo com Azevedo (2001), os componentes principais do aerogerador são os que causam maior prejuízo financeiro devido ao tempo de parada e ao custo de manutenção. Dentre eles, pode-se citar a caixa multiplicadora, o gerador, o sistema de controle *yaw* (freios), as pás do rotor, o controle de ângulo de *pitch* (resposta aerodinâmica) e por último, a torre que sustenta todo o sistema.

Segundo Sheng (2013), rolamentos danificados por excesso de vibração são responsáveis por 20% a 70% do tempo total de parada dos aerogeradores em operação, portanto a maioria dos estudos são direcionados a avaliação da caixa multiplicadora. A Figura 1.6 mostra a relação entre os tempos de parada e as principais causas de parada de aerogeradores.

Figura 1.6: Relação entre os tempos de parada e as causas de parada de aerogeradores.



FONTE: Sheng, Keller, & Glinsky, 2013.

Apesar deste histograma apontar a caixa de engrenagem como principal causa de indisponibilidade dos aerogeradores, devido a falha dos rolamentos por vibração excessiva. As falhas catastróficas que ocorrem na torre do aerogerador de energia eólica possuem poucos estudos. A problemática deve-se a dificuldade de monitoramento e correlação de informações obtidas de outras regiões do aerogerador, que possam gerar resultados confiáveis, para uma tomada de decisão rápida, que possa prever falhas.

1.1. Motivação

O estudo de prevenção de falhas catastróficas em torres eólicas tem sido bastante discutido no mundo, devido a falhas prematuras que podem até condenar as estruturas em intervalos pequenos de tempo se o projeto não for bem executado. Condenar ou perder uma estrutura devido a falha de uma torre torna-se extremamente caro, daí a necessidade de estudos que possam garantir afunçãoabilidade e permanência dos equipamentos em operação. As falhas catastróficas causam prejuízos enormes em caso de falhas nas torres, pois há a perda completa da estrutura, custando valores na casa de milhões de dólares. Portanto, tem-se a necessidade de implementação de novas tecnologias que possam prevenir e projetar com segurança tais estruturas. Existem vários estudos a respeito da análise dinâmica e estática dos aerogeradores, bem como seus efeitos ao longo dos anos. Os aerogeradores em geral são projetados para durar cerca de 20 anos (segundo o fabricante VESTAS), porém observa-se que na prática há condenação de estruturas com ciclo de vida muito reduzidas, entre 5 e 10 anos em função das condições operacionais devido a efeitos de vibração, carga de flambagem excessiva e a própria fadiga e fluência do material.

Diante do exposto, a Figura 1.7 apresenta um mapa que correlaciona as palavras chaves de vários artigos. Os artigos foram selecionados da base de dados *Scopus* utilizando as palavras chaves como filtro de busca: *neural network*, *wind turbine* e *fault*. Destaca-se que o mapa foi obtido por meio da ferramenta VOXviewer:

Os artigos que possuem maior quantidade de citações são os mostrados em amarelo na Figura 1.8, mostrando que os temas que envolvem monitoramento, aquisição de dados e inteligência artificial aplicado aos aerogeradores possuem crescentes estudos.

Atualmente, o estudo das características modais em estruturas de maneira geral, tem se tornado uma das principais formas de prevenção de falhas, contribuindo para a melhoria da manutenção e monitoramento de equipamentos de maneira geral. Diversos trabalhos realizam a análise de falhas por meio de análise modal como o de Oliveira (2017) e o de Khan, A. (1999), em que são utilizadas simulações numéricas e redes neurais inteligentes sobre modelos teóricos para a determinação de propriedades modais do modelo, e assim prever danos a estrutura de maneira geral.

No contexto da análise modal, essencialmente, há duas técnicas. A primeira, quando a entrada é conhecida e mensurada, é denominada de análise modal experimental. Normalmente é aplicada em estruturas menores, pois é possível de excitar toda a estrutura com um impacto ou excitação por *shaker*. Por outro lado, a análise modal operacional é aplicada em estruturas onde não é possível medir ou é desconhecida a entrada na estrutura.

As redes neurais possuem uma capacidade enorme de processamento, monitoramento e controle de dados, e podem classificar e agrupar um enorme volume de dados de forma rápida e simples. Elas possuem a habilidade de aprender padrões, conseguindo prever resultados, e elevar o grau de confiabilidade de um processo. O processamento de informações, segundo Mcavoy (2002), ocorre de maneira rápida e eficaz, e é imperativa na utilização de sensores virtuais para tomada de decisões, sendo a base do *machine learning* (aprendizado da máquina).

A análise modal experimental é utilizada para referenciar as características modais de um modelo, e isso pode ser realizado através do túnel de vento. O trabalho de Flávia de Melo (2020) é realizado um estudo das características de um túnel de vento para melhoria da eficiência de Aerogeradores dado o potencial de ventos de uma dada região, o que pode ser aplicado ao contexto de determinação das propriedades modais de uma viga através do conhecimento do comportamento dinâmico do túnel de vento e os perfis de velocidades no interior do mesmo.

Um experimento interessante realizado nessa área foi o experimento *Unsteady Aerodynamics Experiment Phase VI*, realizado em 2000 pelo *National Renewable Energy Laboratory* (NREL) no túnel de vento Ames da NASA. O teste de comparação foi realizado em conjunto pela NREL e o *Northeast Wisconsin Technical College* (NWTC) onde observaram sérias deficiências nas atuais ferramentas de modelagem aerodinâmica de aerogeradores por meio de experimentos em túnel de vento com um modelo em escala (VERMEER et al., 2003).

Portanto, a análise modal é fundamental para se conhecer o comportamento dinâmico de uma estrutura, e com isso, pode-se monitorar e prever falhas estruturais em equipamentos de maneira geral. Dessa forma, conhecendo-se as características modais de um determinado objeto, pode-se prever o comportamento dinâmico dele submetido a cargas dinâmicas.

1.2. Justificativa

A geração de energia eólica atualmente é considerada um dos grandes desafios tecnológicos da atualidade, de fato como energia competitiva e disponível em todas as regiões do planeta, podendo futuramente substituir as fontes fósseis como alternativa limpa. Diversos autores discorrem a respeito da modelagem de sistemas para aperfeiçoamento dessas tecnologias, entre elas os impactos de deformações e vibrações da estrutura causadas pela ressonância com o vento incidente, que podem levar a falhas catastróficas dos sistemas. Existem estudos como o de Dalpiaz, G., & Rivola, A. (1997) e Oliveira (2017) que evoluem em direção a redes neurais inteligentes para controle dos sistemas mecânicos, tornando essas tecnologias cada vez mais seguras e confiáveis no monitoramento de sistemas mecânicos. Concomitantemente, a aplicação de drones ajuda na inspeção visual dos equipamentos, registrando imagens que podem ser posteriormente analisadas para a identificação de eventuais problemas. Sobrevoando fazendas eólicas ou solares, os drones podem agilizar o processo de inspeção visual.

Para tanto, o grande desafio de projeto desses equipamentos é determinar as características modais do aerogerador. Conforme Humar (2001) indica, a análise da resposta de vibração é de considerável importância no projeto de estruturas que possam estar sujeitas a perturbações dinâmicas. Em geral, os trabalhos sobre esse tema tratam da análise de vibrações presentes na estrutura, observando-se os deslocamentos dos picos de frequências quando a rigidez da estrutura muda, ou seja, danos causados a estrutura como um todo. Em alguns casos, utilizam-se *strain gauges* para avaliar deformações na torre em regiões próximas a base, de forma a medir os efeitos sobre a fundação do aerogerador. No entanto, avaliam danos já causados na estrutura, não a prevenção contra danos.

Diante do exposto, Sirqueira (2008) realizou uma análise modal de uma torre eólica, e obteve as frequências modais com as formas modais. Na análise harmônica considero uma carga determinística senoidal correspondente a ação do vento atuando sobre as pás da torre eólica. Ao final, concluiu que a influência do primeiro modo de vibração na resposta do modelo da torre é predominante (os modos correspondentes a flexão), ou seja, a torre comporta-se como uma viga engastada e livre de maneira geral.

O trabalho de Oliveira (2017), por sua vez, realiza uma análise modal para predição do dano e vida útil da estrutura utilizando sensores reais e virtuais. Sensores reais são sensores físicos, como *strain gauges* e acelerômetros, enquanto sensores virtuais são sensores que fisicamente não existem, mas por meio de modelos permitem inferir a medição em outro ponto. Destaca-se que os sensores virtuais dependem da resposta dos sensores físicos para melhor o desempenho previewal do modelo. Neste sentido, Lotufo. (1999) descreve que o sensor virtual é a concatenação de informações obtidas por alguns poucos sensores, para se obter a resposta em outra região da estrutura analisada.

Apesar da proposta metodológica de Oliveira (2017) permitir obter bons resultados para o monitoramento das frequências naturais e vida da estrutura. O modelo utilizado foi baseado num modelo numérico, que pode não prever todos os efeitos de um modelo experimental.

Portanto, o presente trabalho propõe avaliar as propriedades modais de um modelo de viga engastada livre, aproximação de um aerogerador conforme Sirqueira (2008), sob escoamento. Para tanto, é utilizado a proposta de sensor virtual para aumentar ou suprimir a quantidade de sensores físicos. Por fim, diferente do trabalho de Oliveira (2017) que utilizou um modelo numérico é almejado utilizar uma viga instrumentada sob ação de um escoamento gerado por um túnel de vento.

1.3. Objetivo do Trabalho

1.3.1. Objetivo Geral

Determinação das características modais de um modelo de viga sob escoamento com auxílio de sensores virtuais. Sendo o modelo dos sensores virtuais obtido por meio da inteligência artificial do tipo redes neurais.

1.3.2. Objetivos Específicos

Para atingir o objetivo geral do trabalho, listam-se os seguintes objetivos específicos:

- Estudo da arte das turbinas eólicas, principais falhas e técnicas de monitoramento;
- Estudo das propriedades modais de uma viga engastada livre, sendo o modelo de Euler Bernoulli;
- Estudo e aplicação das técnicas de análise modal experimental e operacional utilizada em experimentos;
- Estudo e aplicação da rede neural utilizada para sensores virtuais em análise modal;
- Determinação das velocidades de escoamento do túnel de vento para experimentar a viga engastada livre;

- Aplicação das técnicas de análise modal;
- Por fim, análise comparativa das propriedades modais da viga de Euler Bernoulli, com às obtidas por análise modal experimental e operacional.

1.4. Estrutura do trabalho

Diante da problemática, no capítulo 1 foi realizada uma introdução ao tema com relação ao estudo de aerogeradores, e os problemas enfrentados em relação aos efeitos de cargas de vento dinâmicas. É motivado pelas falhas catastróficas e a importância de se realizar estudos que possam prevenir problemas através de métodos de monitoramento.

Depois, no capítulo 2 é realizada uma revisão bibliográfica sobre os diversos temas correlacionados (Aerogeradores, sensores de deformação, acelerômetros, sistemas de monitoramento, sensores virtuais, redes neurais), mostrando as aplicações gerais e as diversas ferramentas e tecnologias existentes na área de monitoramento de estruturas.

Em sequência, no capítulo 3 é realizada uma apresentação sobre Redes Neurais e os tipos de algoritmos e os princípios de funcionamento.

O capítulo 4 é dedicado a apresentação de conceitos sobre análise modal de maneira geral, e depois realizando-se um detalhamento sobre as técnicas e os tipos, equacionamento e metodologias.

O capítulo 5 apresenta os materiais utilizados (o túnel de vento, a viga, o sistema de aquisição de dados, etc) e a metodologia adotada para realização do estudo, visando cumprir o objetivo geral e os específicos descritos neste trabalho.

O capítulo 6 mostra os principais resultados obtidos através das metodologias adotadas para a análise modal da viga.

Por fim, no capítulo 7 são apresentadas as conclusões sobre os resultados obtidos, bem como as sugestões dos trabalhos futuros.


2. REVISÃO BIBLIOGRÁFICA

Neste capítulo é apresentada uma revisão bibliográfica sobre temas relacionados a energia eólica e falhas em aerogeradores, com o objetivo de contextualizar o problema. Em geral pode-se relacionar o aumento da geração da energia eólica no mundo com a escassez de combustíveis fósseis e a elevada dependência de fontes de energéticas não renováveis, e com isso os elevados custos de desenvolvimento tecnológico e de sistemas de monitoramento que visam a redução de custos de manutenção que tornem esse tipo de energia competitiva e de baixo custo no mercado.

2.1. Falhas em Aerogeradores

Os aerogeradores geralmente operam em regime de trabalho contínuo, ou seja, o regime de trabalho das peças que envolvem rolamentos, buchas de fixação e mancais é bastante elevado em termos de desgaste. Dado este fato, é importante a prevenção de falhas catastróficas destes componentes, visto que podem gerar prejuízos enormes devido a indisponibilidade do equipamento. A Figura 2.1 mostra o esquema representativo de um aerogerador de energia eólica.

Figura 2.1: Componentes de um aerogerador em esquema simplificado.



FONTE: MEDEIROS. Windbox, 2020. Conteúdo de gestão e publicações sobre energia eólica. Disponível em <https://windbox.com.br/blog/componentes-dos-aerogeradores/>. Acesso em 02 de dezembro de 2022.

Segundo R. Brandão (2011), os pontos mais críticos em que ocorrem as falhas catastróficas, ocorrem em duas regiões principais, o nacele e a torre de sustentação. Os principais problemas, segundo H. Azevedo (2015), que podem causar falhas das estruturas das torres eólicas são: vibrações sobre a estrutura como um todo; tensões e deformações excessivas; levando a redução da vida útil do equipamento.

Existem poucos estudos a respeito das falhas em aerogeradores de maneira geral. Cerca de 426 resultados foram encontrados na plataforma *Scopus*, com as palavras-chave: Rede neural, túnel de vento, viga sob escoamento, análise modal. Sendo a torre uma grande incógnita na falha. A torre transfere todas as cargas para a fundação, e é o elo que determina a resistência mecânica de todo o sistema, e pouco se sabe sobre o comportamento real deste componente quando submetido a cargas dinâmicas oscilantes. Segundo R. Brandão (2011), quando se insere um fator estocástico como a velocidade do vento, que alterna em módulo e direção, é possível avaliar o conteúdo energético da influência do vento através de análises estocásticas, como por exemplo em uma análise espectral.

Um exemplo de falha imprevisível aconteceu na França onde a torre do aerogerador entrou em colapso devido a esforços excessivos sobre o nacele, provavelmente devido a mudanças abruptas de direção do vento, que geraram uma torção e vibração na estrutura, e a levou a falha, conforme Figura 2.2.

Figura 2.2: Destroços da queda de Aerogerador Eólica por vibração –França.



FONTE: PortaldasEnergia.net (2021).

Neste contexto, de janeiro até junho de 2019 foram noticiadas as quedas de 3 aerogeradores da GE (*General Electric*) nos Estados Unidos da América, com falhas justamente nas torres que sustentam todo o aerogerador, devido a esforços excessivos sobre o sistema, conforme mostrado na Figura 2.3.

Figura 2.3: Falha catastrófica de um aerogerador nos EUA.



FONTE: PortaldaNergia.net (2019).

Outro exemplo de falha catastrófica, foi o observado na Suécia, onde houve a queda de um aerogerador da fabricante VESTAS, devido a uma falha no processo de fabricação das pás, o que gerou esforços excessivos sobre a estrutura, conforme mostrado na Figura 2.4.

Figura 2.4: Falha catastrófica de uma Aerogerador na Suécia.



FONTE: PortaldaNergia.net (2020).

Na Figura 2.4, mostra um dos quase 1.500 aerogeradores (todo o parque eólico) que foram condenadas por causa de uma falha no processo de fabricação das pás, em que houve uma contaminação do material, o que gerou falha sistemática em todos os aerogeradores.

2.2. Técnicas de Monitoramento

As técnicas de monitoramento e diagnóstico de efeitos dinâmicos e estáticos sobre máquinas em geral estão ganhando aceitação em vários setores industriais. Elas provaram ser eficazes na

manutenção preditiva ou proativa e no controle de qualidade de acordo com Dalpiaz e Rivola (1997). Junto com o rápido desenvolvimento de tecnologias, os sensores estão sendo cada vez mais usados para monitorar o *status* dos equipamentos. Algumas técnicas foram desenvolvidas para um controle mais fino de equipamentos e sistemas, algumas de destaque serão apresentadas.

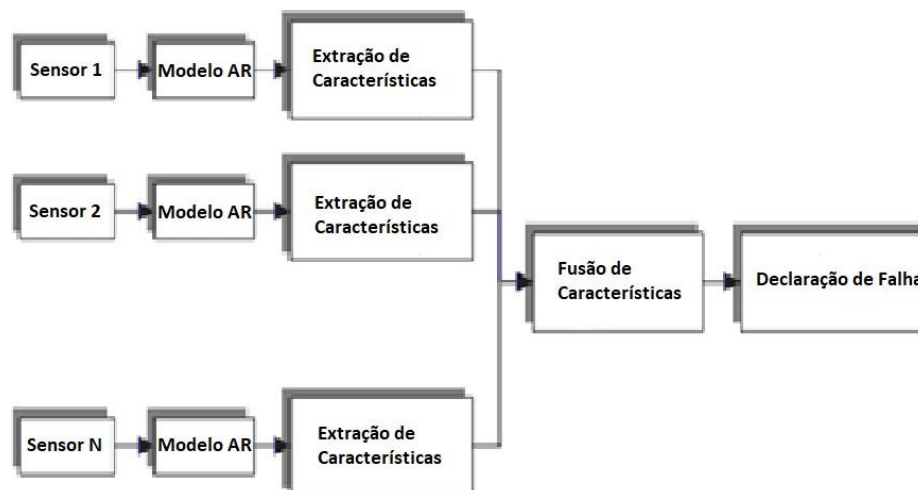
2.2.1. Método da fusão de dados multisensores

O método da fusão de dados multisensores foi aplicada com sucesso em várias áreas. Chen et al. (1995) desenvolveu uma metodologia baseada na união de informações baseadas em sensor e em um modelo para prever fratura e propagação de trincas. Fang e Yao (1997) desenvolveu a fusão de dados tridimensional para determinação de forças por um modelo agregador multivariado de série temporal. Khan et al. (1999) propôs uma metodologia para obter a discriminação ótima do tipo de falha por meio de uma configuração otimizada de localização do sensor. Para sistemas rotativos, Dalpiaz e Rivola (1997) aplicou uma transformada de *Wavelet* para extrair características de sinais de translação recíproco. Logan e Mathew (1996) propôs a extração de características caóticas de diferentes falhas de mancais de rolamento como uma medida para o diagnóstico de falha por vibração. Por último, uma grande aplicação que foi aprimorada no Brasil, foi a fusão de imagens multisensor para identificação e o mapeamento de ambientes flúvio-estuarinos da Amazônia por Gonçalves et al. (2009).

Um trabalho interessante é o de F. Gonçalves et al. (2009), em que multisensores são usados para coletar sinais de vibração de desbalanceamento rotativo em uma bancada de teste. As características de cada sinal de vibração são extraídas com um modelo autorregressivo. A fusão de dados é então implementada com um algoritmo de correlação em cascata em uma rede neural. Os resultados mostram que o diagnóstico baseado em fusão de dados multisensor supera o diagnóstico de sensor único com significância estatística.

À medida que a complexidade da máquina aumenta, as técnicas baseadas em um único sensor podem exibir baixa sensibilidade a falhas no estágio inicial de crescimento da falha. As técnicas de fusão de dados combinam dados de diferentes sensores e informações relacionadas de bancos de dados associados, a fim de alcançar maior precisão e inferências mais específicas do que o que poderia ser alcançada pelo uso de um único sensor sozinho. A Figura 2.5 mostra o diagrama de blocos que exemplifica essa metodologia.

Figura 2.5: Diagrama de blocos exemplificando o funcionamento do método de fusão de dados.

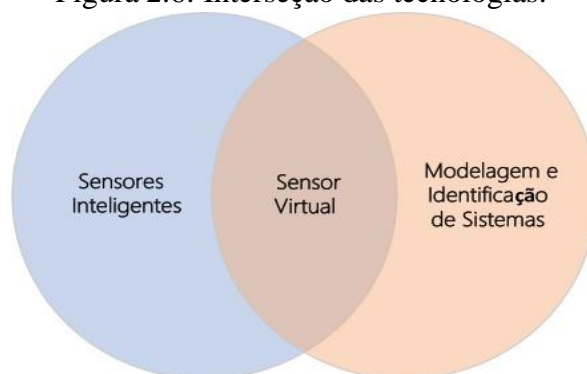


FONTE: Adaptado de Liu, Q., & Wang, H. P. (2001).

2.2.2. Método do sensor virtual

Sensor virtual é um modelo matemático que calcula, com base nos dados disponíveis nos sistemas, as variáveis mais importantes para o monitoramento do processo em estudo. Para o sistema de controle o resultado do cálculo se comporta como um novo sensor inserido no processo. De acordo com Lotufo e Garcia (2008), o sensor virtual está na intersecção de duas grandes áreas: sensores inteligentes e modelagem e identificação de sistemas, conforme mostrado na Figura 2.6.

Figura 2.6: Intersecção das tecnologias.



FONTE: Lotufo e Garcia (2008)

Os sensores inteligentes são dispositivos físicos que possuem a capacidade de monitorar, detectar e responder movimentações ou alterações físicas sofridas por determinado equipamento em tempo real. A modelagem e identificação de sistemas é uma área do conhecimento que estuda técnicas alternativas de modelagem matemática, desenvolver e implementar modelos matemáticos de sistemas reais para implementação, enquanto o sensor virtual representa a união entre o modelo matemático desenvolvido e o sensor inteligente, de forma a cruzar as informações e obter dados precisos.

Em muitos processos em que se pode contar com uma multiplicidade de sensores e se tem também o monitoramento ou o controle realizado por computador, torna-se possível implementar um sensor virtual (*soft-sensor*), o qual nada mais é que um modelo que estima a variável desejada a partir de dados medidos. Segundo Fortuna et al. (2007), os sensores virtuais possuem muitas vantagens em relação a utilização apenas de sensores físicos:

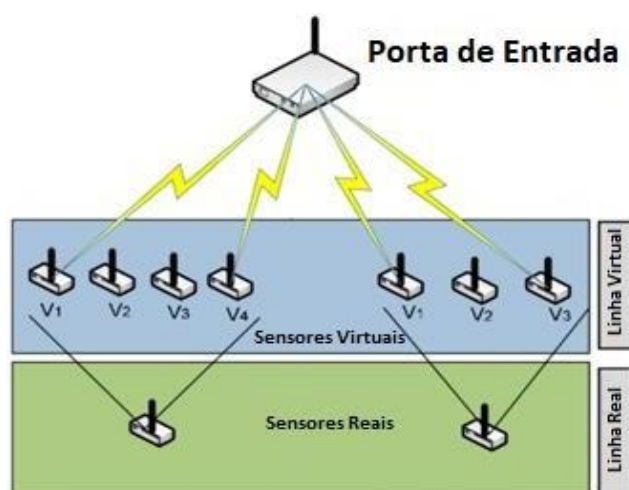
- Alternativa de baixo custo;
- Podem ser utilizados paralelamente aos sensores físicos;
- Podem gerar informações relacionadas a detecção de falhas, e gerar uma maior confiabilidade ao processo;
- Fácil ajuste de parâmetros.

O sensor virtual pode ser dividido em duas partes principais, uma composta pelos sensores propriamente ditos e outra composta pelo modelo (é o resultado da instrumentação e da modelagem). De maneira geral, são utilizados sensores disponíveis comercialmente e o objeto final está concentrado no modelo implementado em programa computacional. Existem muitos métodos para se estimar variáveis através de outras variáveis medidas, e estes podem ser classificados em 3 grandes grupos:

- Modelos fenomenológicos: Obtidos através de uma abordagem analítica (são os chamados modelos mecanicistas).
- Modelos empíricos: Obtidos de dados obtidos em laboratório.
- Modelos caixa – Preta: Obtidos de dados operacionais através da aplicação de algoritmos como redes neurais, computação nebulosa e/ou métodos estatísticos.

A Figura 2.7 ilustra o esquema de funcionamento de sensores virtuais:

Figura 2.7: Esquema de funcionamento de sensores virtuais.



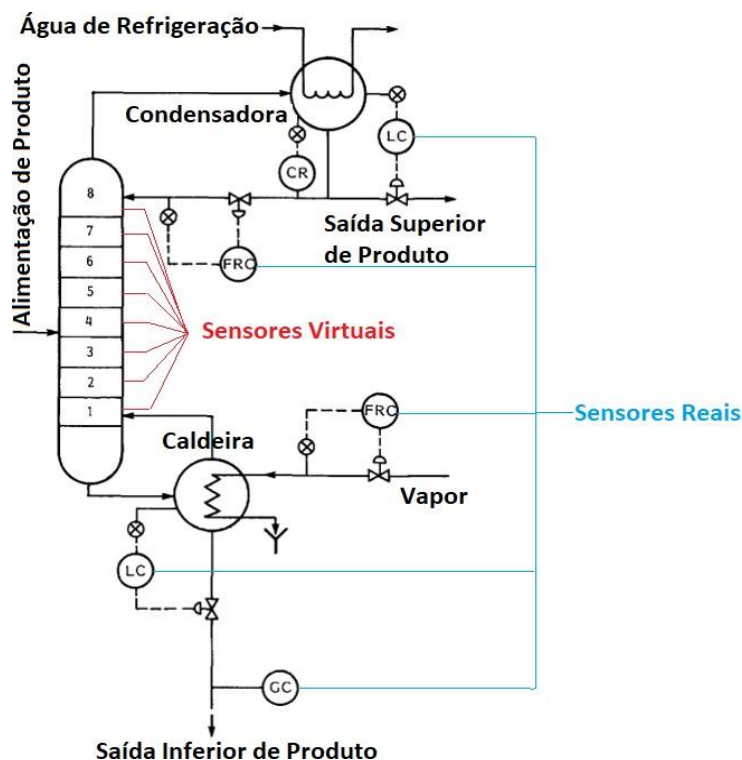
FONTE: Traduzido de Khalid, Zubair Fisal, Norsheila Rozaini & Mohd (2014).

No trabalho de Tham, et al (1990), é proposto um caso em que são utilizados oito sensores virtuais para inferir as saídas de processos sujeitos a uma grande quantidade de atrasos. Os algoritmos, referidos como *soft-sensors* foram aplicados com sucesso em várias plantas industriais, alguns exemplos são citados:

- Concentração de fermentação em biomassa.
- Composição de coluna de desmentanizador.
- Índice de fluidez de um polímero.

Os resultados obtidos mostram o potencial desse método para solucionar problemas de controle causados por limitações na instrumentação de processos industriais. Na Figura 2.8, tem-se o diagrama esquemático da coluna de destilação da planta fabril, onde CR é o sensor registrador analisador, FRC é o sensor registrador e controlador de fluxo, GC é o sensor de cromatografia gasosa e por último o LC é sensor de controle de nível variável. Através destes sensores é possível mensurar a composição química da coluna de destilação, quando se implementa, através de técnicas de redes neurais (implementadas em computador) os sensores virtuais de 1 a 8 mostrados na Figura 2.8.

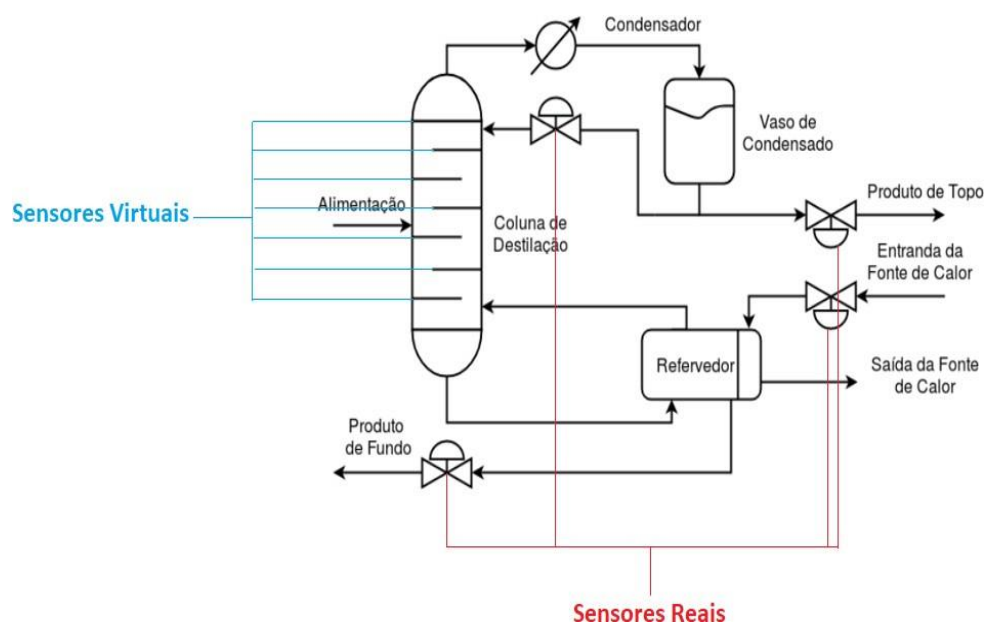
Figura 2.8: Processo de fermentação de biomassa e subprodutos. Em azul, são mostrados os sensores virtuais, e em vermelho os sensores reais.



FONTE: Adaptado e traduzido de Tham, et al (1990).

Por sua vez, no trabalho de Lima (2018) vários sensores alocados em posições estratégicas tornam possível a criação de sensores virtuais dentro de um tanque, baseados em redes neurais artificiais, para estimar a composição do gás liquefeito de petróleo (GLP). A Figura 2.9 ilustra o processo de destilação de gás GLP.

Figura 2.9: Fluxograma do processo de destilação de gás GLP. Em azul, são mostrados os sensores virtuais, e em vermelho os sensores reais.

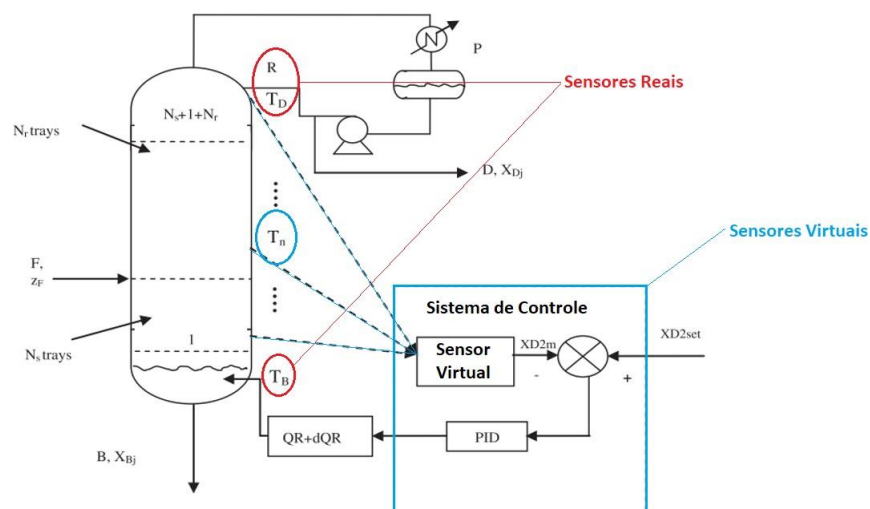


FONTE: Adaptado e traduzido de Lima (2018)

Na Figura 2.9, pode-se observar o posicionamento de sensores reais alocados em pontos estratégicos do fluxograma, de forma que se torna possível a criação de sensores virtuais dentro da coluna de destilação, sensores estes que podem prever a composição do gás GLP.

No trabalho de Rani et al. (2013), foi realizado um projeto de sensores virtuais usando uma rede neural adaptativa para estimar a composição química de um processo de destilação de álcool baseado nas medidas de temperatura do processo fabril. A Figura 2.10 ilustra o processo de destilação analisado no artigo para desenvolvimento do sensor virtual:

Figura 2.10: Fluxograma de Aplicação do Sensor Virtual a uma Destilaria. Em azul, são mostrados os sensores virtuais, e em vermelho os sensores reais.




FONTE: Adaptado e traduzido de Rani et al. (2013)

A Figura 2.10 mostra a utilização de sensores reais, para implementar sensores virtuais no tanque de destilação de álcool, de forma que um sistema de controle baseado em redes neurais adaptativas consiga determinar a composição química do processo.

A Figura 2.11 mostra esta aplicação, que tem se tornando bastante comum no mundo, devido a necessidade de monitoramento e manutenção das instalações das pontes existentes, bem como sua resistência em relação a corrosão ao tempo. A pré-seleção de veículos é tratado como uma balança (aferindo o peso), acelerômetros verificam a aceleração vertical da estrutura, e o sensor de tráfego determina a velocidade média dos veículos aferidos. Os sensores virtuais determinam as taxas de deformação sofridas pela ponte, gerando uma estimativa de vida útil ou de regiões com possíveis problemas estruturais.

Figura 2.11: Aplicação de Sensores Virtuais no Monitoramento de Pontes.



FONTE: PROTEÇÃO DE PONTES. Kistler, 2022. Disponível em: <https://www.kistler.com/>. Acesso em: 12 de dezembro 2022.

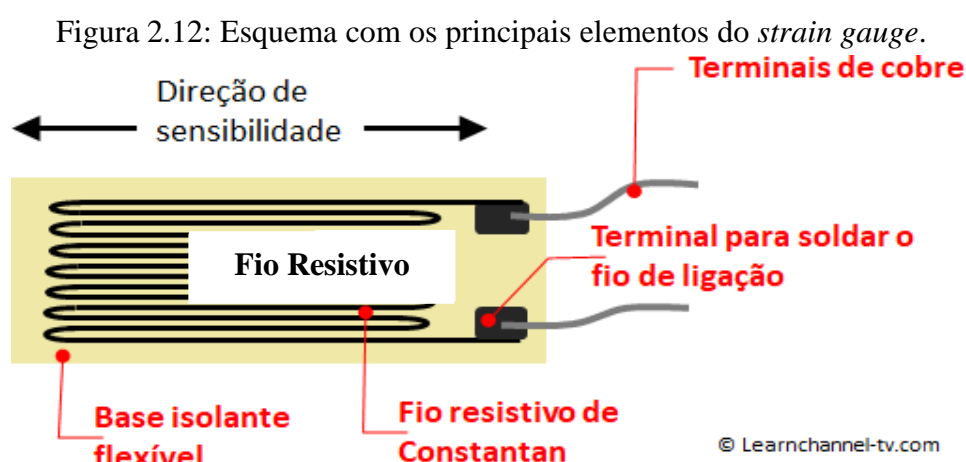
Outro grande exemplo de aplicação de sensores virtuais é o empregado pela NASA (*National Aeronautics and Space Administration*), onde é necessária uma quantidade enorme de sensores para mapeamento do espaço tridimensional e localização de corpos celestes, satélites, determinação de posições por quadrantes, bem como descrever a posição de reentrada na atmosfera dentre outras variáveis que, por meio de sensores reais, elevaria o custo em muitos milhões de dólares (Disponível em <https://www.nasa.gov/feature/smart-sensing-and-sensor-development>). O modelo mais utilizado para estas aplicações é o de regressão gaussiana, que mistura os métodos fenomenológicos, empíricos e de caixa preta, de forma a se obter regressões em 3 variáveis, obtendo-se múltiplas saídas. Esse tipo de regressão é do tipo matricial de ordem elevada, sendo determinada através de redes neurais especializadas nesse tipo de interação.

2.3. Sensores para monitoramento

Atualmente existem inúmeros tipos de sensores que podem ser utilizados em detecção de falhas de sistemas mecânicos. A determinação do sensor correto para cada aplicação possui grande importância na determinação de saídas adequadas a determinados estímulos.

2.3.1. Strain gauge

O extensômetro ou *strain gauge* é um sensor que é colocado na superfície de uma peça, e cuja função é a determinação da deformação sofrida pela mesma devido a aplicação de um carregamento. A Figura 2.12 possui um esquema com os principais elementos deste sensor.



FONTE: EXTENSOMETRIA. Learnchannel-TV.com, 2017. Disponível em: <https://learnchannel-tv.com/pt/tecnologia-de-sensor/ponte-de-wheatstone/ponte-de-wheatstone-com-strain-gauges-extensometros/>. Acesso em 13 de Dezembro de 2022.

Existe um fio resistivo na Figura 2.12, que altera sua resistência elétrica de acordo com o alongamento da superfície em que ele está colocado. Essa alteração de resistência gera sinais elétricos

que são captados pela placa de aquisição, transformando os valores em deformações. Estes valores podem ser convertidos em tensão mecânica.

2.3.2. Acelerômetros

A análise de vibração consiste na instalação de sensores, chamados de acelerômetros que são capazes de medir a vibração no local que são instalados. Esta técnica é amplamente utilizada para a verificação do nível de solitação estrutural, como também para identificar falhas de maneira preditiva. Os acelerômetros são conectados por fios em placas de aquisições ou também chamados de coletores, que são responsáveis por receber os sinais dos sensores e enviá-los ao *software* responsáveis por realizar o armazenamento e processamento de sinal. A Figura 2.13 mostra um acelerômetro piezoelétrico:

Figura 2.13: Exemplo de um acelerômetro piezoelétrico.



FONTE: ACELERÔMETROS. Direct Industry, 2028. Disponível em: <https://www.dmc.pt/tipos-de-acelerAMETros/>. Acesso em 13 de Dezembro de 2022.

2.3.3. Transdutor de deformação

O transdutor de deformação na verdade é uma variação do extensômetro, onde o *strain gauge* é encapsulado, tornando-se ainda mais duráveis. O *strain gauge* é selado, além de ser mecanicamente protegido pela carcaça do transdutor de deformação. Além disso, os transdutores de deformação permitem que sejam medidos valores de força muito elevados. Isso é chamado de medida de *shunt* de força. Ou seja, o transdutor de deformação realiza a medida numa derivação de força, e apenas mede a condição de deformação do componente, que por sua vez é dependente do material - neste caso de aço. Uma aplicação típica dos transdutores de deformação deste modelo está nos freios de *yaw* de aerogeradores, por exemplo, permitindo que a força da sapata de freio seja gravada por meio de uma medição de deformação na parte de trás do freio. A Figura 2.14 ilustra um transdutor de deformação:

Figura 2.14: Exemplo de um transdutor de deformação.




FONTE: TRANSDUTORES DE TENSÃO. HBM, 2017. Disponível em: <https://www.hbm.com/pt/7347/medico-confiavel-de-forcas-e-mAMEntos-em-aerogeradores/>. Acesso em 13 de dezembro de 2022.

A Figura 2.14 mostra que o transdutor é parecido com o *strain gauge*, sendo que a diferença está no fato de ele ser encapsulado, para proteção do sensor.

2.3.4. Sensor de flexão

Sensores de flexão convertem a alteração da flexão ou da curvatura em variação de resistência elétrica, ou seja, eles convertem energia de deformação em energia elétrica. Em geral, as medidas de flexão podem ser fornecidas por diferentes tipos de sensores capazes de fornecer medidas diretas ou indiretas de valores angulares, como por exemplo, o sensor de rede de *bragg* de fibra óptica ou a família de unidades de medição inercial (acelerômetros, giroscópios, magnetômetros ou combinações entre eles). A Figura 2.15 apresenta um sensor de flexão:

Figura 2.15: Exemplo de um sensor de flexão.



FONTE: G. Sanggio (2015). p 2.


O sensor de flexão é bem prático e de fácil aferição, visto que pode ser colado sobre qualquer superfície lisa, sendo baseado na medida da variação da capacitância do circuito integrado.

2.4. Monitoramento em aerogeradores

O conceito do *strain gauge* tornou possível a evolução tecnológica nos sistemas de monitoramento de estruturas a partir de simples medições e tratamento de dados em campo, sendo utilizado nas mais diversas aplicações industriais. Ao longo dos anos surgiram diversas aplicações na literatura que possibilitaram o desenvolvimento de sistemas mais efetivos e produtivos de uma maneira geral.

O trabalho desenvolvido por Alexandre Pressas (2021) foi uma dessas grandes contribuições, onde é proposto a utilização de uma rede neural dinâmica para capturar os efeitos de deformação no interior do rotor de um aerogerador por meio de sensores reais, replicados em sensores virtuais ao longo de toda a estrutura. A Figura 2.16 ilustra a aplicação concebida pelo autor.

Figura 2.16: Aplicação de *strain gauges* e outros sensores para monitoramento de aerogeradores.



FONTE: Adaptado e traduzido de Alexandre Pressas (2021)

Outro trabalho muito importante foi o apresentado por Van Binsbergen (2021) na Conferência Internacional de Mecânica Offshore e Engenharia do Ártico – OMAE, em que foi desenvolvido um modelo dinâmico de trens de força de aerogeradores usando medições de sensor real para replicar resultados em sensores virtuais. Neste estudo, os dados do SCADA (Sistema de Controle e Aquisição de Dados) e outros dados do sensor são analisados a partir de um aerogerador de 1,5 MW, fornecida pelo *National Renewable Energy Laboratory*. Um modelo multicorpos do trem de força é feito e sensores baseados em simulação são colocados em rolamentos para observar a possibilidade de obter propriedades geométricas e modais a partir de sensores de vibração baseados em simulação. A partir de sensores de vibração, tensão e deformação, foi possível estabelecer um modelo que capturasse os efeitos medidos em um aerogerador *offshore*, como mostrado na Figura 2.17:

Figura 2.17: Ilustração de conjunto de torres eólicas *offshore* ancoradas.




FONTE: VALDEMAR MEDEIROS. CPG, 2022. Disponível em: <https://clickpetroleoegas.com.br/projeto-de-lei-em-tramitacao-no-senado-quer-regulamentar-a-producao-offshore-de-energia-eolica-e-solar-para-atrair-novos-investimentos-ao-brasil/> . Acesso em 15 de dezembro de 2022.

Na Figura 2.17, na região submersa foram instalados sensores de vibração, e extensômetros nos cabos de aço que seguram os aerogeradores. Já na parte acima da água foram instalados *strain gauges* e acelerômetros para modelagem dos sensores virtuais no modelo.

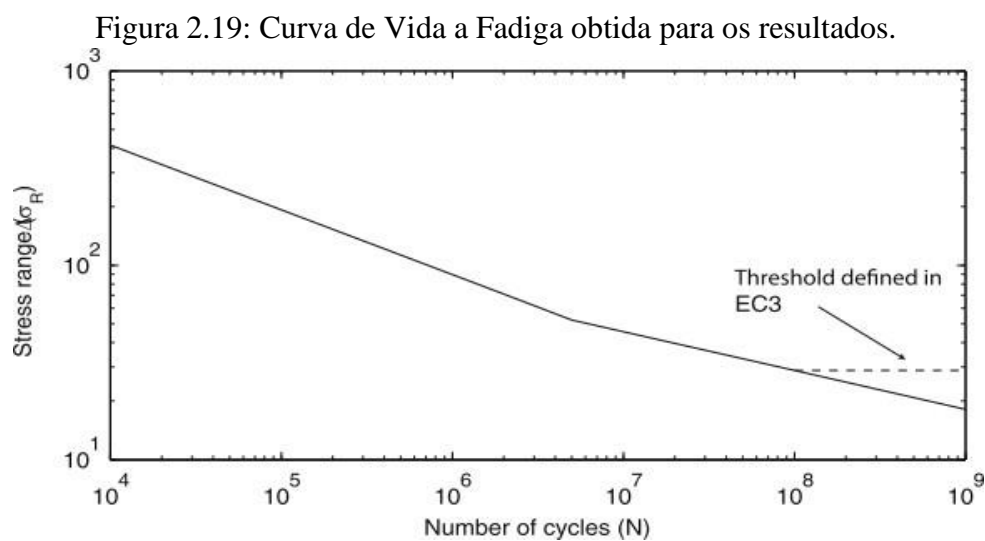
Outro trabalho muito importante referente a utilização de *strain gauges* é apresentado por Oliveira (2017), em que é proposto a utilização de *strain gauges* e acelerômetros em determinados pontos da Torre de uma Aerogerador eólica a fim de reproduzir o efeito para vários sensores virtuais ao longo da mesma Torre, e melhorar os resultados de deformação obtidos, extrapolando-se para mais pontos na análise. A Figura 2.18 mostra os pontos de instrumentação adotados pelo autor:

Figura 2.18: Aplicação de *strain gauges* (Q1 e Q2) e acelerômetros (S1, S2, S3, S4, S5 e S6) para Aerogeradores.



FONTE: Oliveira (2017).

Os resultados obtidos por meio de uma rede neural foram convertidos em uma curva de vida a fadiga, mostrada na Figura 2.19:

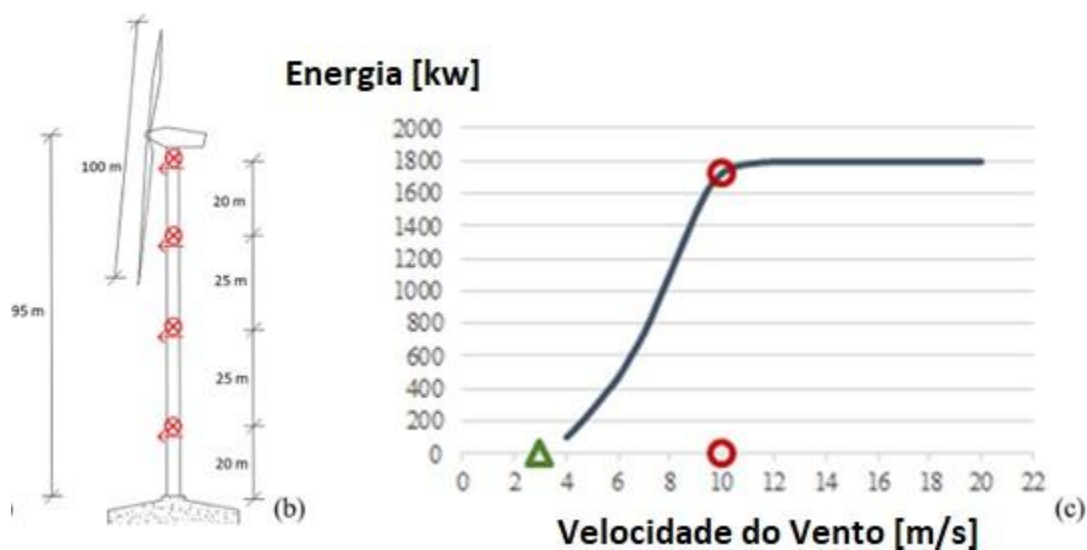


FONTE: Oliveira (2017)

Os dados foram obtidos e então, foi montada a curva S-N a partir dos dados do transdutor de tensão para converter os resultados obtidos de deformação do *strain gauge* para tensões em função da ciclagem.

Outro trabalho importante foi o apresentado por J. Pacheco (2020) sobre o desenvolvimento de um sistema de monitoramento de fazendas de aerogeradores por meio de sensores de deformação e SCADA. As estratégias foram desenvolvidas em Portugal e devem ser capazes de avaliar a condição estrutural de um conjunto aerogeradores e sua vida a fadiga usando a resposta às cargas de operação. A Figura 2.20 mostra os pontos de instrumentação com sensores reais e a geração de energia obtida em função da velocidade do vento:


Figura 2.20: Posição dos sensores de medição instalados e a curva de potência da Aeroerador.



FONTE: J. Pacheco (2020).

Foram realizados alguns ensaios para se conhecer o comportamento da estrutura. A Figura 2.21 mostra o posicionamento dos *strain gauges* dentro da torre do aerogerador.


Figura 2.21: *Strain gauge* montado no interior da torre do aerogerador para avaliação das deformações.



FONTE: J. Pacheco (2020).

Algumas aplicações utilizam *strain gauges* de forma dedicada a equipamentos de geração de energia eólica, o sensor mais utilizado no mundo é a série de sensores de deformação ESR que fornece dados de medição de deformação digitalizados diretamente para o controlador da máquina ou sistema de aquisição de dados. O sensor de deformação possui compensação de temperatura integrada e medição livre de tensão (*stress-free*), que permite tempo de operação quase ilimitado. A Figura 2.22 ilustra o sensor ESR.


Figura 2.22: ESR strain Sensor aplicado a AeroGeradores.



FONTE: ESR STRAIN SENSOR. Leine Linde, 2022. Disponível em: <https://www.leinelinde.com/pt-BR/produtos/sensores-de-deformacao/esr-strain-sensor/>. Acesso em 12 de dezembro de 2022.

A Figura 2.23 ilustra o posicionamento de sensores em aerogeradores para aquisição de deformações em tempo real.

Figura 2.23: Posicionamento de *strain gauges* em aerogeradores (Serie ESR).



FONTE: ESR STRAIN SENSOR. Leine Linde, 2022. Disponível em: <https://www.leinelinde.com/pt-BR/produtos/sensores-de-deformacao/esr-strain-sensor/>. Acesso em 12 de dezembro de 2022.

As figuras Figura 2.22 e Figura 2.23 mostram aplicações reais do sensor de deformação que são soluções vendidas comercialmente para monitoramento de sistemas dinâmicos. Outros exemplos são as configurações tradicionais de *strain gauges*, com o desenho padrão mais simples, como mostrado na Figura 2.24:

Figura 2.24: *Strain gauge* posicionado no interior da torre de um aerogerador em construção.



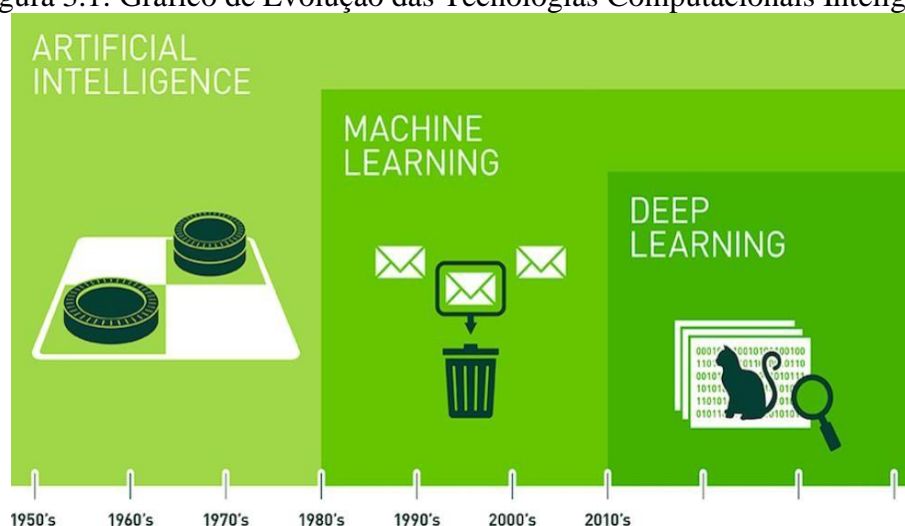
FONTE: STRAIN GAGES. HBM, 2014. Disponível em: <https://www.hbm.com/pt/6949/siemens-cargas-em-fundacoes-de-turbinas-eolicas-offshore/>. Acesso em 10 de dezembro de 2022.

A Figura 2.24 mostra que o *strain gauge* é bem maior que os comuns encontrados no mercado, e que ele está disposto no sentido da torre.

3. REDE NEURAL

Inteligência artificial pode ser definida como sendo o ramo da ciência da computação que estuda como construir máquinas que executem tarefas de forma inteligente. O termo inteligência artificial surgiu em 1956, a partir de uma série de conferências na universidade de *Dartmouth*, nos Estados Unidos, em que o professor John McCarthy propôs que matemáticos e cientistas trabalhassem em um projeto para conseguir que uma máquina se comportasse de maneira que, um ser humano pudesse realizar suas tarefas de forma inteligente. Os termos Inteligência Artificial (IA), *Machine Learning* (ML) e *Deep Learning* estão intimamente interligados, mas não são a mesma coisa. O histórico de desenvolvimento destas tecnologias é representado na Figura 3.1.

Figura 3.1: Gráfico de Evolução das Tecnologias Computacionais Inteligentes.



FONTE: DEEP LEARNING. Ciência de Dados, 2018. Disponível em <https://www.cienciaedados.com/aplicacoes-de-ia-e-machine-learning-na-construcao-civil/>. Acesso em 10 de dezembro de 2022.

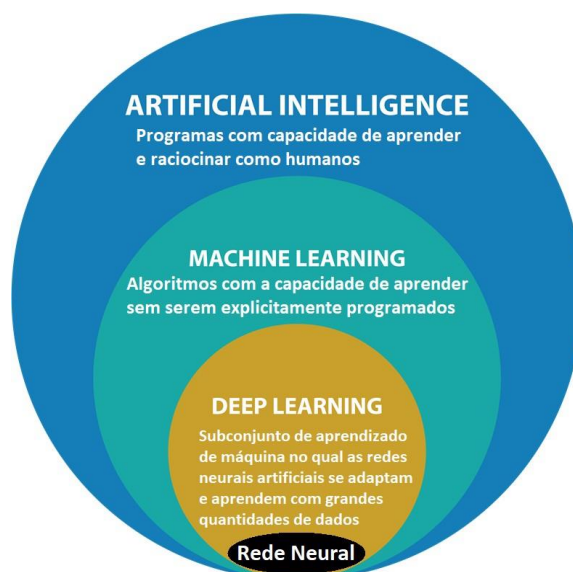
Os principais eventos da história da evolução da Inteligência Artificial podem ser citados cronologicamente como:

- Warren S. McCulloch e Walter Pitts (1943): A pesquisa teve como objetivo entender como o cérebro humano poderia produzir padrões complexos por meio de células cerebrais (neurônios). Uma das principais ideias foi a comparação entre neurônios com o limite binário para lógica booleana;
- Frank Rosenblatt (1958): Desenvolvimento do método Perceptron, levando o trabalho de Warren S. McCulloch e Walter Pitts um passo adiante. Utilizando um IBM 704, ele conseguiu fazer o computador aprender a distinguir cartas marcadas a esquerda de cartas marcadas à direita;

- Yann LeCun (1989): Publicou um artigo sobre como o uso de restrições na propagação retroativa na arquitetura de redes neurais podem ser utilizadas para treinar algoritmos. Essa pesquisa resultou em uma rede neural para reconhecer os dígitos de CEP escritos a mão fornecidos pelos EUA no serviço postal.

A Inteligência Artificial teve sua evolução baseada em duas grandes áreas de desenvolvimento tecnológico, o *Machine Learning* e o *Deep Learning*. Esses dois ramos estão dentro da esfera que compreende todo o ramo de Inteligência Artificial. A Figura 3.2 ilustra e exemplifica estas áreas:

Figura 3.2: Definição e caracterização do conceito de Inteligência Artificial, *Machine Learning* e *Deep Learning*.



FONTE: ARTIFICIAL INTELLIGENCE. PNG EGG, 2018. Disponível em <https://www.pngegg.com/en/png-tgvpc>. Acesso em 08 de dezembro de 2022.

A Figura 3.2 mostra a ideia básica sobre o conceito de Inteligência Artificial, e sua estrutura organizacional, mostrando que a rede neural representa o código base para sua existência.

3.1. *Machine Learning* (Aprendizado de Máquina)

O *Machine Learning* se refere a capacidade de uma máquina aprender sem a intervenção humana, ou seja, diferente da Inteligência Artificial Simbólica, ao invés de cada etapa ser explicitamente programada, o algoritmo é treinado com um banco de dados, e cria um modelo estatístico e determinístico, por meio de uma representação matemática (modelo) capaz de executar uma tarefa de previsão ou classificação, sem que seja programado algo no código. O ML foi descrito em 1959 pelo engenheiro do MIT Arthur Samuel e hoje é a principal técnica de IA utilizada, possibilitando a criação de tecnologias como Big Data e o surgimento de GPUs (*Graphic Processing Unit*, ou unidade de processamento gráfico), que permite que o processamento das máquinas seja mais rápido e mais barato em caso de processamento de elevada quantidade de dados.

3.2. *Deep Learning* (Aprendizagem Profunda)

O *Deep Learning* é um ramo de aprendizado de máquina (*Machine Learning*) baseado em um conjunto de algoritmos que tentam modelar abstrações de alto nível de dados usando várias camadas de processamento, compostas de várias transformações lineares e não lineares, de forma a realizar tomadas de decisão autônomas. O *Deep Learning* é a tecnologia base para ferramentas como o *Google Translate* (Google Tradutor) e a Cortana (assistente personalizado da Microsoft), por exemplo. Em suma, com enorme quantidade de poder computacional, as máquinas podem agora reconhecer objetos e traduzir voz em tempo real. O *Deep Learning*, portanto, torna finalmente a Inteligência Artificial de fato inteligente e aplicável.

3.3. Método de Rede Neural Artificial

As Redes Neurais Artificiais são técnicas computacionais, que apresentam um modelo matemático, baseado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência e treinamento. Diante disso, uma rede neural pode ter até milhares de unidades de processamento, lembrando neurônios. Em um breve histórico resumido sobre as Redes Neurais pode ser obtido por meio dos três trabalhos mais importantes já registrados sobre esta área: McCulloch e Pitts (1943), Hebb (1949), e Roseblatt (1958). Estas publicações introduziram o primeiro modelo de Redes Neurais simulando máquinas em funcionamento, sendo estas, o modelo básico de rede e auto-organização é o modelo Perceptron de aprendizado supervisionado. McCulloch e Pitts propuseram o primeiro modelo matemático para um neurônio artificial, Hebb (1949) propôs pela primeira vez um modelo de organização sináptica para neurônios e por último Roseblatt (1958), que o método matemático de Perceptron de aprendizado supervisionado, que foi a base para fundamentação da inteligência artificial aplicada a máquinas e equipamentos. Seu nome e estrutura são inspirados no cérebro humano, imitando a maneira como os neurônios enviam sinais uns para os outros. As Rede Neurais são formadas por subcamadas profundas, compostas por nós de ligação, possuindo uma camada de entrada, uma ou mais camadas ocultas (para processamento) e uma camada de saída de dados. Em geral, as Redes Neurais contam com dados de treinamento para aprendizado, o que faz com que os algoritmos sejam sempre afiados para precisão com o passar do tempo, em um *loop* infinito, que tende a zerar a margem de erros.

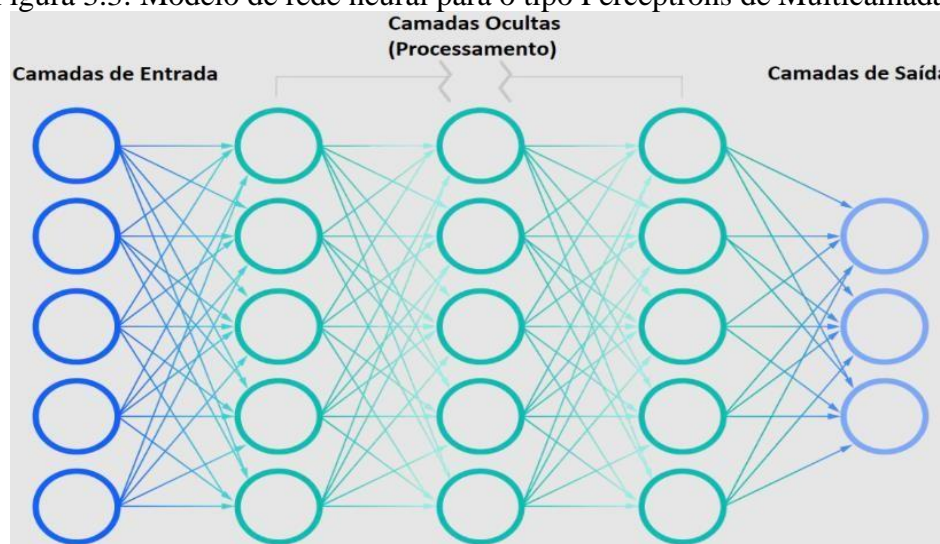
As Redes Neurais Artificiais foram criadas na década de 50, mas foram deixadas de lado devido à baixa capacidade computacional da época, o que tornava a resolução de problemas extremamente limitada. Isso mudou a partir da década de 90, quando o avanço tecnológico de *hardware* finalmente alcançou um patamar, em que tornou a aplicação prática das Redes Neurais possível. Essa evolução

foi possível porque as Redes Neurais são um formato de estrutura de dados inspirada nas redes de neurônios do cérebro humano.

3.4. Estrutura básica de uma rede neural

As Redes Neurais são construídas por meio de algoritmos de regressão linear, compostos por dados de entrada, processamento e dados de saída. As Redes Neurais podem ser classificadas em diferentes tipos, dentre as quais, a mais antiga e mais famosa é o Perceptron, criada por Frank Rosenblatt em 1958. Esse modelo foi aperfeiçoado em Perceptrons de Multicamadas (MLPs), compostas por uma camada de entrada, várias camadas ocultas de processamento e uma camada de saída. Os dados são alimentados nesta rede neural, e o algoritmo é treinado e ajustado conforme as iterações. A Figura 3.3 ilustra o modelo de Perceptrons de Multicamadas de uma rede neural.

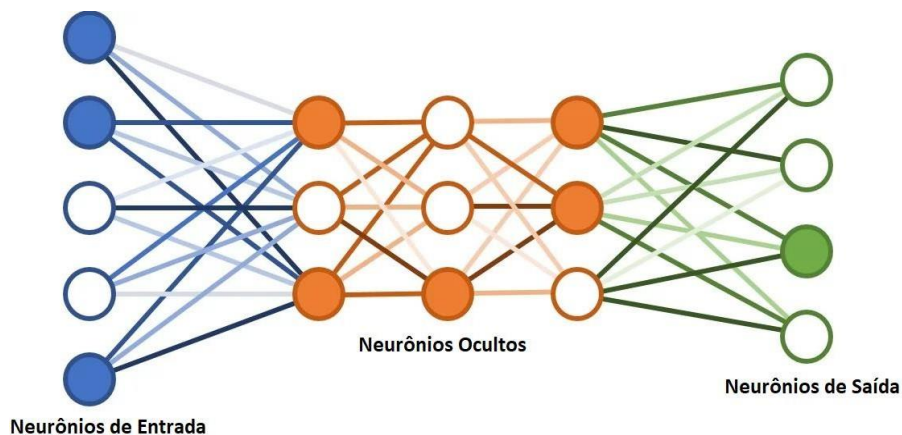
Figura 3.3: Modelo de rede neural para o tipo Perceptrons de Multicamadas.



FONTE: REDES NEURAIAS. IBM, 2020. Disponível em: <https://www.ibm.com/br-pt/cloud/learn/neural-networks>. Acesso em 10 de dezembro de 2022.

A Figura 3.4 ilustra uma rede neural com 5 entradas e 4 saídas, para exemplificar as ligações entre as entradas e saídas de um processo.

Figura 3.4: Esquema de Ligação esquemático que representa uma rede neural simples 5 entradas e 4 saídas.



FONTE: DEEP LEARNING. Programaria, 2020. Disponível em <https://www.programaria.org/inteligencia-artificial-tudo-que-voce-precisa-saber-para-comecar-a-explorar-esse-universo/>. Acesso em 08 de dezembro de 2022.

A quantidade de neurônios na camada oculta é uma variável que pode ser definida de diversas formas. A mais comum é a definida pelo método de Fletcher – Gloss (Silva et al., 2010), dado pela equação 3.1:

$$2 \cdot k^{\frac{1}{2}} + N_2 \leq N_1 \leq 2 \cdot k + 1 \quad (3.1)$$

Onde:

- **k**: Número de pontos de entradas de rede.
- **N₁**: Número de neurônios na camada oculta.
- **N₂**: Número de neurônios na camada de saída.

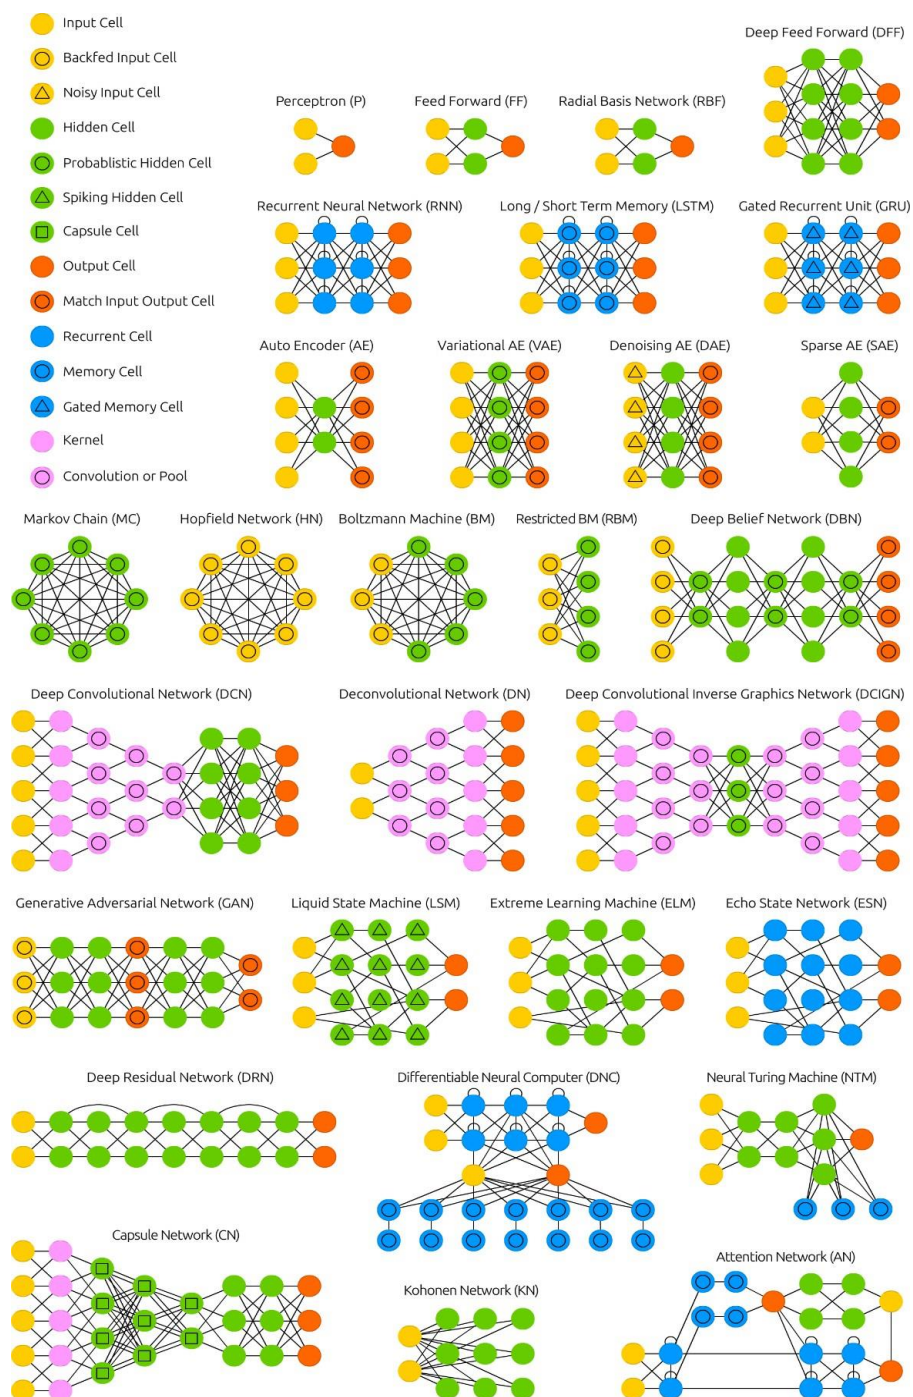
A Estrutura de uma rede neural pode ser apresentada como sendo uma sequência lógica de Retro Propagação de Erros (*Backpropagation*). O algoritmo de Retro Propagação de Erros segue a seguinte sequência:

- 1º Inicialização: Inicialize os pesos da rede aleatoriamente.
- 2º Processamento Direto: Apresente um padrão à rede. Realizar a ativação de todos os Neurônios e calcular o erro.
- 3º Passo Reverso: Calcular os novos pesos para cada neurônio, no sentido retroativo, camada por camada.
- 4º Teste de Parada: Teste o critério de parada adotado, se satisfeito, finalizar o algoritmo.

Por fim, as Redes Neurais possuem uma diversidade muito grande de modelos, sendo possível montar alguns diagramas esquemáticos que exemplificam os principais tipos. O instituto Asimov de

pesquisa e desenvolvimento em Inteligência Artificial criou um quadro bastante didático para ilustrar os tipos de Redes Neurais existentes, mostrado na Figura 3.5:

Figura 3.5: Quadro esquemático mostrando o esquema básico das Redes Neurais mais conhecidas.

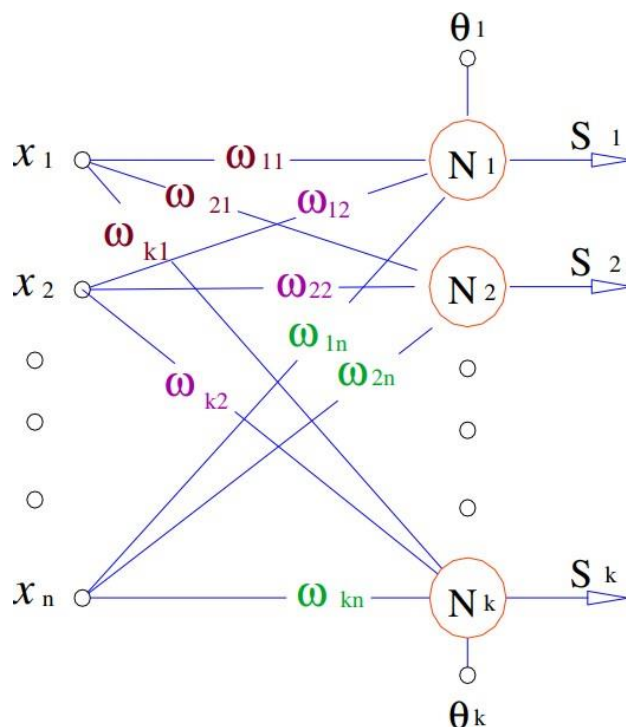


FONTE: THE NEURAL NETWORK ZOO. Instituto Asimov, 2016. Disponível em: <https://www.asimovinstitute.org/neural-network-zoo/>. Acesso em 05 de dezembro de 2022.

3.5. Algoritmo de uma rede neural

A arquitetura de uma rede neural pode ser modelada, de acordo com a Figura 3.6:

Figura 3.6: Esquema ilustrativo da arquitetura de uma rede neural.



Fonte: T. Rauber (1998)

Onde $x = [x_1, x_2, x_3, \dots, x_n]$ é a camada de entrada no sistema, e N_k representa o k – ésimo neurônio, ω_{jk} representa o peso do neurônio em relação à entrada x_j . Por fim, S_k representa a k – ésima saída. A função de sinapse é dada pela função de soma dos pesos, definida por Net_k , assim tem-se:

$$Net_k = \sum_{j=1}^p \omega_{jk} + \theta_k \quad (3.2)$$

A função de ativação da rede neural Perceptron é dada pelo degrau unitário, e sua saída S_j é dada por:

$$S_j = \begin{cases} 1, & \text{se } Net_j > 0 \\ 0, & \text{se } Net_j \leq 0 \end{cases} \quad (3.3)$$

Para o treinamento da rede neural, busca-se encontrar o conjunto de pesos que determine uma reta que separe as classes diferentes, de maneira que ela possa classificar corretamente as entradas. O algoritmo de aprendizado, pode ser escrito em função do erro calculado, em relação a saída desejada t_j :

$$e_j = t_j - S_j \quad (3.4)$$

Logo, a variação do peso $\Delta\omega_{jk}$ pode ser escrita, em função da taxa de aprendizado λ da seguinte

maneira:

$$\Delta\omega_{jk} = \lambda \cdot x_j \cdot e_j \quad (3.5)$$

A cada entrada nova, os pesos são atualizados com a seguinte regra:

$$\omega_{jk}^{t+1} = \omega_{jk}^t + \Delta\omega_{jk}^t \quad (3.6)$$

Aperfeiçoando o algoritmo, por meio do *Backpropagation*, tem-se:

$$\Delta\omega_{jk} = -\lambda \cdot \frac{\partial E}{\partial \omega_{jk}} \quad (3.7)$$

Onde E_q é o erro quadrático médio, dado pela seguinte expressão:


$$E_q = \frac{1}{2} \cdot \sum_p \sum_{j=1}^k (t_j^p - S_j^p)^2 \quad (3.8)$$

Por fim, o critério de parada, substituindo as equações, fica em função do erro absoluto:

$$e_j = \sum_k (e_k \cdot \omega_{jk}) \cdot \frac{\partial S_j}{\partial x} \quad (3.9)$$

A Figura 3.7 basicamente ilustra o funcionamento de um único neurônio de camada da rede neural, utilizando pesos sinápticos para processamento da função de ativação no processo de aprendizado.

Figura 3.7: Princípio de funcionamento do neurônio da rede neural.



FONTE: G.F. Oliveira, L. N. (2018)

Sua funcionalidade é formada pela camada de entrada, x_1, x_2, \dots, x_m , estes sinais são ponderados pelos pesos sinápticos $w_{k1}, w_{k2}, \dots, w_{kp}$, destes é realizada uma combinação linear, adicionada pelo valor de bias, b_k , o resultado dessa operação é o valor u_k , que é limitado por uma função de ativação

$\varphi(\cdot)$, que pode ser linear ou não. Adiciona-se um limiar φ_k e por fim gera-se a saída estimada pela rede neural, y_k (G.F. OLIVEIRA, L. N, 2018).

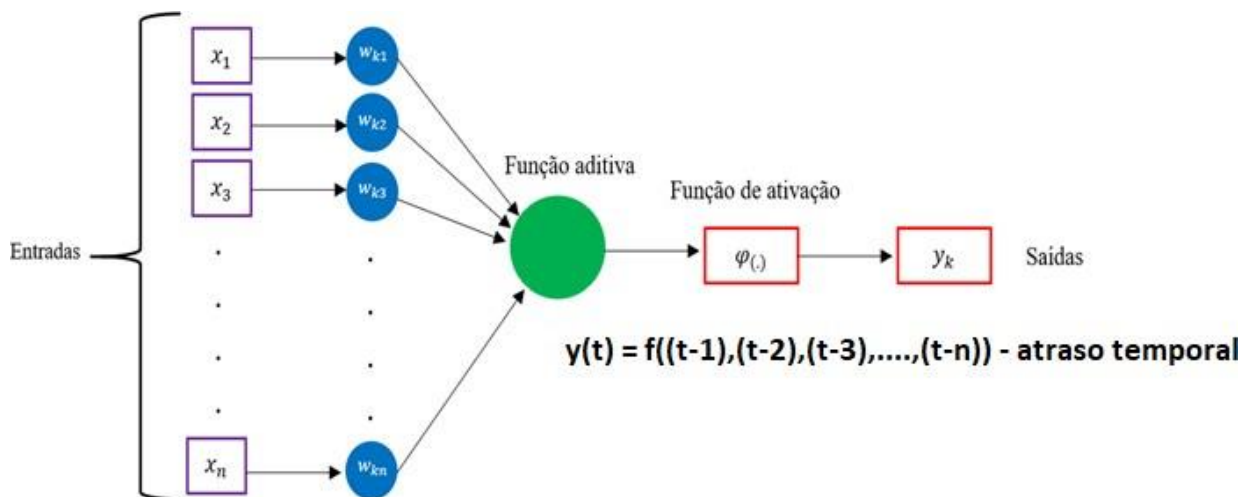
3.6. Redes Neurais Dinâmicas

Existem casos especiais de alguns problemas que não podem ser modelados utilizando sistemas estáticos e redes *feedforward*, como problemas que utilizam noção de temporalidade ou algum tipo de ordem no conjunto de dados de entrada. Os sistemas que solucionam esses problemas são chamados de sistemas dinâmicos, e operam por meio de redes neurais recorrentes. De forma geral, sistemas dinâmicos, ou redes neurais dinâmicas são topologias desenvolvidas para introduzir a inclusão de relações temporais no mapeamento de entradas e saídas de dados. Redes neurais dinâmicas, são usadas para filtragem e previsões não lineares. A previsão é um tipo de filtragem dinâmica, na qual os valores passados de uma ou mais séries temporais são usados para prever valores futuros.

Os modelos preditivos também são usados para identificação do sistema (ou modelagem dinâmica), na qual você constrói modelos dinâmicos de sistemas físicos. Esses modelos dinâmicos são importantes para análise, simulação, monitoramento e controle de uma variedade de sistemas, incluindo sistemas de manufatura, processos químicos, robótica e sistemas aeroespaciais.

O modelo proposto neste trabalho requer uma rede neural dinâmica recorrente com atraso no tempo devido ao comportamento não linear e dependente do tempo dos dados de aquisição (aceleração medida sobre a placa plana em função do tempo em cada posição), sendo definida por variações temporais para prever efeitos futuros. A Figura 3.8 mostra o princípio de funcionamento da Rede Neural adotada para o estudo neste trabalho:


Figura 3.8: Modelo base de uma rede neural dinâmica.



FONTE: Autoria Própria

Um exemplo prático é mostrado pelo autor Ivan Nunes, “Redes Neurais Artificiais para Engenharia e Ciências Aplicadas” (pag. 170, 2016). O exemplo dado tem o seguinte enunciado: Um grupo de pesquisadores estará tentando aplicar redes neurais artificiais a fim de prever o comportamento futuro deste processo. Assim, pretende-se utilizar uma arquitetura de PMC (*Multi Layer Perceptron*), com topologia *time delay neural network (TDNN)*, conforme ilustrado na Figura 3.9:

Figura 3.9: Topologia de PMC do exemplo.



FONTE: Ivan Nunes, pag. 170 (2016).

As topologias candidatas passíveis de serem aplicadas no mapeamento deste problema são especificadas pela Tabela 3.1:

Tabela 3.1: Tabela contendo a quantidade de entradas para a Variável TDNN.

VARIÁVEL	ENTRADAS	NEURÔNIOS NA CAMADA OCULTA
TDNN1	5	$N_1 = 10$
TDNN2	10	$N_2 = 15$
TDNN3	15	$N_3 = 25$

FONTE: Ivan Nunes, pag. 170 (2016).

Tais regras, embora ainda muito utilizadas, são apropriadas tão somente para alguns tipos de problemas bem-comportados, pois desconsideram atributos que são de fato muito relevantes para especificação topológica de redes neurais, tais como quantidade de dados, complexidade do problema, qualidade dos dados e disposição no espaço amostral. Segundo o matemático russo Kolmogorov (1903 – 1987), para casos em que a quantidade de dados e a complexidade do problema seja elevada, deve-se realizar uma análise de covariância dos dados para se chegar à quantidade de neurônios ideal.

Para o nosso caso, foi realizada uma análise estatística dos dados para o melhor ajuste do valor de correlação (R^2) dos dados, visto que o desvio padrão é igual a média para efeitos normalizados, o que impede a análise por covariância.

4. Análise Modal

O estudo do comportamento dinâmico de uma estrutura é essencial para se conhecer as suas características e funcionamento. Sabe-se que tendo em visto os crescentes avanços tecnológicos e a necessidade de resultados cada vez mais precisos e fiéis a realidade, a análise numérica deve ser complementada por um modelo experimental que torne válido todo o estudo realizado sobre a estrutura, de forma que o modelo numérico computacional, possa de fato ser uma representação mais próxima possível do real. Diante dessa metodologia, para completar tais modelos, é necessária uma análise modal do modelo experimental.

No âmbito da análise de vibração de estruturas por via experimental, existem dois métodos que se destacam: a Análise Modal Experimental (AME) e a Análise Modal Operacional (AMO). No trabalho de Allemang, R. J.; Brown, D. L (1982), é definido que a diferença principal entre os dois métodos é o tipo de excitação provocada no experimento. Segundo a AME, a excitação é conhecida e produzida artificialmente, sendo por norma, provocado por um gerador de sinais (*shaker*) ou martelo de impacto. Já a AMO, a excitação não é conhecida e é provocada pelo ambiente. Portanto, para estruturas de grande porte, a AMO é particularmente interessante, visto que não seria conveniente fabricar ou comprar um equipamento que provoque vibrações em estruturas grandes como prédios, aviões ou pontes. A grande importância da análise modal é a imprescindibilidade de se obter as propriedades modais de um sistema (frequências naturais, formas de vibração e razões de amortecimento).

4.1. Sistema de 1 grau de liberdade

Existem dois métodos de identificação dos parâmetros modais para sistemas com 1 grau de liberdade, que são:

- Método de Identificação dos Picos.
- Método do Círculo.

4.1.1. Método de Identificação dos Picos

É muito empregado em sistemas que apresentam modos bem separados e com algum amortecimento, podendo identificar parâmetros modais através dos picos presentes no gráfico da Função de Resposta em Frequência, este método, embora simples, ajusta bem os resultados a modelos com poucos graus de liberdade. Neste tipo de análise, os picos da FRF são deletados, e os diversos modos são isolados, localizando-se a frequência para a qual a FRF é máxima, sendo essa portanto a

frequência natural do estudo. O amortecimento é determinado pelo círculo de *Nyquist*, e por fim, é possível obter uma estimativa da constante modal do modo de vibrar associado a frequência estimada. É importante observar que só é possível obter constantes reais, o que gera modos reais, e com isso amortecimentos proporcionais.

4.1.2. Método do Círculo

A identificação dos parâmetros modais usando o método do círculo é realizado segundo a sequência:

- Determinar o número de pontos a serem utilizados (acima de 6).
- Determinar o círculo que melhor se ajusta aos pontos adotados (pelo método dos mínimos quadrados).
- Determinar a frequência em que ocorre a taxa de varrimento máxima (o que corresponde a frequência natural).
- Calcular os diversos valores de amortecimento, utilizando-se combinações entre os pontos selecionados.
- Determinar a magnitude e a fase da constante modal, através do raio e rotação do círculo relativos aos eixos real e imaginário.

Utilizando-se a FRF móvel, com amortecimento proporcional, pode-se escrever a Equação (4.1) para terminação das propriedades modais pelo método do círculo

$$Y_{jk}(\omega) = \sum_{r=1}^N i \cdot \omega \cdot \left[\frac{\Psi_{rj} \cdot \Psi_{rk}}{(k_r - \omega^2 \cdot m_r) + i \cdot (\omega \cdot c_r)} \right] \quad (4.1)$$

onde:

- $Y(\omega)$: Função de resposta em frequência de mobilidade.
- ω : Frequência natural.
- Ψ : Vetor modal do sistema não amortecido ou com amortecimento proporcional.
- M : Massa modal.
- k_r : Rigidez modal.
- c_r : Amortecimento modal.

4.2. Sistemas com múltiplos graus de liberdade

Os Sistemas de múltiplos graus de liberdade são extensões de sistemas de um grau de liberdade. De maneira geral, sistemas mecânicos necessitam de mais de uma coordenada para descrever seu movimento e vibração, e o resultado disso é um sistema de múltiplos graus de liberdade, caracterizado pelas matrizes de massa e rigidez. A equação do movimento livre para um sistema de múltiplos graus de liberdade é descrito como sendo uma equação de autovalores e autovetores:

$$([k] - \lambda^2 \cdot [M]) \cdot \psi = 0 \quad (4.2)$$

Onde as matrizes $[M]$ e $[k]$ (massa e rigidez, respectivamente) são simétricas. A solução da equação (4.2) é composta por “n” autovalores ω_r^2 e de “n” autovetores ψ_r^2 , onde r é o índice variando de 1 a n ($r = 1, 2, 3, 4, \dots, n$). A raiz quadrada destes autovalores são as frequências naturais do sistema e os autovetores são seus modos de vibrar.

4.3. Análise Modal Experimental

A análise modal experimental consiste em uma técnica onde um estímulo é gerado por meio de um martelo de impacto, e a resposta de vibração é obtida por um acelerômetro. Com base nos dois sinais é realizado o cálculo da FRF, e com isso definir os modos de vibração, as frequências naturais e os fatores de amortecimento da estrutura analisada. De acordo com Peeters, B.; De Roeck, G. (2001), a análise modal experimental apresenta como principal vantagem o fato de não ser uma análise destrutiva e se poder efetuar em condições próximas a realidade e com boa confiabilidade dos resultados obtidos.


De forma geral, o intuito da análise modal experimental é obter um modelo matemático do sistema em estudo, com o intuito de descrever com boa aproximação o comportamento dinâmico de uma estrutura em termos modais. São utilizadas curvas de FRF obtidas experimentalmente para descrever de forma indireta as propriedades modais de um sistema (PEETERS, B. 2001).

A metodologia mais comum consiste em excitar a estrutura e medir os sinais de força de excitação e os sinais de resposta de aceleração dos pontos avaliados do objeto. Existem erros e incertezas no processo, que são filtrados através de um modelo de identificação matemático para o sistema, como filtros de sinal. Os sinais de excitação e resposta são enviados a um analisador de sinais, que estima as FRF entre os pontos medidos, ou as Funções de Resposta ao Impulso (FRI) entre os mesmos pontos. O procedimento de análise modal experimental envolve várias fases, que podem ser classificadas como sendo:

- Abordagem do problema pela teoria da análise modal;
- Escolha do método de análise modal experimental;
- Escolha da forma de aquisição de parâmetros modais;
- Estimação de parâmetros modais e validação.

Estas condições são em grande parte uma função do número de canais de aquisição ou fontes de excitação que estão disponíveis, e geralmente a melhor situação de teste é o de configuração *Multi-Input/Multi-Output* (MIMO), pois os dados são recolhidos no menor tempo possível com o menor número de mudanças nas condições de teste. A Figura 4.1 mostra um exemplo de sistema MIMO.

Figura 4.1: Exemplo de modelo do sistema MIMO.



FONTE: Daniel dos Santos (2016).

Para a análise modal experimental, existem dois métodos de identificação dos parâmetros modais:

- Método Exponencial Complexo de Mínimos Quadrados.
- Método de Seleção de Pico.

A variável X_k representa as múltiplas entradas no sistema, e a variável $h_{k|k}$ representa uma estimativa das saídas já tratadas do sinal.

4.3.1. Método Exponencial Complexo de Mínimos Quadrados

O método exponencial complexo de mínimos quadrados calcula a resposta ao impulso correspondente a cada função de resposta em frequência e ajustada à resposta a um conjunto de senoides amortecidas complexas. Uma senoide amortecida pode ser moldada na forma:

$$S_i(n) = \sum_i A_i e^{j\phi_i} \exp\left(-\left(\frac{\omega_i}{f_s} - \frac{j\omega_i}{f_s}\right) \cdot n\right) + \sum_i A_i e^{j\phi_i} \exp\left(-\left(\frac{\omega_i}{f_s} + \frac{j\omega_i}{f_s}\right) \cdot n\right) \quad (4.3)$$

onde:

- f_s é a taxa de amostragem.
- f_i é a frequência senoidal.
- b_i é o coeficiente de amortecimento.
- n é o impulso para cada função de resposta.
- A_i e φ_i são a amplitude e a fase da senoide.

4.3.2. Método de Seleção de Pico

O método de seleção de pico assume que cada pico significativo na função de resposta de frequência corresponde exatamente a um modo natural. Perto de um pico, assume-se que o sistema se comporte como um oscilador harmônico amortecido de um grau de liberdade.

$$H(f) = -\frac{1}{(2.\pi)^2} \cdot \frac{1}{m} \cdot (1/(f^2 - j.\xi_r.f_r.f - f_r^2)) \quad (4.4)$$

Onde H é a função de resposta em frequência, f_r é a frequência de ressonância não amortecida e ξ_r representa o amortecimento relativo, m representa o tamanho da amostra considerada. Dado um pico localizado em f_p , variando-se de k até p (índice), o procedimento leva o pico e um número fixo de pontos para cada lado, substitui o termo de massa por uma variável fictícia d , e calcula os parâmetros modais resolvendo o sistema de equações:

$$\begin{bmatrix} H(f_{p-k}) & j.2.H(f_{p-k}) & -1 \\ \dots & \dots & \dots \\ H(f_p) & j.2.H(f_p) & -1 \\ \dots & \dots & \dots \\ H(f_{p+k}) & j.2.H(f_{p+k}) & -1 \end{bmatrix} \cdot \begin{bmatrix} f^2 \\ \dots \\ d \end{bmatrix} = \begin{bmatrix} f^2 \\ f^2.H(f_{p-k}) \\ \dots \\ f^2.H(f_{p+k}) \end{bmatrix} \quad (4.5)$$

4.4. Análise Modal Operacional

Análise modal quando é feita para verificação de um modo específico de vibração, em casos em que a força excitadora não é conhecida, a técnica é denominada análise modal operacional. A avaliação das FRF na identificação de parâmetros modais do sistema ocorre ao mesmo tempo em que é avaliado também o comportamento da estrutura a cada frequência ou a cada instante de tempo, obtendo-se também os modos de vibrar do sistema.

O modo operacional é a forma com que a estrutura vibra em determinada frequência sob forças de excitação, segundo Schwarz e Richardson (1999). Esses modos dependem das propriedades

físicas, geométricas, condições de contorno do sistema, forças e carregamentos externos. A estimação dos modos operacionais pode ser dada pela definição da função resposta em frequência:

$$\{X(\omega)\} = [H(\omega)].\{F(\omega)\} \quad (4.6)$$

Onde:

- $[H(\omega)]$: Matriz de FRFs.
- $\{X(\omega)\}$: Vetor de deslocamento no domínio da frequência.
- $\{F(\omega)\}$: Vetor força excitadora no domínio da frequência.
- ω : Frequência.

Se houver uma frequência natural ω_0 , o modo operacional para esta frequência será dado por:

$$\{MODO(\omega_0)\} = [H(\omega_0)].\{F(\omega_0)\} \quad (4.7)$$

A técnica de estimação de modos operacionais necessita de dois canais de medição simultânea e dos estimadores de FRFs. Elas possuem informações de amplitude e fase de cada sinal analisado em termos de aceleração, velocidade ou deslocamento em função da força de excitação. A fase é medida entre a resposta e a força excitadora.

Utilizando-se o método de Detecção de Picos, as frequências naturais são estimadas através dos picos dos autos espectros das respostas adquiridas, enquanto as formas modais são obtidas pela definição de direção, magnitude e sentido da amplitude modal. O método de identificação estocástica mais utilizado é o baseado na covariância das respostas de referência (SSI – COV/ref), e trata-se de uma reformulação de subespaços pela covariância, ambos propostos por Peeters e De Roeck (1999). Os dados de resposta dinâmica contêm informações que formam o que ele chama de modelo de espaço de estado, capaz de identificar o sistema estudado. Assim, o SSI-COV busca identificar um modelo estocástico de espaço de estado considerando apenas a resposta da estrutura. A partir das respostas dinâmicas obtidas experimentalmente, é possível obter as matrizes de covariância entre todas as saídas e as saídas de referência, através da Equação (4.8):

$$R_i^{ref} = E[y_{k+i}.y_k^{ref}] \in R^{l \times r} \quad (4.8)$$

Onde:

- l : é o número de sinais de resposta.
- R_i^{ref} : Matrizes de covariância.
- E : estimador matricial de covariância.
- r : o número de sensores de referência.


4.5. Critério de Garantia Modal: MAC (*Modal Assurance Criterion*)

O MAC indica se estimativa para os autovetores da matriz de rigidez do modelo possui boa qualidade, segundo uma faixa considerável aceitável. A comparação entre dois métodos através da correlação entre os modos de vibrar dos mesmos pode ser obtida por diferentes critérios, segundo Martins (2011) e Alves (2012). Segundo Allemang e Brown (1982), o mais conhecido é o MAC, representado pela Equação (4.14):

$$MAC_{ij} = \frac{|(\varphi \cdot R_i)^T \cdot \varphi_j|^2}{((\varphi \cdot R_i)^T \cdot \varphi \cdot R_i) \cdot ((\varphi \cdot A_j)^T \cdot \varphi \cdot A_j)} \quad (4.14)$$

Onde $\varphi \cdot R_i$ é o i -ésimo modo de vibração de referência e $\varphi \cdot A_j$ é o j -ésimo modo de vibração do modelo calculado. A correlação do modo de vibrar é considerada boa quando o valor se aproxima de 1 (um), e uma má correlação ocorre quando o valor se aproxima de 0 (zero). Quando um modelo em estudo está perfeitamente correlacionado, os valores da diagonal da matriz MAC se aproximam de um, enquanto os valores fora da diagonal se aproximam de zero. A Figura 4.2 ilustra um gráfico MAC de correlação entre modos:

Figura 4.2: Ilustração do gráfico MAC.



FONTE: Vale (1996).


4.6. Viga de Euler Bernoulli

As teorias de viga começaram a ser estudadas a partir do século XVII, segundo Timoshenko (1953). Em meados do século XVIII, Bernoulli e Euler apresentaram trabalhos que podem ser considerados o limiar da teoria geometricamente não linear para vigas com material elástico linear. Para pequenas dimensões o modelo de Euler é o mais adequado, pois o cisalhamento e a inércia de rotação são desprezados, e pressupõe-se que as seções transversais permanecem sempre planas e perpendiculares ao eixo longitudinal da viga, após sua deformação. O plano de vibração deve ser o

mesmo plano da seção transversal da viga, de maneira que a rotação e a translação sejam desconsideradas.

Para vibrações em modelos de viga na direção perpendicular à linha neutra, tem-se flexão, ou vibrações transversais, pois elas se movem ao longo do comprimento da viga. É adotada também a premissa de pequenas deformações, os efeitos dos esforços cortantes sobre a deflexão lateral são desprezados e a viga possui características isotrópicas. A Figura 4.3 mostra o modelo de viga arbitrário:

Figura 4.3: Modelo de viga genérico com carregamento vertical.



FONTE: Adriano Shineyder et al (2018)

O modelo de Euler – Bernoulli estabelece que a curvatura de uma viga elástica em qualquer ponto é correlatada ao momento fletor interno que atua naquele ponto. Desta forma, realizando o equilíbrio estático entre as forças inerciais e tendências rotacionais, é possível escrever a Equação (4.15) para o modelo dinâmico:

$$c^2 \cdot \frac{\partial^4 w(x, t)}{\partial x^4} + \frac{\partial^2 w(x, t)}{\partial t^2} = \frac{f(x, t)}{\rho \cdot A} \quad (4.15)$$

Onde o valor c é:

$$c = \sqrt{\frac{E \cdot I}{\rho \cdot A}} \quad (4.16)$$

Onde:

- $w(x, t)$: deflexão da viga.
- $f(x, t)$: carga externa.
- E : módulo de elasticidade.

- I : momento de inércia da seção transversal.
- ρ : densidade do material.
- A : área da seção transversal.
- x : variável espacial.
- t : variável temporal.

A Equação (4.15) pode ser caracterizada como sendo o balanço de forças, contendo variáveis temporais e espaciais, induzindo a imposição de condições iniciais e de contorno ao sistema. Considerando-se a Figura 4.3, em cada extremidade da viga há duas condições de contorno que dependem do tipo de vinculação, podendo ser apoiada, engastada ou livre. As condições de contorno podem ser resumidas na Tabela 4.1:

Tabela 4.1: Condições de contorno para viga.

VARIÁVEL	Condição em cada Extremidade		
	LIVRE	APOIADA	ENGASTADA
Esforço cortante (V)	Zero	-	-
Momento Fletor (M)	Zero	Zero	-
Inclinação (θ)	-	-	Zero
Deslocamento (w)	-	Zero	Zero

FONTE: Autoria Própria

Com as condições mostradas na Tabela 4.1, pode-se resolver o problema de valor inicial referente à parte espacial da Equação (4.15), visto que o esforço cortante, momento fletor e a inclinação são grandezas relacionadas ao deslocamento vertical, como mostrado nas Equações (4.17) a (4.19):

$$V(x, t) = -E \cdot I \cdot \frac{\partial^3 w(x, t)}{\partial x^3} \quad (4.17)$$

$$M(x, t) = -E \cdot I \cdot \frac{\partial^2 w(x, t)}{\partial x^2} \quad (4.18)$$

$$\theta(x, t) = E \cdot I \cdot \frac{\partial w(x, t)}{\partial x} \quad (4.19)$$

Além dessas condições, são necessárias duas condições iniciais: deslocamento vertical (w) e a velocidade (v) desse deslocamento no tempo inicial. Essas variáveis são representadas pelo termo de forças de inércia no balanço de forças (derivada parcial de segunda ordem da Equação (4.15)), e são relacionadas pela Equação (4.20):

$$v(x, t) = \frac{\partial w(x, t)}{\partial t} \quad (4.20)$$

A solução analítica do modelo de viga dinâmica é realizada através do Método de Separação de Variáveis, o qual propõe o produto de duas funções, sendo uma relativa a posição espacial x denotada por $w(x)$ que representa o modo de vibração, e outra dependente de t , denominada $T(t)$, como mostrado na Equação (4.21):

$$w(x, t) = \sum_{n=1}^{\infty} w_n(x) \cdot T_n(t) \quad (4.21)$$

Esta equação possui grande significado conceitual, uma vez que a sobreposição de respostas harmônicas para vários modos de vibração resulta na formação da deflexão pontual da viga. Portanto, todo problema de vibrações necessita de solução de uma equação de autovalores, que resultam nas frequências naturais de vibração do sistema, representadas por ω_n , que é capaz de determinar cada modo de vibração w_n . A técnica de separação de variáveis permite dividir a equação diferencial parcial em duas diferenciais ordinárias em Função do espaço e do tempo, como mostrados na Equação (4.22):

$$\frac{c^2}{w_n(x)} \cdot \frac{d^4 w_n}{dx^4} = -\frac{1}{T_n(t)} \cdot \frac{d^2 T_n}{dt^2} = \omega_n^2 \quad (4.22)$$

Assim, tem-se as Equações (4.23) e (4.24) para as frequências naturais e para a variável auxiliar β_n :

$$\omega_n = (\beta_n \cdot L) \cdot \sqrt{\frac{E \cdot I}{\rho \cdot A \cdot L^4}} \quad (4.23)$$

$$\beta_n^4 = \frac{\omega_n^2}{c^2} \quad (4.24)$$

A solução da Equação (4.22) envolve equações diferenciais ordinárias com soluções generalizadas. A Equação (4.24) mostra as equações em função das condições de contorno que são impostas ao problema genérico, determinadas a partir de condições iniciais impostas ao caso:

$$w_n(x) = C_1 \cdot \cos(\beta_n \cdot x) + C_2 \cdot \sen(\beta_n \cdot x) + C_3 \cdot \cosh(\beta_n \cdot x) + C_4 \cdot \sinh(\beta_n \cdot x) \quad (4.25)$$

$$T_n(t) = A_n \cdot \cos(\omega_n \cdot t) + B_n \cdot \sen(\omega_n \cdot t) + \frac{1}{\rho \cdot A \cdot b(x) \cdot \omega_n} \cdot \int_0^t Q_n(r) \cdot \sen(\omega_n \cdot (t - r)) \quad (4.26)$$

Onde as variáveis $Q_n(t)$ e B_n são descritas como sendo:

$$Q_n(t) = \int_0^L f(x, t) \cdot w_n(x) \cdot dx \quad (4.27)$$

5. MATERIAIS E METODOLOGIA

5.1. Materiais

5.1.1. Túnel de vento

O túnel de vento em que serão realizados os experimentos da AMO é o modelo AA-TVSH2 do tipo subsônico de circuito aberto, sugador, montado em bancada metálica móvel, possuindo comprimento total de 6,2 m. A imagem do túnel de vento é mostrada na Figura 5.1.

Figura 5.1: Túnel de vento mostrando a entrada de ar (1), região de ensaios (2), difusor (3) e o motor de sucção (4).




FONTE: Adaptado de Flávia de Melo, 2020

Na Figura 5.1, a seção 1 mostra a entrada de ar, de dimensões 1,0 m x 1,0 m que é seguida da seção de contração com razão de 4,7:1. A seção 2 é a região de ensaios do tipo fechada, com seção transversal quadrada de dimensões 0,46 m x 0,46 m x 1,20 m. A seção 3 é o difusor, com comprimento de 2,70 m e área de seção quadrada de 0,46 m x 0,46 m e área com seção circular na saída de 0,85 m de diâmetro. A seção 4 mostra o motor com hélice de 9 pás, trifásico, tensão de 220 v e potência de motor de 12,50 cv de baixa rotação (4 polos) até 1.760 rpm. Essas características tornam o túnel de vento capaz de fornecer um escoamento com velocidade nominal de até 37,0 m/s na seção de testes.

5.1.2. Viga engastada

O experimento foi definido tendo como modelo de estudo uma viga de alumínio com 300 mm x 19 mm x 3 mm para realização do estudo. A Figura 5.2 ilustra o modelo de viga e as posições onde foram instalados os acelerômetros.


Figura 5.2: Posicionamento dos acelerômetros.



FONTE: Autoria Própria.

A Figura 5.3 mostra a viga instrumentada já na posição para realizar o ensaio com o martelo de impacto.


Figura 5.3: Viga na posição de ensaio.



FONTE: Autoria Própria.

Foi realizada uma avaliação analítica do modelo de viga adotado para se ter a referência teórica de valores de frequência e modos, obtendo-se as frequências naturais de vibração e os modos de vibrar mostrados na Figura 5.4.

Figura 5.4: Frequências naturais e modos de vibrar do modelo analítico.



FONTE: Autoria Própria.

5.1.3. Sistema de Aquisição

Para mensurar os sinais de vibração da viga são utilizados acelerômetros da marca *Briuel & Kjaer*, modelo 4516, um de sensibilidade $1,065 \cdot 10^{-3} \text{mv/ms}^2$ e o outro de sensibilidade $1,073 \cdot 10^{-3} \text{mv/ms}^2$, ambos com amplitude de 10% de medição de frequência. Os dois acelerômetros possuem massa de 1,5 g, sendo recomendado para medir a vibração ao longo da viga proposta no trabalho devido a sua menor massa, e também é utilizado outro acelerômetro para mensurar a vibração na base da viga. A Tabela 5.1 mostra as especificações técnicas dos acelerômetros utilizados.


Tabela 5.1: Dados técnicos dos acelerômetros utilizados.

Sensibilidade da Voltagem	$10 \pm 10\%$
Faixa de medição	$\pm 500 \text{ G}$ (aceleração da gravidade)
Faixa de frequência	1 – 20.000 Hz
Sensibilidade acelerômetro B&K	$1,065 \cdot 10^{-3} \text{ mv/ms}^2$
Sensibilidade acelerômetro PCB	$1,073 \cdot 10^{-3} \text{ mv/ms}^2$
Massa acelerômetro 1	1,5 g
Massa acelerômetro 2	1,5 g
Frequência de Ressonância (igual para ambos)	40 kHz

FONTE: Ficha técnica do acelerômetro. Disponível em: <https://www.bksv.com/pt>.

A Figura 5.5 mostra os dois acelerômetros utilizados.

Figura 5.5: Acelerômetros B&K, modelo 4516, utilizados nas medições.



FONTE: Aatoria Própria.

Em conjunto aos acelerômetros decidiu-se mensurar a força de reação normal no engaste da viga, para tanto foi utilizado a célula de carga da PCB Piezotronics, modelo 201B02. Este sensor de força (célula de carga) incorpora um amplificador microeletrônico integrado que serve para converter a saída de carga de alta impedância em um sinal de tensão de baixa impedância para análise ou registro. Este sensor é projetado para medir forças de compressão e impacto de uma fração de 1 lbf (1 N) a 50.000 lbf (a 22,4 kN). A superfície de detecção plana localizada na parte superior do sensor é projetada para medir uma força dinâmica rapidamente aplicada axialmente ao sensor. A Figura 5.6 mostra a célula de carga utilizada.

Figura 5.6: Célula de carga PCB, modelo 201B02, utilizados nas medições.



FONTE: Aatoria Própria.

Para captação dos sinais foi utilizada uma placa de aquisição da marca National Instruments, modelo NI 9234, cujas especificações são mostradas na Tabela 5.2.

Tabela 5.2: Dados técnicos da placa de aquisição.

Número de Canais:	4 analógicos
Resolução ADC:	24 bits
Tipo de ADC:	Delta - Sigma
Modo de Amostragem:	Simultânea
Tipo de TEDS suportada:	IEEE 1451.4 TEDS Class I
Frequência:	13,1072 MHz
Precisão:	± 50 ppm max
Amplitude de Entrada:	± 5 V
Faixa de tensão de modo comum (AI- para terra):	± 2 V

FONTE: Ficha técnica do conversor. Disponível em: <https://lp.jav.com.br/national-instruments/>.

A Figura 5.7 mostra a placa utilizada.

Figura 5.7: Placa de aquisição, NI 9234 utilizada.



FONTE: Autoria Própria.

A placa de aquisição por sua vez foi conectada em a notebook, onde por intermédio de um código realizado em Matlab, foi realizada a configuração dos parâmetros de aquisição, tais como a sensibilidade dos acelerômetros (já mostradas na Tabela 5.1), número de pontos (12.800), número de amostras (3), tipos de médias (móvel).

O Martelo de impacto utilizado foi o da PCB Piezotronics, modelo 086C03, com sensibilidade de $2,25$ mV/N . A Figura 5.8 mostra o martelo de impacto utilizado.

Figura 5.8: Martelo de impacto utilizado.



FONTE: Autoria Própria.

5.2. Metodologia

5.2.1. Análise Modal Experimental (AME)

A análise modal experimental é realizada com o uso de uma excitação impulsiva aplicada por um martelo de impacto para determinação das características modais da viga. A amostra é fixada a uma mesa de ensaios e a uma célula de carga. Um acelerômetro é posicionado também em várias posições ao longo da viga, que então é estimulada através do impacto do martelo em diversas posições ao longo do seu comprimento. A viga foi dividida em 6 partes igualmente espaçadas, e o acelerômetro e ponto de estímulo foram variados ao longo de todas as posições.

A frequência de aquisição foi de 12.800 Hz, foram realizadas 30 medições em cada ponto de aplicação do acelerômetro e aplicação do martelo, configurando 1080 medições. Na análise modal experimental, para excitação da viga na análise modal experimental, onde a resposta deve ser conhecida, é utilizado um martelo de impacto. O Martelo de impacto utilizado é um Impulse Hammer w/force, modelo 086D20, com sensibilidade de $2,25 * 10^{-3} mV/N$. A Tabela 5.3 mostra o resumo do experimento de estudo da AME a ser adotado.

Tabela 5.3: Metodologia da AME.

Fator	Posições do Acelerômetro (mm)	Posições do Estímulo via Martelo de Impacto
Nível	0 60 120 180 240 300	0 60 120 180 240 300
Réplicas	3 réplicas	

FONTE: Autoria Própria

A Figura 5.9 ilustra a Viga ao lado do Martelo de Impacto:

Figura 5.9: Viga e Martelo de Impacto.



FONTE: Autoria Própria.

5.2.2. Determinação das velocidades de escoamento do túnel de vento

A avaliação do perfil de velocidades no interior do túnel de vento é necessária para se avaliar as velocidades onde a execução do experimento seja mais fiel possível, sem que haja influência de características do equipamento, visando a comparação entre os valores de *set point* e os valores obtidos pelo tubo de Pitot em diversas posições, de forma que seja possível a avaliação da viga engastada nessas posições.

A metodologia experimental foi definida com base no perfil de velocidades gerado no interior do túnel de vento. A aquisição de dados foi realizada para as velocidades de 2,5 m/s, 5 m/s, 7,5 m/s, 10 m/s, 12,5 m/s, 15 m/s, 17,5 m/s, 20 m/s e por último 22,5 m/s. Para isso, a seção transversal do túnel de vento foi dividida em 9 intervalos de 50 mm em 50 mm, totalizando 10 pontos de medição, onde será posicionado o tubo Pitot para medição da velocidade do vento. O tubo de Pitot instrumentado no túnel de vento realiza a aquisição dos dados de gradiente de pressão gerados pelo escoamento do vento, e estes são convertidos para velocidade através da Equação (5.1):

$$v = \sqrt{\frac{2 \cdot \Delta P}{\rho}} \quad (5.1)$$

Onde:

- ΔP : Diferença de pressão obtida no tubo Pitot.
- ρ : Densidade do ar.

A Tabela 5.4 mostra o resumo da metodologia de estudo do perfil de velocidades que será adotado no estudo, mostrando a quantidade de réplicas a serem realizadas para determinação das velocidades ótimas de estudo:


Tabela 5.4: Método de avaliação do perfil de velocidades do túnel de vento.

Fator	Velocidade (m/s)	Posição do Pitot (mm)
Nível	2,5 5,0 7,5 10 12,5 15 17,5 20 22,5	0 50 100 150 200 250 300 350 400 450
Réplicas	3 réplicas	

FONTE: Autoria Própria.

A Figura 5.10 ilustra o Tubo de Pitot nas posições:


Figura 5.10: Tubo de Pitot dentro do túnel de vento.



FONTE: Autoria Própria.

As velocidades de *set point* do vento comparados com os valores mensurados pelo tubo de Pitot, e os resultados são mostrados graficamente na Figura 5.11:

Figura 5.11: Perfil de velocidades no túnel de vento.



FONTE: Autoria Própria.

Pelos gráficos obtidos, observa-se que na Figura 5.11 foi observado que a velocidade obtida no tubo de Pitot é bem próxima da velocidade de set point ensaiada no túnel de vento para todas as alturas de medição na faixa entre 10 e 20 m/s, logo é recomendado que o experimento seja conduzido dentro dessas velocidades:

- 10 m/s.
- 12,5 m/s.
- 15 m/s.
- 17,5 m/s.
- 20 m/s.

5.2.3. Análise Modal Operacional (AMO)

Foram utilizados dois acelerômetros para a instrumentação da viga de alumínio, fixados por meio de cera de abelha à superfície da viga. Para o experimento, manteve-se um dos sensores fixo na posição de 300 mm da viga (no topo), e o outro acelerômetro teve sua posição variada em outros 5 pontos com espaçamentos de 60 mm entre cada posição ao longo do experimento. Após a instrumentação do modelo, o corpo de prova foi submetido às velocidades variadas.

Para a AMO, a variável de saída obtida pelos acelerômetros é a amplitude de aceleração. Foram realizados 5 experimentos para verificação da estabilidade do sistema durante as medições, e os sensores de medição foram posicionados em 6 posições diferentes.

Para estabilizar as medições no conversor, um dos sensores foi fixado (posição de 300 mm) e o outro sensor teve sua posição variada em 5 posições (de 60 mm em 60 mm) e para 5 velocidades diferentes. Dessa forma, foram realizadas 5 réplicas de cada medição de forma a tornar aleatória as medições dos dados e cobrir a faixa de medição para as velocidades determinadas no ensaio. A Tabela 5.5 mostra o resumo do experimento de estudo da AMO a ser adotado.

Tabela 5.5: Metodologia da AMO.

Fator	Velocidade (m/s)	Posição do Acelerômetro (mm)
Nível	10 12,5 15 17,5 20	0 60 120 180 240 300
Réplicas	5 réplicas	

FONTE: Autoria Própria

A Figura 5.12 mostra a viga instrumentada dentro do túnel de vento.

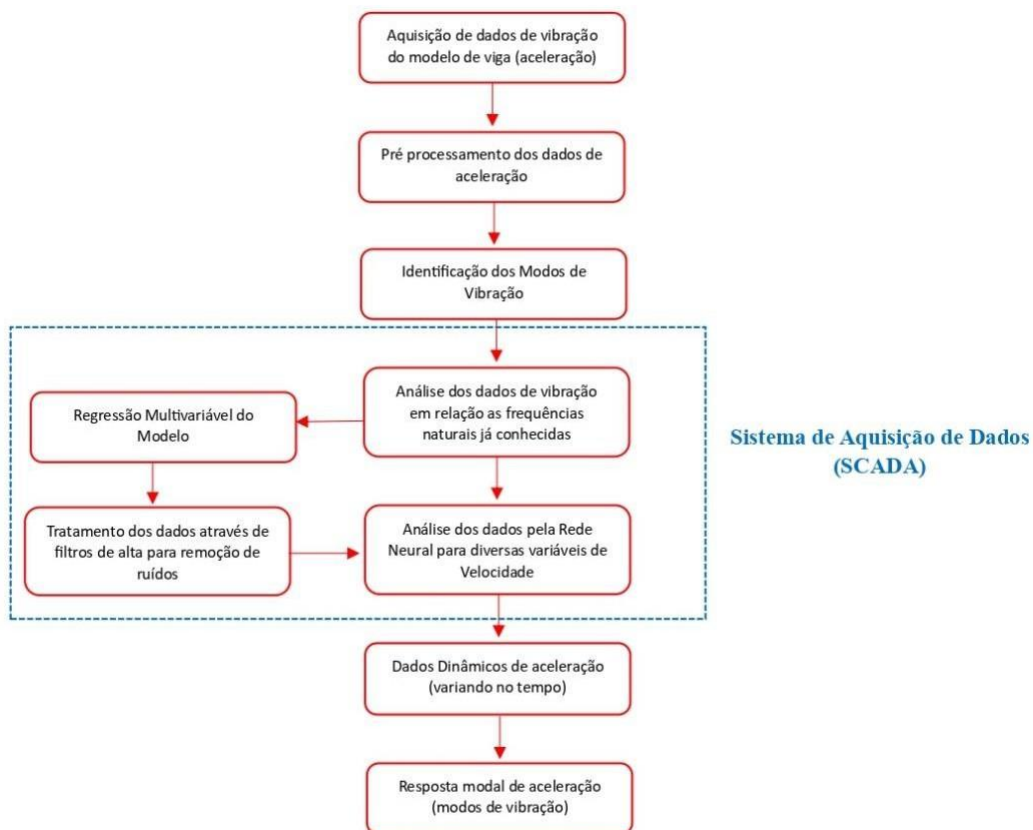
Figura 5.12: Viga instrumentada dentro do túnel de vento.



FONTE: Autoria Própria.

Em sequência, é utilizada uma rede neural artificial, treinada com os dados obtidos, aplicando-se o conceito do sensor virtual para possibilitar a aplicação da AMO no modelo de viga adotado. A Figura 5.13 mostra o fluxograma do sistema implementado.

Figura 5.13: Fluxograma do sistema implementado na análise modal estrutural do modelo de viga.



FONTE: Autoria Própria.

5.2.4. Determinação do sensor virtual por Rede Neural Dinâmica

A configuração ideal para uma rede neural é uma tarefa complexa, e que exige testes sucessivos de dados até se determinar a melhor configuração possível. Para isso, alguns itens foram definidos de antemão para construir a arquitetura da rede neural:

a) Quantidade de entradas

Foi definida uma entrada para o modelo adotado: Altura em relação a base (subdivisões de altura). A velocidade foi variada de 10 m/s até 20 m/s (foi realizada uma rede neural para cada velocidade), enquanto a altura de medição em relação a base foi detalhada em 6 subdivisões de aplicação de sensores reais para mapear as características físicas da viga e implementar os sensores virtuais no modelo. Isto é, a rede neural vai utilizar como entrada a altura apenas para modelar os sensores virtuais para cada altura, ou seja, serão 5 redes neurais, uma para cada velocidade, para a realizar a análise do acelerômetro em cada posição da viga.


b) Quantidade de Saídas da rede neural

A saída é única, cada rede neural vai calcular a resposta dinâmica da aceleração para um determinado ponto específico, configurando o sensor virtual naquele ponto.

c) Estrutura Final da Rede Neural

A Configuração final da Rede Neural adotada é mostrada na Figura 5.14:

Figura 5.14: Arquitetura da Rede Neural adotada.



FONTE: Autoria Própria.

A rede neural foi treinada pelo método Levenberg-Marquardt, que é considerado o mais rápido dos algoritmos de treinamento retro propagação do erro, porém requer mais memória computacional. Trata-se de um método numérico que procura o mínimo local em uma função e converge mais rapidamente do que um algoritmo genético para problemas não lineares.

A rede neural foi estruturada de acordo com alguns parâmetros, que são resumidos na Tabela 5.6:

Tabela 5.6: Topologia da Rede Neural adotada.

Arquitetura	Dynamic Nonlinear input-output
Tipo de treinamento	Supervisionado
Velocidades de Análise	10 m/s 12,5 m/s 15 m/s 17,5 m/s 20 m/s
Número máximo de camadas ocultas	1
Arquitetura (entrada – oculta – saída)	1 – 10 - 1
Atraso temporal da Rede neural Dinâmica	15
Algoritmo de treinamento	<i>Error back-propagation</i> e Levenberg-Marquardt.
Função de ativação da camada oculta	Tangente Hiperbólica
Função de ativação da camada de saída	Função Linear

FONTE: Autoria Própria.

Foi utilizado o algoritmo de treinamento da Retro Propagação de Erros ou *Error back-propagation*, sendo este o algoritmo mais utilizado em arquiteturas *Dynamic Nonlinear input-output*. A otimização deste algoritmo de Retro Propagação de Erros foi realizada por meio do algoritmo Levenberg-Marquardt. A função de desempenho foi definida como o Erro Quadrático Médio, e realizou-se a inicialização dos pesos sinápticos em zero, logo as matrizes de pesos não devem convergir para um certo patamar em caso de múltiplos treinamentos. Observando-se os efeitos do sobre ajuste (*overfitting*), foi selecionado o método de validação cruzada, ao impor a divisão dos pares de entradas e saída de treinamento nos subconjuntos de:

- Treinamento: 70% dos dados. Estes dados são apresentados à rede durante o treinamento, e a rede é ajustada de acordo com seu erro.
- Validação: 15% dos dados. Estes dados são usados para medir a generalização da rede e para interromper o treinamento quando a generalização parar de melhorar.
- Testes: 15% dos dados. Estes dados não têm efeito no treinamento e, portanto, fornecem uma medida independente do desempenho da rede durante e após o treinamento.

Para o critério de parada, a função de desempenho do tipo Erro Quadrático Médio é aplicada em cada etapa do treinamento da Rede Neural. A fase de treinamento é dada como concluída quando um dos seguintes critérios forem atendidos:


- Tempo máximo de computação atingir o valor de 10 minutos (sobre os dados de treinamento).
- EQM atingir o valor de desempenho de 0 (sobre os dados de treinamento).
- Evolução incremental do gradiente atinja o valor de 10^{-6} (sobre os dados de treinamento).
- Número de interações de treino atinja 10^6 (sobre os dados de treinamento).
- O número de testes de validação alcance 6 respostas positivas (sobre os dados de validação).

Após o treinamento, a certificação e visualização foram aferidas pelo valor do coeficiente de correlação (R^2) sobre os dados de teste, determinado entre o valor estimado na Rede Neural e o valor de referência tomado como alvo de treinamento. O código utilizado para implementação da rede neural está disponível no Apêndice, junto aos dados utilizados para a análise e implementação dos sensores virtuais.

6. RESULTADOS

6.1. Resultados da Análise Modal Experimental (AME)


Foi realizada a conversão dos dados obtidos do domínio do tempo para o domínio da frequência a partir da *Fast Fourier Transform* (FFT) entre martelo de impacto e acelerômetro, a fim de se observar os picos no domínio da frequência. Teoricamente, a ordem de um sistema n é definida pelo número de valores singulares da matriz Toeplitz diferente de zero. Assim, os polos correspondentes a um modelo de certa ordem são comparados com os polos de um modelo de ordem menor, e o polo é dito estável quando as diferenças entre as frequências, as taxas de amortecimento e os modos de vibrar estiverem dentro de limites pré-determinados. Schanke (2015) explica que o objetivo do diagrama de estabilização é separar os polos físicos, que são estáveis, dos polos provenientes dos ruídos externos, que não são estáveis. O alinhamento de polos estáveis identifica os modos de vibração. O gráfico de estabilização para o experimento realizado é mostrado na Figura 6.1.



FONTE: Autoria Própria.

A Figura 6.1 mostra as 4 primeiras frequências de vibração da viga, que foram identificadas nos valores de 25, 165, 450 e 900 Hz. Os modos de vibrar (normalizados) da viga são mostrados (em relação a referência, linha na cor preta) na Figura 6.2:


Figura 6.2: Modos de vibrar da viga pela análise modal experimental.



FONTE: Autoria Própria.

Os modos de vibrar mostrados na Figura 6.2, mostram que a forma geral da viga segue a teoria, porém o formato mostrado é incoerente, devido aos picos lineares gerados pelas retas que legam os pontos dos acelerômetros. Na Figura 6.3 são mostrados os valores de correlação para os modos de vibração.

Figura 6.3: Valores de correlação para os modos de vibrar da AME.



FONTE: Autoria Própria.

A diagonal principal do gráfico, mostrada na Figura 6.3, evidencia a solução independente das formas modais associadas às frequências naturais da viga. De outra forma, o coeficiente de correlação dos modos para as frequências naturais está superior à 90%, o que é um ótimo resultado.

Em sequência, de posse das frequências naturais e os modos de vibrar da viga, obteve-se na Tabela 6.1 as razões de amortecimento para cada frequência natural.

Tabela 6.1: Amortecimentos em função da frequência natural obtida pela AME.

FREQUÊNCIA	RAZÃO DE AMORTECIMENTO MODAL
25,99 Hz	0,0067
162,08 Hz	0,0159
451,01 Hz	0,0030
890,53 Hz	0,0023

FONTE: Autoria Própria.


As razões de amortecimento em geral, diminuem com o aumento da frequência.

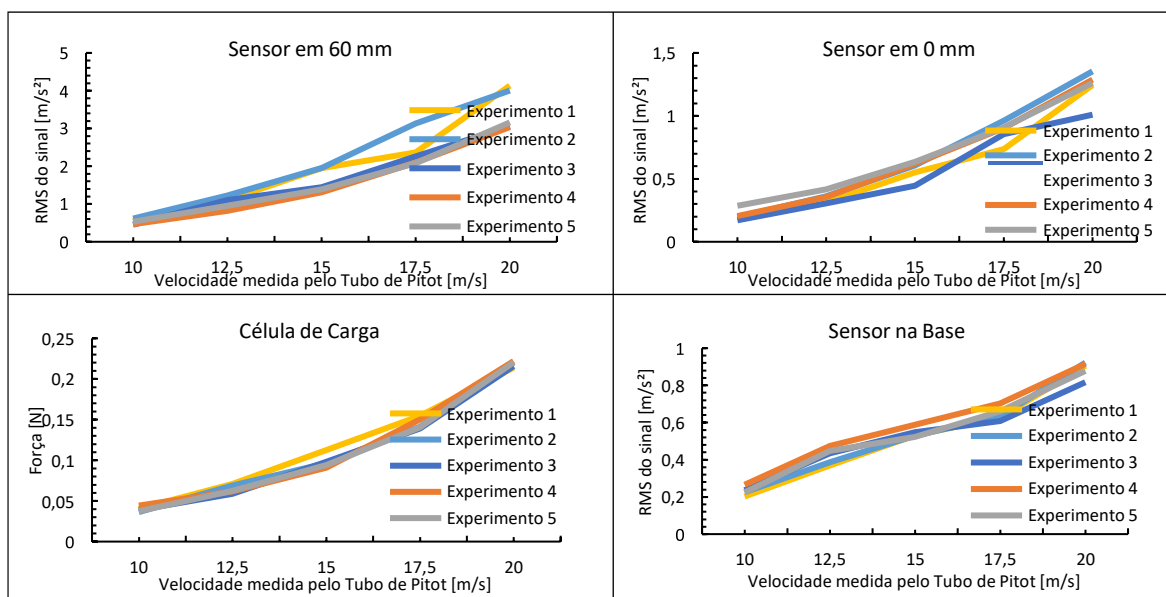
6.2. Resultados da Análise Modal Operacional (AMO)

Para a análise modal operacional, inicialmente foi realizado o estudo do perfil de velocidades do túnel de vento. Relembra-se que, as velocidades de escoamento geradas pelo túnel de vento que possuem menor desvio padrão são de 10 a 20 m/s, conforme Figura 5.11.

A Figura 6.4 mostra os resultados da viga instrumentada no túnel de vento dos cinco experimentos realizados.

Figura 6.4: Resultados dos experimentos para a viga instrumentada no túnel de vento.







FONTE: Autoria Própria.

Pela Figura 6.4, observa-se que os experimentos são estáveis, apresentando pouca variação entre as réplicas. Para as velocidades de escoamento mais elevadas as diferenças entre os sinais se tornam menores para o sensor nas posições 300 mm, 240 mm, 120 mm e 0 mm, e o sensor na posição mais elevada da viga (300 mm) possui o melhor resultado em termos de variação da medição para o acelerômetro variável. O sensor na base da viga apresenta baixa variação em função das réplicas realizadas, porém apresenta certa variação com o aumento das velocidades.

Agora é realizada uma análise comparativa do coeficiente de correlação (R2) para determinar o número de pontos de atraso do sensor virtual nas posições de 0, 60, 120, 180 e 240 mm. Reforça-se que o sensor virtual é obtido pela rede neural dinâmica. Os resultados para número de pontos de atraso 2, 5, 10 e 15 são apresentados na Figura 6.5.

Figura 6.5: Coeficiente de correlação da rede neural dinâmica.



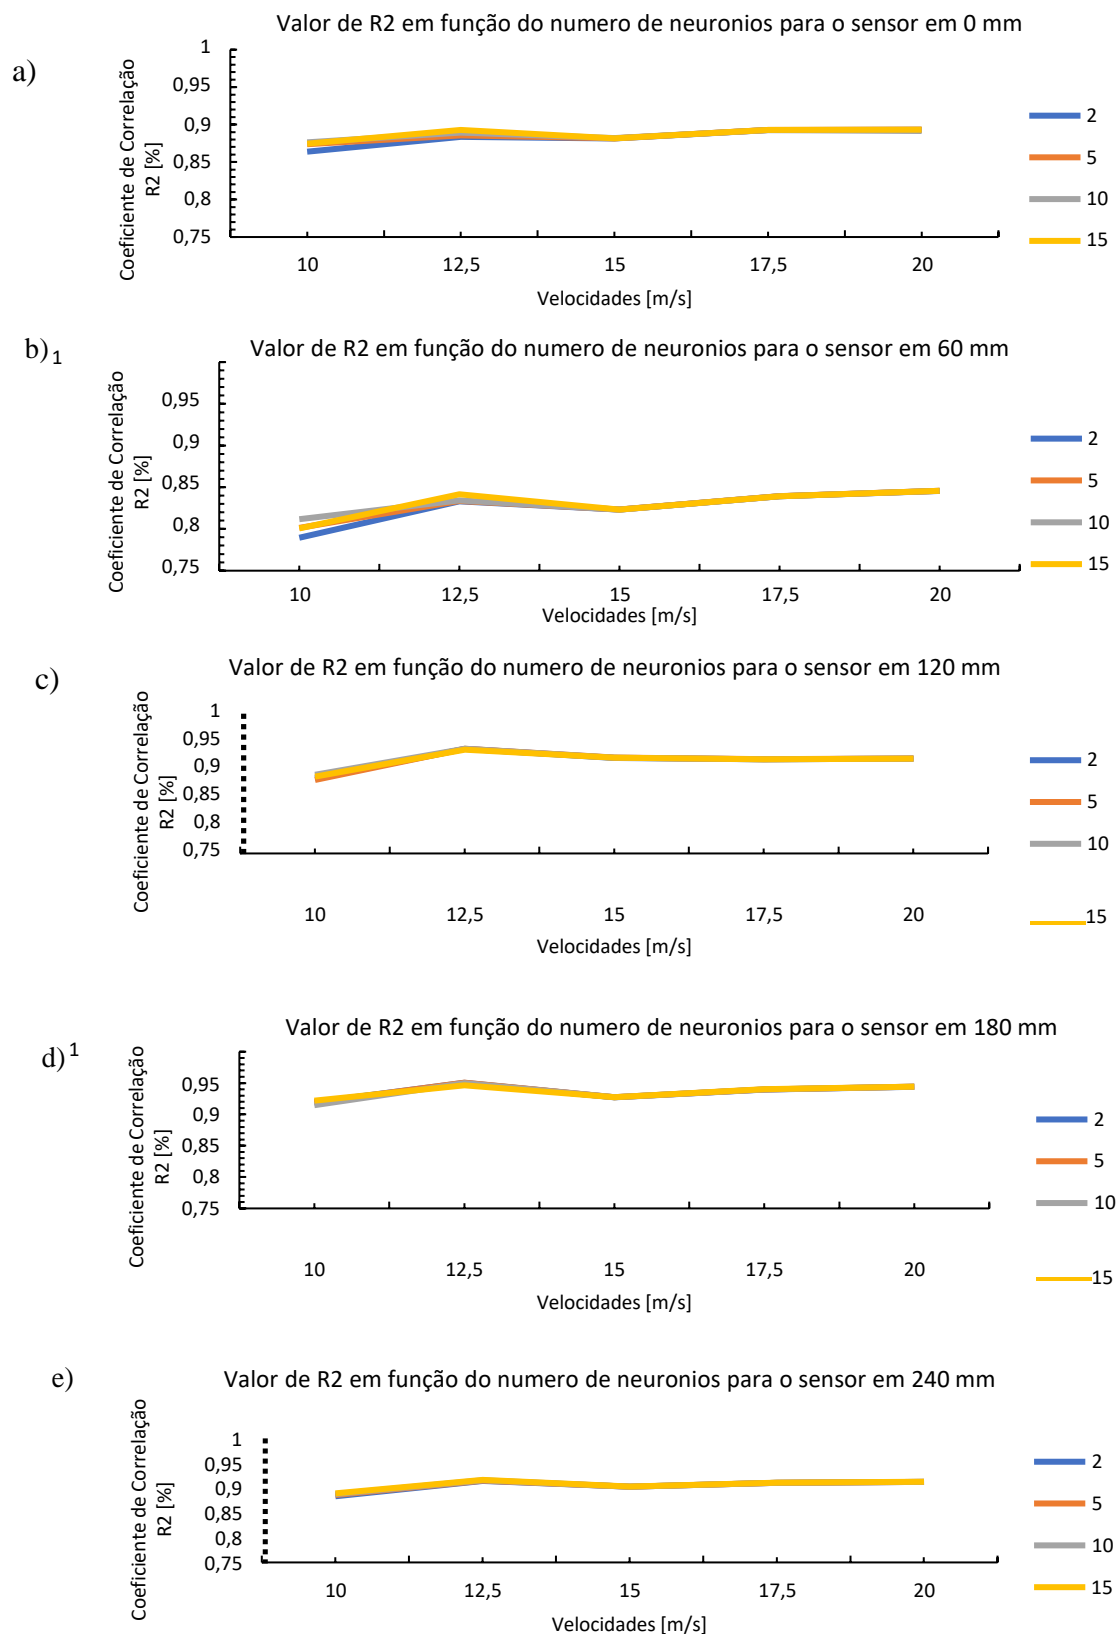


FONTE: Autoria Própria.

Pela Figura 6.5 observa-se que os melhores resultados são obtidos para o atraso de 15 pontos em todas as posições de sensores e velocidades de escoamento. Portanto, foi adotado esse atraso para a rede neural dinâmica.

Depois, realiza-se a análise comparativa de correlação para a configuração do número de neurônios na camada oculta. As posições do sensor virtual são 0, 60, 120, 180 e 240 mm, enquanto o número de neurônios na camada oculta são avaliados em 2, 5, 10 e 15. Os resultados são apresentados na Figura 6.7.

Figura 6.6: Coeficiente de correlação da rede neural dinâmica.

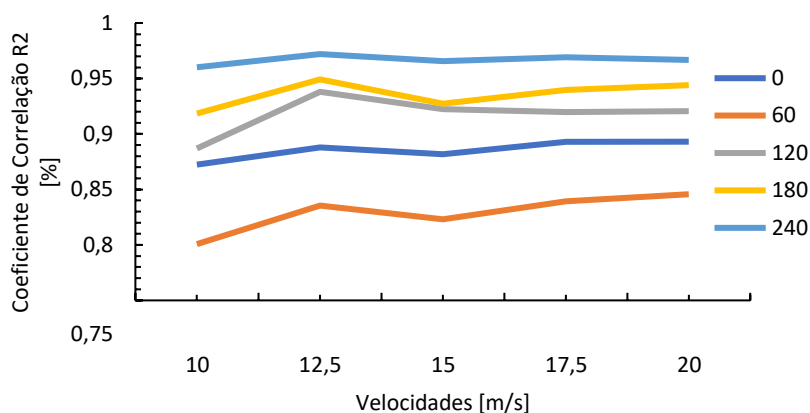


FONTE: Autoria Própria.

Pela Figura 6.6 observa-se que o melhor coeficiente de correlação ocorre com 15 neurônios de forma geral. No entanto, a curva com 10 neurônios possui esforço computacional menor e ótimos resultados de coeficiente de correlação também são observados. Diante do apresentado, determina-se como 10 o número de neurônios para a rede neural dinâmica.

Por sua vez, a Figura 6.7 mostra o coeficiente de correlação da rede neural dinâmica dos sensores virtuais utilizando-se 10 neurônios na camada oculta e 15 pontos de atraso.

Figura 6.7: Coeficiente de correlação da rede neural dinâmica.





FONTE: Autoria Própria.

A Figura 6.7 mostra que para o sensor na posição de 240 mm o valor de correlação (R2) entre os resultados é o mais alto, e o pior resultado foi observado para o sensor em 60 mm.

Os gráficos nas Figuras mostram que o sinal é estável em relação as réplicas realizadas para todos os sensores utilizados. Quando a velocidade aumenta, em geral os valores gerais do sinal aumentam, e de forma linear e estável. Os dados adquiridos no domínio do tempo, e estimados pela rede neural artificial para o modelo de viga submetido ao escoamento de vento. Os modos de vibrar (normalizados) da viga, para cada uma das velocidades, são mostrados na Figura 6.8:

Figura 6.8: Modos de vibrar da viga pela análise modal operacional.

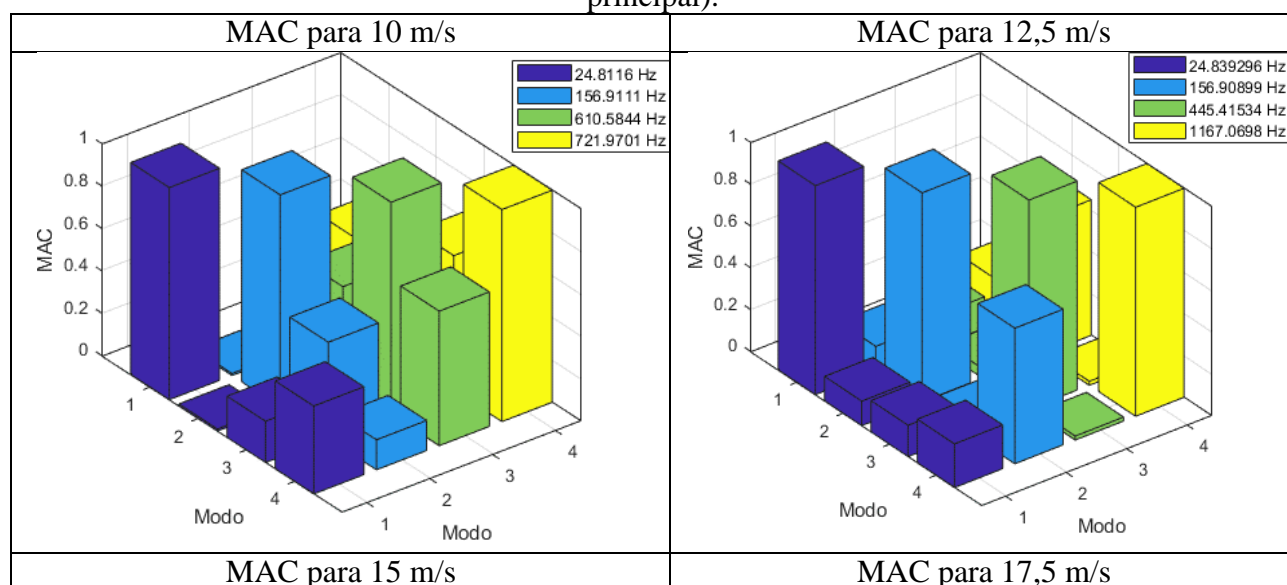


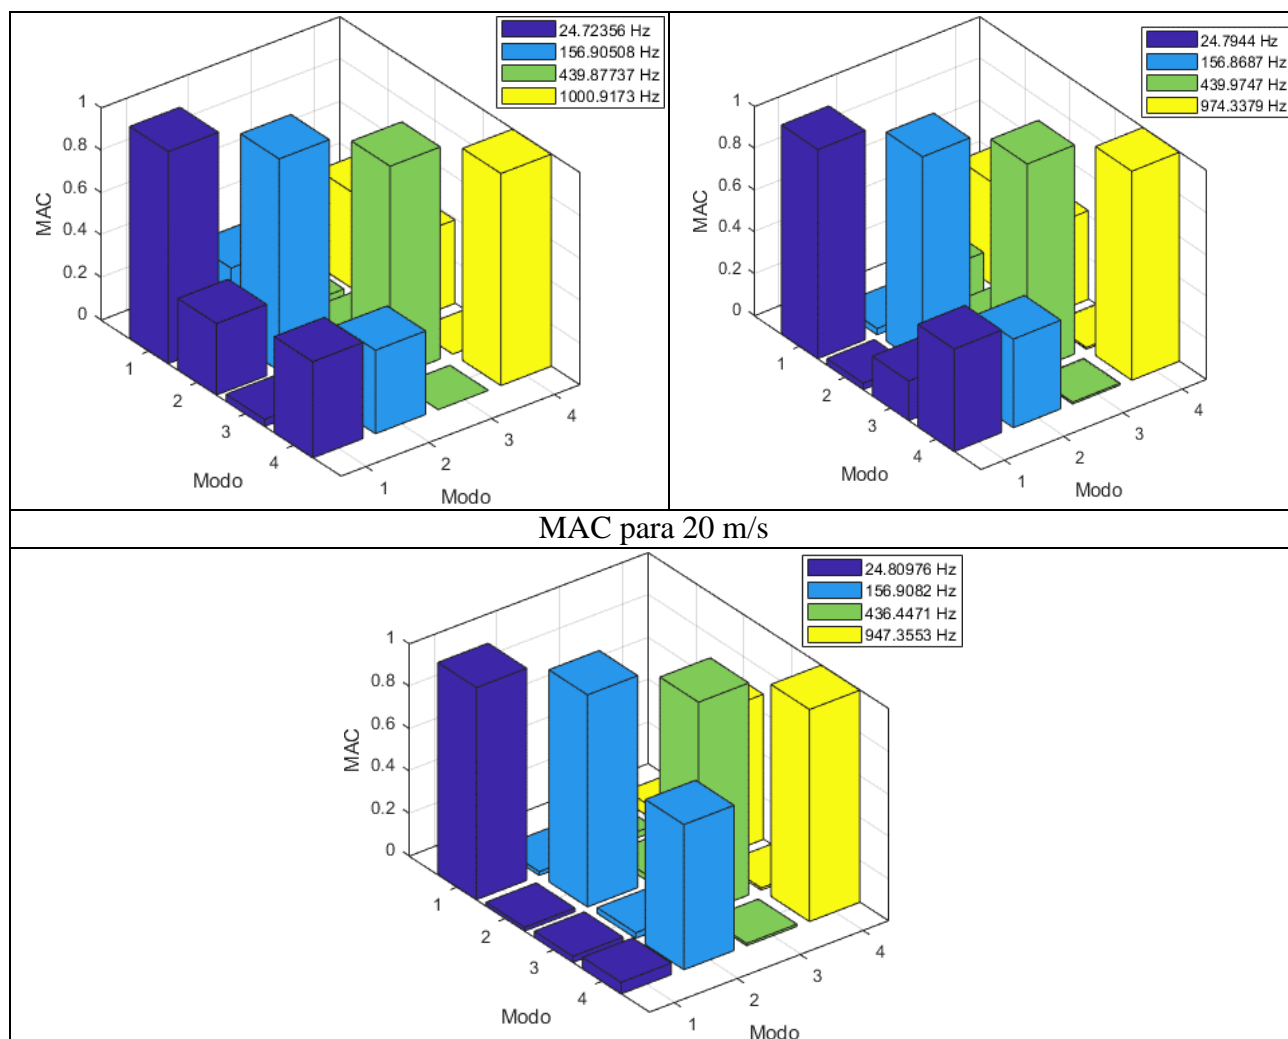


FONTE: Autoria Própria.

A Figura 6.8 mostra que os dois primeiros modos se mantêm em todos os escoamentos, sofrendo variação maior a partir de 400 Hz. O modo próximo de 1000 Hz sofre pouca influência do escoamento, ou seja, o impacto maior é observado nas baixas frequências. O formato geral dos modos de vibrar mostrados, seguem a teoria de Euler-Bernoulli, porém existem variações da posição de engaste da viga, que não condizem com a realidade.

Figura 6.9: Comparativo entre os valores de correlação das frequências de vibração (diagonal principal).





Pelos valores observados na Figura 6.9, os valores de correlação (R^2) para as formas modais associadas às frequências naturais (presentes na diagonal principal) estão acima de 90%. No entanto, apesar do elevado valor na diagonal principal, observa-se correlação ao comparar alguns modos distintos, o que é um indicativo de ruído. Para 10 m/s o escoamento é mais crítico, e nas velocidades maiores vai ficando mais pontual, e o 4º modo é o que mais tem correlação com os outros modos de maneira geral. Assim, com as frequências naturais e os modos de vibrar da viga, obteve-se na Tabela 6.2 as razões de amortecimento modal para cada frequência.

Tabela 6.2: Amortecimentos em função da frequência natural obtida.

	FREQUÊNCIA	RAZÃO DE AMORTECIMENTO
	10,0 m/s	24,78
156,82		0,0034
722,01		0,0013
942,71		0,0001
12,5 m/s	FREQUÊNCIA	RAZÃO DE AMORTECIMENTO
	24,83	0,0102
	156,90	0,0045
	445,54	0,0114

	1167,07	0,0001
	FREQUÊNCIA	RAZÃO DE AMORTECIMENTO
15,0 m/s	24,70	0,0121
	156,85	0,0042
	439,87	0,0143
	1000,91	0,0001
	FREQUÊNCIA	RAZÃO DE AMORTECIMENTO
17,5 m/s	24,81	0,0138
	156,90	0,0042
	438,34	0,0149
	974,33	0,0001
	FREQUÊNCIA	RAZÃO DE AMORTECIMENTO
20 m/s	24,78	0,0126
	156,87	0,0059
	436,50	0,0142
	947,35	0,0001

FONTE: Autoria Própria.


A Tabela 6.2 mostra que as maiores razão de amortecimento modal ocorrem no primeiro e no segundo modo de vibrar, e o menor amortecimento de todos ocorre no quarto modo, em torno de 1000 Hz. De maneira geral, com o aumento das velocidades de escoamento, o amortecimento aumentou para cada uma das frequências naturais observadas.

6.3. Comparativo entre os modos de vibrar

6.3.1. AME x Euler-Bernoulli

É realizado o comparativo entre as formas modais da AME com o modelo viga de Euler Bernoulli. A comparação será realizada utilizando o critério de MAC cruzado, e os resultados são apresentados na Figura 6.10:

Figura 6.10: Comparativo entre as formas modais AME x Euler-Bernoulli.



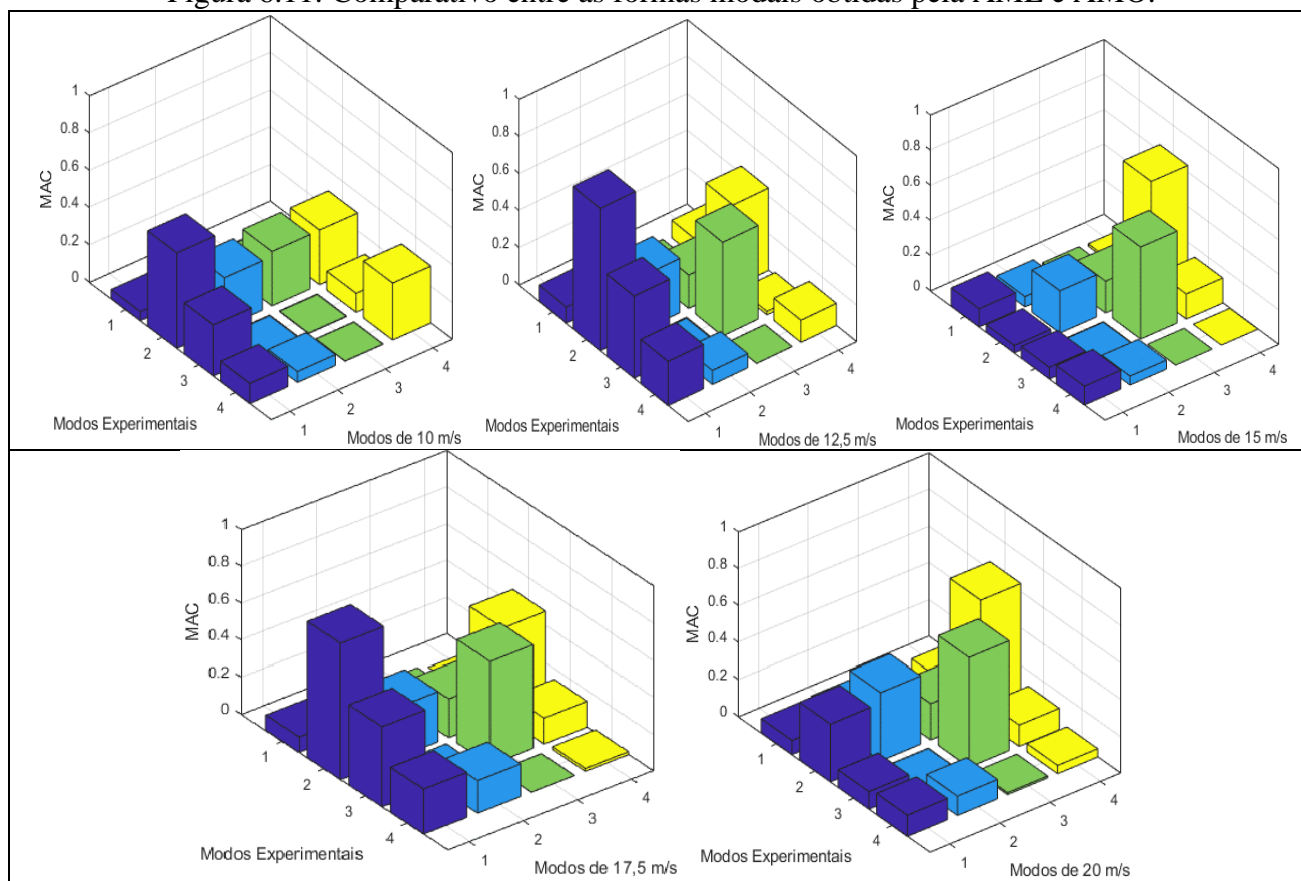
FONTE: Autoria Própria.

A Figura 6.10 mostra que os modos 2, 3 e 4 apresentaram os melhores coeficientes de correlação entre as duas análises, com valores superiores a 70%. O primeiro modo não apresentou um bom valor de coeficiente de correlação, em realidade ele apresentou correlação com o 4 modo. E, apesar deste problema, nota-se pouca correlação entre modos distintos, o que é um bom resultado. Por fim, deve-se investigar se a correlação do 1 e 4 modos deve-se à AME ou a consideração engastada-livre para viga de Euler-Bernoulli ser representativa para o problema.

6.3.2. AME x AMO

Será realizada agora uma comparação entre as formas modais obtidas pela AME e pela AMO. A comparação será realizada utilizando o critério de MAC cruzado. Os resultados são mostrados na Figura 6.11, para cada configuração da velocidade de escoamento.

Figura 6.11: Comparativo entre as formas modais obtidas pela AME e AMO.



FONTE: Autoria Própria.

Na Figura 4.16, observa-se que, em todos os comparativos entre os modos de vibrar, houve baixa correlação entre as formas modais obtidas pela AME e pela AMO, os melhores resultados possuem correlação em torno de 40% para o mesmo modo. Isto é, as formas modais encontradas pelas duas metodologias são distintas. A diferença das formas modais pode ser causada pela velocidade de escoamento que muda as características modais da viga ou pode ser devido ao método de

identificação estocástica baseado na covariância das respostas de referência (SSI – COV/ref) não ser adequado para esta aplicação. A Tabela 6.3 apresenta um comparativo entre as razões de amortecimento modal para AME x AMO:

Tabela 6.3: Comparativo entre as razões de amortecimento AME x AMO

AME		AMO				
Frequência	Razão de Amortecimento	Razão de Amortecimento				
		10 m/s	12,5 m/s	15 m/s	17,5 m/s	20 m/s
25,99 Hz	0,0067	0,0087	0,0102	0,0121	0,0138	0,0126
162,08 Hz	0,0159	0,0034	0,0045	0,0042	0,0042	0,0059
451,01 Hz	0,0030	0,0013	0,0114	0,0143	0,0149	0,0142
890,53 Hz	0,0023	0,0001	0,0001	0,0001	0,0001	0,0001

FONTE: Autoria Própria.

A Tabela 6.3 mostra que as razões de amortecimento foram diferentes para as duas avaliações, isso ocorre devido ao modelo de cada metodologia ser diferente, configurando frequências naturais próximas, mas razões de amortecimento bem distintas.

7. CONSIDERAÇÕES FINAIS

7.1. Conclusões

Foi realizada uma revisão bibliográfica sobre turbinas eólicas para contextualização do tema, e foram apresentadas problemáticas relacionadas a turbinas de eixo vertical.

O Modelo de Euler-Bernouli foi desenvolvido segundo a teoria das pequenas deformações para elementos de viga, e forma que pode se aproximar a torre eólica desse modelo em certa escala. Com isso, obteve-se um modelo teórico para comparação com os modelos experimentais a serem realizados.

O túnel de vento utilizado na UFG foi problemas abaixo de 10 m/s e acima de 20 m/s, apresentando instabilidade no escoamento e turbulência nessas regiões. Foi proposto o estudo do perfil de velocidades no interior do túnel de vento, e verificou-se que, utilizando-se o tubo de Pitot e a teoria do convergente para determinar a velocidade do escoamento no interior do túnel de vento, os valores obtidos apresentaram elevada variação, e com isso acentuado desvio padrão médio dos resultados entre as réplicas realizadas. Para o estudo realizado, mostrou-se que no intervalo entre 10 m/s e 20 m/s o escoamento era relativamente estável entre as 5 réplicas realizadas do experimento.

A rede neural dinâmica desenvolvida foi configurada com 10 neurônios, 15 pontos de atraso e em velocidades entre 10 m/s e 20 m/s, e treinada com o método de Levenberg-Marquardt. O código foi desenvolvido de forma a criar uma rede neural para cada velocidade, totalizando 5 redes neurais, modelando os sensores virtuais ao longo de toda a viga e assim ter o perfil modal da mesma em cada ponto, independente da velocidade.

De forma geral, para a AME foram obtidas as frequências naturais 25, 165, 450 e 900 Hz. Para essas frequências a forma geral do modo de vibrar da viga segue a teoria, porém a posição mostrada é incoerente, devido aos picos lineares gerados pelas retas que legam os pontos dos acelerômetros e ao deslocamento do ponto onde a viga está engastada para algumas frequências, talvez devido a ruído. De qualquer maneira, ao realizar o MAC, foram obtidos valores de correlação praticamente sem ruído, todos na diagonal principal do gráfico e com coeficientes de correlação na ordem de 90%, o que é um bom resultado.

Para a AMO foram obtidas as frequências naturais para cada velocidade de escoamento, e em geral, as frequências obtidas foram de 25, 157, 445 e 1000 Hz. Os dois primeiros modos de vibrar se mantêm em todos os escoamentos, sofrendo variação maior a partir de 400 Hz. É observado também

que o modo próximo de 1000 Hz sofre pouca influência do escoamento, portanto o impacto maior é observado nas baixas frequências. O formato geral dos modos de vibrar seguem a teoria de Euler-Bernoulli, porém existem variações da posição de engaste da viga observados graficamente que não condizem com a realidade.

Fazendo um comparativo entre a AME e a viga de Euler-Bernoulli, observa-se que os modos 2, 3 e 4 apresentaram os melhores coeficientes de correlação entre as duas análises, com valores superiores a 70%. O primeiro modo não apresentou um bom valor de coeficiente de correlação, em realidade ele apresentou correlação com o 4 modo. E, apesar deste problema, nota-se pouca correlação entre modos distintos, o que é um bom resultado.

Realizando-se um comparativo entre a AME e a AMO, foi observado que houve baixa correlação entre as formas modais e os melhores resultados possuem correlação em torno de 40% para o mesmo modo. Isto é, as formas modais encontradas pelas duas metodologias são distintas. Essa diferença das formas modais pode ser causada pela velocidade de escoamento ou pode ser devido ao método de identificação estocástica não ser adequado para esta aplicação, o que pode ser uma sugestão para trabalhos futuros realizar essa análise.

7.2. Sugestões de trabalho futuros

Sugestões para trabalhos futuros:

- Realizar a avaliação da condição de engastada livre para a viga de Bernouli.
- É interessante avaliar as AME e os parâmetros considerados, visando otimizar o sistema. Avaliar a AMO e outras técnicas de análise.
- Estudar o comportamento modal em velocidades abaixo de 10 m/s e acima de 20 m/s.
- Estudar outras geometrias de viga e material.
- Avaliar a coerência de métodos de identificação modal e determinar modelos mais eficientes.

8. REFERÊNCIAS

- ADRIANO S., LEONARDO A. et al. Análise Dinâmica Do Modelo De Viga De Euler-Bernoulli Via Método Das Diferenças Finitas. Revista Ifes Ciência, v.4, n.3, 2018 – Instituto Federal do Espírito Santo. (2018).
- ALLEMANG, R. J.; BROWN, D. L.; A Correlation Coefficient For Modal Vector Analysis. In: International Modal Analysis Conference, 1., 1982, Orlando. Proceedings, Orlando 1982, vol. 1, pp. 110-116.
- ALVES, Vinícius N. Alves. Estudo de novas estratégias para identificação de danos estruturais a partir de dados vibracionais. 2012. 188 f. Dissertação (Mestrado em Engenharia Civil) - Escola de Minas, Universidade Federal de Ouro Preto, Departamento de Engenharia Civil. Ouro Preto, 2012.
- ANDOLFATO, R. P., CAMACHO, J. S., de BRITO, G. A. (2004). Extensometria básica. (NEPAE UNESP, Ilha Solteira, 2004).
- APRENDIZADO DE MÁQUINA. Png Egg. Disponível em <https://www.pngegg.com/en/png-tgvpc>.
- BRAADFIELD, TERRY. (2001). Strain gauges [online]. Disponível na Internet via URL: <http://arapaho.nsuok.edu/~bradfiel/advlab/strain/>. Arquivo capturado em 12/04/2001.
- CHEN Y.B., & ORADY, E. (1997). An entropy-based index evaluation scheme for multiple sensor fusion in classification process. ASME Manufacturing Science and Technology, MED 6-1, 3–8.
- COMPARAÇÃO ENTRE TAMANHOS DE AEROGERADORES. Enercons, 2012. Disponível em <https://enercons.com.br>.
- COMPONENTES DOS AEROGERADORES: CONHEÇA TODA A SUA ESTRUTURA. Wind Box. Disponível em <https://windbox.com.br/blog/componentes-dos-aerogeradores/>.
- DALPIAZ, G., & RIVOLA, A. (1997). Condition monitoring and diagnostics in automatic machines: Comparison of vibration analysis techniques. Mechanical Systems and Signal Processing 11(1), 53–73.
- DANIEL DOS SANTOS, DANIEL C. A. & CHARLES C. Seleção de Pilotos em Sistemas de Múltiplas Antenas para Maximização da SNR Recebida. (2016).
- DIEDERIK B., AMIR R. NEJAD, JAN H. (2021). Dynamic Model Development of Wind Turbine Drivetrains Using Sensor Measurements.
- Experiment in the NASA-Ames Wind Tunnel: A Comparison of Predictions to Measures. National Renewable Energy Laboratory. Golden. 2001. Snel.
- F. GONÇALVES, P. SOUZA FILHO, W. PARADELLA (2009). Fusão de dados multisensor para a identificação e o mapeamento de ambientes flúvio-estuarinos da Amazônia. Revista Brasileira de Geofísica.
- FANG, X.D., & YAO, Y.L. (1997). In-process evaluation of the overall machining performance in finish-turning via single data source. Transactions of the ASME Journal of Manufacturing Science

and Engineering 119, 444–447.

FLÁVIA DE MELO R. SOUSA. (2020). Caracterização experimental de túneis de vento para análise de potencial eólico. Tese de Mestrado defendida em 2020.

FONSECA, CARLOS E. R. B. ALMEIDA (2015). Rede neural autorregressiva com entradas exógenas (NARX) aplicada ao controle de velocidade em veículos elétricos.

FORTUNA, L., GRAZIANI, S., RIZZO, A., XIBILIA, M.G. (2007). *Soft Sensors for Monitoring and Control of Industrial Processes*. London: Springer.

G. CUARELLI. Estimación de parâmetros da marcha humana a partir de medições feitas por acelerômetros e giroscópios e uso de mecanismo de referência. (2013).

G. OLIVEIRA, F. MAGALHÃES, Á. CUNHA (2017). Dynamic monitoring system for utility-scale wind turbines: damage detection and fatigue assessment. *Journal of Civil Structural Health Monitoring*.

G. RAMERA. Um Sistema para Medição da Movimentação da Junta Telescópica da Coluna de Direção Veicular em Teste de Impacto Frontal. (2011).

G. SAGGIO, F. RILO, L. SBERNINI (2015). Resistive flex sensors: A survey. *Journal of Smart Materials and Structures*.

GLOBAL WIND ENERGY COUNCIL. (2020). *GLOBAL WIND REPORT 2019*. Bruxelas, Bélgica. 2020.

H. AZEVEDO (2015). Um método para Identificação de falhas em componentes e subcomponentes de Aerogeradores através de monitoramento de Condição baseado em vibração. Dissertação para apresentação ao programa de Pós-Graduação em Engenharia Mecânica como requisito para obtenção do grau de Mestre em Engenharia Mecânica.

HEBB. (1949). *The Organization of Behavior: A Neuropsychological Theory*.

HUMAR, J. L. *Dynamics of Structures*. 2 ed. Ottawa (Canada): A.A. Balkema Publishers, Lisse, 2002. 967 p.

IVAN NUNES (2016). *Redes Neurais Artificiais para Engenharia e Ciências Aplicadas*. (pag. 170, 2016).

J. PACHECO, S. GUIMARÃES, C. MOUTINHO, et al. (2020). New strategies for optimized structural monitoring of wind farms: experimental campaign.

JÚNIOR, P. A.M. NASCIMENTO, E. O. NETO, M. G.F. OLIVEIRA, L. N. (2018). Characterization of Automobile Acoustic Insulation Performance based on Artificial Neural Networks via Sensitivity Analysis.

KHAN, A., Ceglarek, D., Shi, J., Ni, J., & Woo, T.C. (1999). Sensor optimization for fault diagnosis in single fixture systems: A methodology. *Transaction of the ASME Journal of Manufacturing Science and Engineering* 121(2), 109–117.

LEINE LINDE: SENSORES DE DESLOCAMENTO. Leinelinde.com. Disponível em:

<https://www.leinelinde.com/pt-BR/produtos/sensores-de-deformacao/esr-strain-sensor/>.

LIMA, F. M. Projeto e implementação de um sistema baseado em redes neurais para inferência da composição de pentano em uma torre de destilação. Dissertação (Mestrado) — Universidade Federal do Rio Grande do Norte, UFRN, Natal/RN – Brasil, 2010.

LOGAN, D.B., & MATHEW, J. (1996). Using the correlation dimension for vibration fault diagnosis of rolling element bearings. Basic concepts. *Mechanical Systems and Signal Processing* 10(3), 241–250.

LOTUFO, F. A.; GARCIA, C (2008). Sensores Virtuais ou Soft Sensors: Uma Introdução. 7th Brazilian Conference on Dynamics, Control and Applications. Presidente Prudente, SP: [s.n.]. p. 1-11.

MAGALHAES A., IGOR M., FRANCISCO F. (2016). A Characterization of Vertical Axis Wind Turbines. 2016.

MAGALHAES F, CUNHA A. (2011) Explaining operational modal analysis with data from an arch bridge. *Mech Syst Signal Process* 25:1431–1450.

MARTA, ANA CORRÊA, SALES. Estudo comparativo de análise de deflexões obtido a viga benkelman e fwd (falling weight deflectometer). (2016)

MARTINS, Jorge Felipe S. Otimização do comportamento dinâmico de um componente estrutural de um auto-rádio. 2011. 151 f. Dissertação (Mestrado em Engenharia Mecânica) - Escola de Engenharia, Universidade do Minho, Minho, 2011.

MC CULLOCH e PITTS. (1943). A logical Calculus of the ideas immanent in Nervous Activity.

MCAVOY, T. (2002). Intelligent “control” applications in the process industries. *Annual Reviews in Control*, 26(1), 75– 86.

MELO, E. (2013). Fonte eólica de energia: aspectos de inserção, tecnologia e competitividade. *Estudos avançados*, 27:77.

MODELOS E ARQUITETURAS DE REDES NEURAIS. Instituto Asimov. Disponível em <https://www.asimovinstitute.org/neural-network-zoo/>.

OLIVEIRA, GUSTAVO MAGALHÃES, FILIPE CUNHA, ÁLVARO CAETANO, ELSA. Dynamic monitoring system for utility-scale wind turbines: damage detection and fatigue assessment. (2017).

PEETERS, B. System Identification and Damage Detection in Civil Engineering. 2000. 238 p. PhD Thesis—Faculteit Toegepaste Wetenschappen, Katholieke Universiteit Leuven, Leuven, Belgium, 2000.

PEETERS, B.; DE ROECK, G. Stochastic System Identification for Operational Modal Analysis: A Review. *Journal of Dynamic Systems, Measurement, and Control*, v. 123, p. 659-667,2001.

PRESSAS, VALENTIN, ZHAO, MÔNICA EGUSQUIZA, VALERO, EDUARD EGUSQUIZA. (2021). On the use of neural networks for dynamic stress prediction in Francis’s turbines by means of stationary sensors.

PROGRAMAÇÃO DE REDES NEURAIAS. Programaria.com.br. Disponível em <https://www.programaria.org/>.

Q. LIU, H. WANG (2001). A case study on multisensor data fusion for imbalance diagnosis of rotating machinery. *Artificial Intelligence for Engineering Design, Analysis and Manufacturing: AIEDAM*.

R. BRANDÃO (2011). *Aerogeradores: Manutenção*. Instituto Politécnico do Porto. Instituto Superior de Engenharia do Porto. Área de Máquinas e Instalações Eléctricas. Departamento de Engenharia Eletrotécnica.

RANI, A.; SINGH, V.; GUPTA, J. R. P. (2013). Development of Soft Sensor for Neural Network Based Control of Distillation Column. *ISA Transactions*, v. 52, p. 438-449.

ROSEMBLATT. (1958). The perceptron: A probabilistic model for information storage and organization in the brain.

SAGGIO, G. RIILO, F. SBERNINI, L. QUITADAMO, L. RITA. (2015). Resistive flex sensors: A survey.

SCHANKE, A. S. *Operational Modal Analysis of Large Bridges*. 2015. 151 p. Masteroppgave–Fakultet for Ingeniørvitenskap og Teknologi, Norges TekniskNaturvitenskapelige Universitet, Trondheim, Norway, 2015.

SCHWARZ, Brian J.; RICHARDSON, Mark H.. Introduction to operating deflection shapes. In: *CSI Reliability Week, 1999*. Orlando. *Anais...* Jamestown: Vibrant technology, 1999.

SHENG, S., KELLER, J., & GLINSKY, C. (2013). *Gearbox Reliability Collaborative Update*. Sandia Reliability Workshop, Albuquerque, NM. (2013).

SIRQUEIRA, A. S. *Comportamento estrutural de torres de aço para suporte de Aerogeradores*. 112f. Dissertação (Mestrado em Engenharia Civil) – Faculdade de Tecnologia e Ciências, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2008.

SOLAR PROBE, DA NASA, ENVIA PRIMEIROS DADOS SOBRE O SOL. Parker. Disponível em: <https://g1.globo.com/ciencia-e-saude/noticia/2018/12/13/parker-solar-probe-da-nasa-envia-primeiros-dados-sobre-o-sol.ghtml>

T. RAUBER (1998). *Redes Neurais*.

THAM, M.T., MONTAGUE, G.A., MORRIS, A.J., and LANT, P.A (1991). Soft-sensors for process estimation and inferential control. *Journal of Process Control*, 1(1), 3–14.

TIPOS DE ACELERÔMETROS. DCM. Disponível em <https://www.dmc.pt/tipos-de-acelerometros/>.

TIPOS DE AEROGERADORES. Portal da Energia Renovável, 2021. Disponível em PortaldaEnergia.net (2021).

AEROGERADOR EÓLICA DE US\$ 3 MILHÕES EXPLODE AO CAPTAR VENTOS PODEROSOS. *Tec Mundo*, 2011. Disponível em: <https://www.tecmundo.com.br/energia-eolica/16424-Aerogerador-eolica-de-us-3-milhoes-explode-ao-captar-ventos-poderosos.htm>

UMA MONITORIZAÇÃO EFICIENTE PROTEGE PONTES CONTRA SOBRECARGA E PREVIENE ACIDENTES. Kistler, Disponível em: <https://www.kistler.com/pt/solucoes/solucoes-para-controlo-de-trafego/pesagem-em-movimento/protecao-de-pontes/>.

VALE, Alan Rafael M. Análise modal numérico-experimental de hélices navais produzidos na região da amazônica. 2013. 169 p. Trabalho de conclusão de curso (Graduação) - Universidade Federal do Pará, 2003.

VERMEER, L.; Sorensen, J.; Crespo, A. Wind Turbine Wake Aerodynamics. Progress in Aerospace Sciences, v. 39, p. 467-510, 2003.

WARREN S. MC CULLOCH and WALTER P. (1943). A logical calculus of the ideas immanent in nervous activity.

WIND ENERGY SOLUTIONS: THE NEXT CHAPTER IN NEW WIND ENERGY. Energia Renovável da GE. Disponível em: <https://www.ge.com/renewableenergy/wind-energy>

YANN LECUN. (1989). Backpropagation applied to Handwritten Zip Code Recognition.

Z. KHALID, N. FISAL, M. ROZAINI (2014). A survey of middleware for sensor and network virtualization. Sensors (Switzerland).

ZANATA, D. R. P. (2005). Desenvolvimento de Sensor Virtual Empregando Redes Neurais para Medição da Composição em uma Coluna de Destilação. Escola Politécnica da Universidade de São Paulo. São Paulo, p. 245.

WNISR, Lazard. DW – Made for Minds, 2021. Conteúdos científicos e tecnológicos. Disponível em <https://www.dw.com/pt-br/>. Acesso em 07 de dezembro de 2022.

RICHARD, Craig. Windpower, 2019. Conteúdos sobre energia eólica e novas tecnologias. Disponível no endereço eletrônico <https://www.windpowermonthly.com/article/1595597/vestas-tops-q2-orders-global-intake-hits-all-time-high>. Acesso em 08 de dezembro de 2022.

MEDEIROS. Windbox, 2020. Conteúdo de gestão e publicações sobre energia eólica. Disponível em <https://windbox.com.br/blog/componentes-dos-aerogeradores/>. Acesso em 02 de dezembro de 2022.

9. APÊNDICE

9.1. Resumo dos Dados Obtidos e Desvios Padrão – Túnel de vento

Tabela 9.1: Resumo dos dados obtidos dos sensores no túnel de vento

Velocidades de Setup:	10	12,5	15	17,5	20
RMS 300 mm:	1,752	3,307	4,751	6,919	10,078
RMS 240 mm:	1,152	1,925	2,663	4,105	6,010
RMS 180 mm:	0,916	1,559	2,263	3,162	4,785
RMS 120 mm:	0,732	1,742	2,269	3,391	4,576
RMS 60 mm:	0,479	0,959	1,378	2,142	3,082
RMS 0 mm:	0,220	0,358	0,566	0,888	1,186
RMS célula de carga:	0,040	0,061	0,094	0,143	0,219
RMS sensor base:	0,242	0,452	0,554	0,658	0,870
RMS Velocidade Pitot:	9,329	11,912	14,510	17,083	19,662
Velocidade Convergente:	8,519	10,881	13,253	15,590	17,917
Desvio Padrão V. Pitot:	0,080	0,084	0,094	0,106	0,103
Desvio padrão V. Conv.:	0,057	0,050	0,054	0,057	0,055

Fonte: Autoria Própria.

9.2. Tabela de dados de Neurônios x R2 (correlação)

Tabela 9.2: Avaliação do número ideal de neurônios da rede neural dinâmica.

Rótulos de Linha	2 neurônios	5 neurônios	10 neurônios	15 neurônios	Total Geral
10 m/s	0,884478333	0,887188333	0,888915	0,890135	0,887679167
12,5 m/s	0,91556	0,916093333	0,916853333	0,917616667	0,916530833
15 m/s	0,90385	0,903955	0,904031667	0,904078333	0,90397875
17,5 m/s	0,912001667	0,912101667	0,912141667	0,912186667	0,912107917
20 m/s	0,914013333	0,914085	0,913823333	0,914121667	0,914010833
Total Geral	0,905980667	0,906684667	0,907153	0,907627667	0,9068615

Fonte: Autoria Própria.

9.3. Códigos da Rede Neural

A rede neural foi parametrizada no Matlab através do comando *nnstart* (Neural Networking Start):

```

%% UFG - Universidade Federal de Goiás.
% Mestrado em Ciências Mecânicas e Dinâmica dos Fluidos.
% Desenvolvimento e Validação de Sistema de Monitoramento de Aeroogeradores
por meio de Sensores Virtuais e rede neural
%% Leitura do Experimento

clear all
close all
clc

addpath('D:\3 - Mestrado UFG\Dados\Modal Operacional\Experimento 4')

% Leitura dos dados

% Sensores

vel = [100 125 150 175 200];
pos = [0 60 120 180 240];

vel = 100;
aux = 0;

for zz = pos

    for ii = vel

        aux = aux + 1;
        nome = ['pedro_sensor_s1_300_s2_' num2str(zz) '_v' num2str(ii)];
        sensor(:, :, aux) = readmatrix(nome, 'Range', [1 2 51200.3 5]);

    end

end

tempo = readmatrix(nome, 'Range', [1 1 51200.3 1]);
dt = tempo(2) - tempo(1);
Fs = 1/dt;

%% Aplica passa alta nos dados

Fc = 10;
n_ordem = 4;

sensor(:, :, 1) = filtra_alta(sensor(:, :, 1), n_ordem, Fs, Fc);
sensor(:, :, 2) = filtra_alta(sensor(:, :, 2), n_ordem, Fs, Fc);
sensor(:, :, 3) = filtra_alta(sensor(:, :, 3), n_ordem, Fs, Fc);
sensor(:, :, 4) = filtra_alta(sensor(:, :, 4), n_ordem, Fs, Fc);
sensor(:, :, 5) = filtra_alta(sensor(:, :, 5), n_ordem, Fs, Fc);

%% Prepara dados

sensor_p1 = sensor(:, 2, 1);

```

```

sensor_p2 = sensor(:,2,2);
sensor_p3 = sensor(:,2,3);
sensor_p4 = sensor(:,2,4);
sensor_p5 = sensor(:,2,5);

ref_p1 = sensor(:, [1 4],1);
ref_p2 = sensor(:, [1 4],2);
ref_p3 = sensor(:, [1 4],3);
ref_p4 = sensor(:, [1 4],4);
ref_p5 = sensor(:, [1 4],5);

sensor_p6 = sensor(:,1,5);

%% Transforma aceleração para deslocamento
%
% sensor_p1 = acel2desl(sensor_p1,tempo);
% sensor_p2 = acel2desl(sensor_p2,tempo);
% sensor_p3 = acel2desl(sensor_p3,tempo);
% sensor_p4 = acel2desl(sensor_p4,tempo);
% sensor_p5 = acel2desl(sensor_p5,tempo);
% sensor_p6 = acel2desl(sensor_p6,tempo);
%
% sensor_p1 = filtra_alta(sensor_p1,n_ordem,Fs,Fc);
% sensor_p2 = filtra_alta(sensor_p2,n_ordem,Fs,Fc);
% sensor_p3 = filtra_alta(sensor_p3,n_ordem,Fs,Fc);
% sensor_p4 = filtra_alta(sensor_p4,n_ordem,Fs,Fc);
% sensor_p5 = filtra_alta(sensor_p5,n_ordem,Fs,Fc);
% sensor_p6 = filtra_alta(sensor_p6,n_ordem,Fs,Fc);

%% Treina rede neural

n_delay = 15;
n_hidden = 10;

[net1,r1] = treina_rede(ref_p1,sensor_p1,n_delay,n_hidden);
[net2,r2] = treina_rede(ref_p2,sensor_p2,n_delay,n_hidden);
[net3,r3] = treina_rede(ref_p3,sensor_p3,n_delay,n_hidden);
[net4,r4] = treina_rede(ref_p4,sensor_p4,n_delay,n_hidden);
[net5,r5] = treina_rede(ref_p5,sensor_p5,n_delay,n_hidden);

% ou carrega as redes treinadas

% load('net1_v100.mat')
% load('net2_v100.mat')
% load('net3_v100.mat')
% load('net4_v100.mat')
% load('net5_v100.mat')

%% Usa a rede para obter as respostas

sensor_t = sensor(:,2);
ref_t = sensor(:, [1 4]);

X = tonndata(ref_t,false,false);
T = tonndata(sensor_t,false,false);

[x,xi,ai,t] = preparets(net1,X,T);
y1 = net1(x,xi,ai);

[x,xi,ai,t] = preparets(net2,X,T);
y2 = net2(x,xi,ai);

```

```

[x,xi,ai,t] = preparets(net3,X,T);
y3 = net3(x,xi,ai);

[x,xi,ai,t] = preparets(net4,X,T);
y4 = net4(x,xi,ai);

[x,xi,ai,t] = preparets(net5,X,T);
y5 = net5(x,xi,ai);

% Converte cell2mat

y1 = cell2mat(y1)';
y2 = cell2mat(y2)';
y3 = cell2mat(y3)';
y4 = cell2mat(y4)';
y5 = cell2mat(y5)';
y6 = sensor_p6(n_delay + 1:end,1);

y = [y1, y2, y3, y4, y5, y6];
pwelch(y, [], [], [], Fs);

%% Aplica OMA

[fn0,zeta0,phi0,paraPlot] = SSICOV(y',dt,'eps_cluster',12,'eps_MAC',1e-
6);
fn0

plotStabDiag(paraPlot.fn,y(:,1)',Fs,paraPlot.status,paraPlot.Nmin,paraPlo
t.Nmax);

%% Plota modos

modos = phi0(1:4,1:6)';

for ii=1:size(modos,2)

    modos(:,ii) = modos(:,ii)/max(abs(modos(:,ii)));

end

figure
plot(modos,1:6,'-o','LineWidth',1.5)
hold on
plot(zeros(1,6),1:6,'-ok','LineWidth',1.5)
legend(num2str(fn0(1:4)'))
grid on
xlabel('Amplitude')
ylabel('Position')
title('Formas modais para 10 m/s')

MAC(modos)
legend(num2str(fn0),'Location','best')

```

a) Código Principal da AME

```

clear all
close all
clc

addpath('D:\3 - Mestrado UFG\Dados\Modal Experimental\Pedro Medicoes')

for ii = 1:12 % posição de sensor

    for jj = 1:12 % posição de excitação/martelo

        dados = load(['h' num2str(ii) '_' num2str(jj) '.txt']); % Leitura dos
arquivos.
        f = dados(:,1); % vetor de frequência.
        FRF(:,ii,jj) = dados(:,2) + i.dados(:,3); % montou função de
transferência com a 2 e a 3 coluna de dados.
        coe(:,ii,jj) = dados(:,4); % coerência (correlacionar os sinais, de
entrada e saída).

        % w = 2.pi.f;
        % FRF(:,ii,jj) = FRF(:,ii,jj)./(-w.^2);
        %
        % FRF(1,ii,jj) = FRF(2,ii,jj);
        % FRF(1:10,ii,jj) = FRF(1:10,ii,jj)/1000;

        % f = vetor de 6 colunas de frequência.
        % fs = frequência de amostragem.
        % FRF = vetor de 12 colunas contendo parte real e imaginária da
função resposta em frequência.
        % coe = vetor de 6 colunas da coerência (correlação entre os sinais
de entrada e saída).
    end
end

Fs = (f(2) - f(1)) . length(f) . 2; % Frequência de aquisição, com
resolução de 1 Hz. 12.800 Hz.

% Plot a primeira FRF apenas para decidir FR e Num

figure
plot(f, 10.log10(abs(FRF(:,1,1)))) % Módulo da parte real da Função
Resposta em Frequência.
grid on
xlabel('Frequency [Hz]')
ylabel('Amplitude [dB]')
title('FRF 11 - Gráfico da Função Resposta na Posição 11')

%% Análise modal

FR = [0 1000]; % Banda de frequência em análise
Num = 20; % Número de modos

% figure
% modalsd(FRF,f,Fs,'FreqRange',FR) % Figura ilustrando os modos estáveis
phfr = [26 166 449 894];

figure
modalfit(FRF, f, Fs, Num,'FreqRange',FR,'PhysFreq',phfr) % Figura
comparativa da FRF experimental e reconstruída pelo parâmetros modais
[fn, dr, ms, ofrf] = modalfit(FRF, f, Fs,

```

```

Num, 'FreqRange', FR, 'PhysFreq', phfr); % Apenas salvando os parâmetros modais
fn
%% Plota modos

n_sensor = size(ms,1);

modos = real(flipud(ms));

for ii=1:size(modos,2)

    modos(:,ii) = modos(:,ii)/max(abs(modos(:,ii)));

end

figure
plot(modos,1:n_sensor, '-o', 'LineWidth',1.5)
hold on
plot(zeros(1,n_sensor),1:n_sensor, '-ok', 'LineWidth',1.5)
legend(num2str(fn))
grid on
xlabel('Amplitude')
ylabel('Position')
title('Modal forms')

mac = MAC(modos)
legend(num2str(fn), 'Location', 'best')

```

b) Códigos Auxiliares

A seguir são mostrados todos os códigos auxiliares utilizados no código da OMA.

Filtro Passa alta

```

function y = filtra_alta(x,N,Fs,Fc)

% x - sinal original
% N - ordem do filtro
% Fs - freq de aquisição
% Fc - freq de corte

% y - sinal filtrado

% Filtro passa alta

Wn = Fc/(Fs/2);
[b,a] = butter(N,Wn, 'high');
y = filtfilt(b,a,x);

```

Função MAC

```

function mac=MAC(phi)

% This function is to compute and plot Modal Assurance Criterion (MAC)
matrix between identified mode shapes
% rectangle around the peaks.
% Programmer: Mohammad Farshchin, Ph.D candidate at The UofM
% Email: Mohammad.Farshchin@gmail.com
% Last modified: 9/23/2015

```

```

% phi: matrix of the identified mode shapes
% mac: MAC matrix
% Example: load ModeShapes.mat;MAC_Matrix=MAC(phi)

for I=1:size(phi,2)
    for J=1:size(phi,2)
        mac(I,J)=Mac(phi(:,I),phi(:,J));
    end
end
% plot mac matrix
figure
bar3(mac)
box on
title('Modal Assurance Criterion')
ylabel('Mode')
xlabel('Mode')
zlabel('MAC')
end

function mAc=Mac(Phi1,Phi2)
% This function calculates mac between phi1 and phi2
mAc= (abs(Phi1'.Phi2))^2/((Phi1'.Phi1).(Phi2'.Phi2));
end

```

Função SSICOV

```

function [fn,zeta,phi,varargout] = SSICOV(y,dt,varargin)
%
% -----
--
% [fn,zeta,phi,varargout] = SSICOV(y,dt,varargin) identifies the modal
% parameters of the M-DOF system whose response histories are located in
% the matrix y, sampled with a time step dt.
% -----
--
% Input:
% y: time series of ambient vibrations: matrix of size [MxN]
% dt : scalar: Time step
% Varargin: contains additional optional parameters:
%   'Ts': scalar : time lag for covariance calculation
%   'methodCOV': scalar: method for COV estimate ( 1 or 2)
%   'Nmin': scalar: minimal number of model order
%   'Nmax': scalar: maximal number of model order
%   'eps_freq': scalar: frequency accuracy
%   'eps_zeta': scalar: % damping accuracy
%   'eps_MAC': scalar: % MAC accuracy
%   'eps_cluster': scalar: % maximal distance inside each cluster
% -----
--
% Output:
% fn: eigen frequencies identified
% zeta: modal damping ratio identified
% phi: mode shape identified
% varargout: structure data useful for stabilization diagram
% -----
--
% Syntax:
% [fn,zeta,phi] = SSICOV(y,dt,'Ts',30) specifies that the time lag
% has to be 30 seconds.
%
% [fn,zeta,phi] = SSICOV(y,dt,'Ts',30,'Nmin',5,'Nmax',40) specifies that
the

```

```

40. % time lag has to be 30 seconds, with a system order ranging from 5 to
%
% [fn,zeta,phi] = SSICOV(y,dt,'eps_cluster',0.05) specifies that the
% max distance inside each cluster is 0.05 hz.
%
% [fn,zeta,phi] = SSICOV(y,dt,'eps_freq',1e-2,'eps_MAC',1e-2) changes the
% default accuracy for the stability checking procedure
%
% -----
--
% Organization of the function:
% 6 steps:
% 1 - Claculation of cross-correlation function
% 2 - Construction of the block Toeplitz matrix and SVD of it
% 3 - Modal identification procedure
% 4 - Stability checking procedure
% 5 - Selection of stable poles only
% 6 - Cluster Algorithm
% -----
--
% References:
% Magalhaes, F., Cunha, A., & Caetano, E. (2009).
% Online automatic identification of the modal parameters of a long span
arch
% bridge. Mechanical Systems and Signal Processing, 23(2), 316-329.
%
% Magalhães, F., Cunha, Á., & Caetano, E. (2008).
% Dynamic monitoring of a long span arch bridge. Engineering Structures,
% 30(11), 3034-3044.
% -----
--
% Author: E Cheynet, UiS/UiB - Norway
% Last modified: 06/12/2019
% -----
--
%
% see also plotStabDiag.m
%%
% options: default values
p = inputParser();
p.CaseSensitive = false;
p.addOptional('Ts',500.dt);
p.addOptional('methodCOV',1);
p.addOptional('Nmin',2);
p.addOptional('Nmax',30);
p.addOptional('eps_freq',1e-2);
p.addOptional('eps_zeta',4e-2);
p.addOptional('eps_MAC',5e-3);
p.addOptional('eps_cluster',0.2);
p.parse(varargin{:});
% Number of outputs must be >=3 and <=4.
nargoutchk(3,4)
% size of the input y
[Nyy,N]= size(y);
% shorten the variables name
eps_freq = p.Results.eps_freq ;
eps_zeta = p.Results.eps_zeta ;
eps_MAC = p.Results.eps_MAC ;
eps_cluster = p.Results.eps_cluster ;
Nmin = p.Results.Nmin ;
Nmax = p.Results.Nmax ;
% Natural Excitation Technique (NeXT)

```

```

[IRF,~] = NExT(y,dt,p.Results.Ts,p.Results.methodCOV);
% Block Hankel computations
[U,S,~] = blockToeplitz(IRF);
if isnan(U)
    fn = nan;
    zeta = nan;
    phi = nan;
    if nargout==4
        varargout = {nan};
    end
    return
end

% Stability check
kk=1;
for ii=Nmax:-1:Nmin % decreasing order of poles
    if kk==1
        [fn0,zeta0,phi0] = modalID(U,S,ii,Nyy,dt);
    else
        [fn1,zeta1,phi1] = modalID(U,S,ii,Nyy,dt);
        [a,b,c,d,e] = stabilityCheck(fn0,zeta0,phi0,fn1,zeta1,phi1);
        fn2{kk-1}=a;
        zeta2{kk-1}=b;
        phi2{kk-1}=c;
        MAC{kk-1}=d;
        stability_status{kk-1}=e;
        fn0=fn1;
        zeta0=zeta1;
        phi0=phi1;
    end
    kk=kk+1;
end

% sort for increasing order of poles
stability_status=fliplr(stability_status);
fn2=fliplr(fn2);
zeta2=fliplr(zeta2);
phi2=fliplr(phi2);
MAC=fliplr(MAC);
% get only stable poles
[fnS,zetaS,phiS,MACS] =
getStablePoles(fn2,zeta2,phi2,MAC,stability_status);
if isempty(fnS)
    warning('No stable poles found');
    fn = nan;
    zeta = nan;
    phi = nan;
    if nargout==4
        varargout = {nan};
    end
    return
end

% Hierarchical cluster
[fn3,zeta3,phi3] = myClusterFun(fnS,zetaS,phiS);
if isnumeric(fn3)
    warning('Hierarchical cluster failed to find any cluster');
    fn = nan;
    zeta = nan;
    phi = nan;
    if nargout==4
        varargout = {nan};
    end
    return
end

```

```
end
```

```
% average the clusters to get the frequency and mode shapes
```

```

% Up to Nmax parameters are identified
fn = zeros(1,Nmax);
zeta = zeros(1,Nmax);
phi = zeros(Nmax,Nyy);
for ii=1:numel(fn3)
    fn(ii)=nanmean(fn3{ii});
    zeta(ii)=nanmean(zeta3{ii});
    phi(ii,:)=nanmean(phi3{ii},2);
end
phi(fn==0,:)=[];
zeta(fn==0)=[];
fn(fn==0)=[];
% sort the eigen frequencies
[fn,indSort]=sort(fn);
zeta = zeta(indSort);
phi = phi(indSort,:);
% varargout for stabilization diagram
if nargin==4
    paraPlot.status=stability_status;
    paraPlot.Nmin = Nmin;
    paraPlot.Nmax = Nmax;
    paraPlot.fn = fn2;
    varargout = {paraPlot};
end
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%
function [U,S,V] = blockToeplitz(h)
%
% [U,S,V] = SSICOV(h) calculate the shifted block Toeplitz matrix
T1 and
% the result from the SVD of T1
%
% Input:
% h: 3D-matrix of cross-correlation functions
%
% Outputs
% U : result from SVD of H0
% S : result from SVD of H0
% V : result from SVD of H0
%%
if or(size(h,1)~=size(h,2),ndims(h)~=3)
    error('the IRF must be a 3D matrix with dimensions <M x M x
N> ')
end
% get block Toeplitz matrix
N1 = round(size(h,3)/2)-1;
M = size(h,2);
clear H0
for oo=1:N1
    for ll=1:N1
        T1((oo-1).M+1:oo.M,(ll-1).M+1:ll.M) = h(:,:,N1+oo-ll+1);
    end
end
if or(any(isinf(T1(:))),any(isnan(T1(:))))
    warning('Input to SVD must not contain NaN or Inf. ')
    U=nan;
    S=nan;
    V=nan;
    return
else
    try
        [U,S,V] = svd(T1);
    catch exception

```

```

        warning(' SVD of the block-Toeplitz failed ');
        U=nan;
        S=nan;
        V=nan;
        return
    end
end

end

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%
function [IRF,t] = NExT(x,dt,Ts,method)
%
% [IRF,t] = NExT(x,dt,Ts,method) implements the Natural
Excitation Technique to
% retrieve the Impulse Response Function (IRF) from the cross-
correlation
% of the measured output y.
%
% Input:
% x: time series of ambient vibrations: vector of size [1xN]
% dt : Time step
% Ts: Duration of subsegments (T<dt.(numel(y)-1))
% method = 1 use the fft without zero padding.
% method = 2 calls the function xcov with zero padding.
%
% Output
% IRF: impulse response function
% t: time vector associated with the IRF
%
%%
if nargin<4, method = 2; end % the fastest method is the default
method
if ~ismatrix(x), error('Error: x must be a vector or a
matrix'),end

if size(x,1)>size(x,2)
    x=x';
    [Nxx,~]=size(x);
else
    [Nxx,~]=size(x);
end

% get the maximal segment length fixed by T
M = round(Ts/dt);
switch method
case 1

    IRF = zeros(Nxx,Nxx,M);
    for oo=1:Nxx
        for jj=1:Nxx
            y1 = fft(x(oo,:));
            y2 = fft(x(jj,:));
            h0 = ifft(y1..conj(y2));
            IRF(oo,jj,:) = h0(1:M);
        end
    end
    % get time vector t associated to the IRF
    t = (0:1:M-1).dt;
    if Nxx==1,IRF = squeeze(IRF)';end

```

```

case 2

```



```

%%
    function [fn,zeta,phi,MAC,stablity_status] =
stabilityCheck(fn0,zeta0,phi0,fn1,zeta1,phi1)
    % [fn,zeta,phi,MAC,stablity_status] =
stabilityCheck(fn0,zeta0,phi0,fn1,zeta1,phi1)
    % calculate the stability status of each mode obtained for
    % two adjacent poles (i,j).
    %
    % Input:
    % fn0: eigen frequencies calculated for pole i: vetor of N-modes
[1 x N]
    % zeta0: modal damping ratio for pole i: vetor of N-modes [1 x N]
    % phi0: mode shape for pole i: vetor of N-modes [Nyy x N]
    % fn1: eigen frequencies calculated for pole j: vetor of N-modes
[1 x N+1]
    % zeta1: modal damping ratio for pole j: vetor of N-modes [1 x
N+1]
    % phi1: mode shape for pole j: vetor of N-modes [Nyy x N+1]
    %
    % Output:
    % fn: eigen frequencies calculated for pole j
    % zeta: modal damping ratio for pole i
    % phi: mode shape for pole i
    % MAC: Mode Accuracy
    % stablity_status: stabilitystatus
    %%

    % Preallocation
    stablity_status = [];
    fn = [];
    zeta = [];
    phi = [];
    MAC=[];
    % frequency stability
    N0 = numel(fn0);
    N1 = numel(fn1);
    for rr=1:N0
        for jj=1:N1
            stab_fn = errCheck(fn0(rr),fn1(jj),eps_freq);
            stab_zeta = errCheck(zeta0(rr),zeta1(jj),eps_zeta);
            [stab_phi,dummyMAC] =
getMAC(phi0(:,rr),phi1(:,jj),eps_MAC);
            % get stability status
            if stab_fn==0,
                stabStatus = 0; % new pole
            elseif stab_fn == 1 & stab_phi == 1 & stab_zeta == 1,
                stabStatus = 1; % stable pole
            elseif stab_fn == 1 & stab_zeta ==0 & stab_phi == 1,
                stabStatus = 2; % pole with stable frequency and
vector
damping
            elseif stab_fn == 1 & stab_zeta == 1 & stab_phi ==0,
                stabStatus = 3; % pole with stable frequency and
            elseif stab_fn == 1 & stab_zeta ==0 & stab_phi ==0,
                stabStatus = 4; % pole with stable frequency

            else
                error('Error: stablity_status is undefined')
            end

            fn = [fn,fn1(jj)];
            zeta = [zeta,zeta1(jj)];
            phi = [phi,phi1(:,jj)];
            MAC = [MAC,dummyMAC];
            stablity_status = [stablity_status,stabStatus];

```

```

        end
    end

    [fn,ind] = sort(fn);
    zeta = zeta(ind);
    phi = phi(:,ind);
    MAC = MAC(ind);
    stability_status = stability_status(ind);

    function y = errCheck(x0,x1,eps)
        if or(numel(x0)>1,numel(x1)>1),
            error('x0 and x1 must be a scalar');
        end
        if abs(1-x0./x1)<eps % if frequency for mode i+1 is almost
unchanged
            y = 1;
        else
            y = 0;
        end
    end
end

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%
function [fnS,zetaS,phiS,MACS] =
getStablePoles(fn,zeta,phi,MAC,stability_status)
    fnS = [];zetaS = [];phiS=[];MACS = [];
    for oo=1:numel(fn)
        for jj=1:numel(stability_status{oo})
            if stability_status{oo}(jj)==1
                fnS = [fnS,fn{oo}(jj)];
                zetaS = [zetaS,zeta{oo}(jj)];
                phiS = [phiS,phi{oo}(:,jj)];
                MACS = [MACS,MAC{oo}(jj)];
            end
        end
    end
end

% remove negative damping
fnS(zetaS<=0)=[];
phiS(:,zetaS<=0)=[];
MACS(zetaS<=0)=[];
zetaS(zetaS<=0)=[];

% Normalized mode shape
for oo=1:size(phiS,2)
    phiS(:,oo) = phiS(:,oo) ./ max(abs(phiS(:,oo)));
    if diff(phiS(1:2,oo))<0
        phiS(:,oo) = -phiS(:,oo);
    end
end
end

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%
function [fn,zeta,phi] = myClusterFun(fn0,zeta0,phi0)

[~,Nsamples] = size(phi0);
pos = zeros(Nsamples,Nsamples);
for i1=1:Nsamples
    for i2=1:Nsamples
        [~,MAC0] = getMAC(phi0(:,i1),phi0(:,i2),eps_MAC); % here,
eps_MAC is not important.
        pos(i1,i2) = abs((fn0(i1)-fn0(i2))./fn0(i2)) +1-MAC0; %

```

```

compute MAC number between the selected mode shapes
    end
    end
    if numel(pos)==1
        warning('linkage failed: at least one distance (two
observations) are required');
        fn = nan;
        zeta = nan;
        phi = nan;
        return
    else
        Z = linkage(pos, 'single', 'euclidean');
        myClus =
cluster(Z, 'Cutoff', eps_cluster, 'Criterion', 'distance');
        Ncluster = max(myClus);

        ss=1;
        fn = {}; zeta = {}; phi = {};
        for rr=1:Ncluster
            if numel(myClus(myClus==rr))>5
                dummyZeta = zeta0(myClus==rr);
                dummyFn = fn0(myClus==rr);
                dummyPhi = phi0(:,myClus==rr);
                valMin = max(0, (quantile(dummyZeta,0.25) -
abs(quantile(dummyZeta,0.75)-quantile(dummyZeta,0.25)).1.5));
                valMax =quantile(dummyZeta,0.75) +
abs(quantile(dummyZeta,0.75)-quantile(dummyZeta,0.25)).1.5;
                dummyFn(or(dummyZeta>valMax,dummyZeta<valMin)) = [];
                dummyPhi(:,or(dummyZeta>valMax,dummyZeta<valMin)) =
[];

                dummyZeta(or(dummyZeta>valMax,dummyZeta<valMin)) =
[];

                fn{ss} = dummyFn;
                zeta{ss} = dummyZeta;
                phi{ss} = dummyPhi;
                ss=ss+1;
            end
        end
        if isempty(fn)
            fn = nan;
            zeta = nan;
            phi = nan;
            return
        end
    end
end

end
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%
function [y,dummyMAC] = getMAC(x0,x1,eps)
    Num = abs(x0(:)'.x1(:)).^2;
    D1= x0(:)'.x0(:);
    D2= x1(:)'.x1(:);
    dummyMAC = Num/(D1..D2);
    if dummyMAC >(1-eps)
        y = 1;
    else
        y = 0;
    end
end
end
end

```

Função de Treinamento da Rede Neural

```

function [net,r] = treina_rede(X,T,n_delay,n_hidden)

% This script assumes these variables are defined:
%
%   forca_1 - input time series.
%   sensor_1 - target time series.

X = tonndata(X,false,false);
T = tonndata(T,false,false);

% Choose a Training Function
% For a list of all training functions type: help nntrain
% 'trainlm' is usually fastest.
% 'trainbr' takes longer but may be better for challenging problems.
% 'trainscg' uses less memory. Suitable in low memory situations.
trainFcn = 'trainlm'; % Levenberg-Marquardt backpropagation.

% Create a Time Delay Network
inputDelays = 1:n_delay;
hiddenLayerSize = n_hidden;
net = timedelaynet(inputDelays,hiddenLayerSize,trainFcn);

% Prepare the Data for Training and Simulation
% The function PREPARETS prepares timeseries data for a particular
network,
% shifting time by the minimum amount to fill input states and layer
% states. Using PREPARETS allows you to keep your original time series
data
% unchanged, while easily customizing it for networks with differing
% numbers of delays, with open loop or closed loop feedback modes.
[x,xi,ai,t] = preparets(net,X,T);

% Setup Division of Data for Training, Validation, Testing
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;

% Train the Network
[net,tr] = train(net,x,t,xi,ai);

% Test the Network
y = net(x,xi,ai);
e = gsubtract(t,y);
performance = perform(net,t,y)
r = regression(t,y)

% View the Network
%view(net)

% Plots
% Uncomment these lines to enable various plots.
%figure, plotperform(tr)
%figure, plottrainstate(tr)
%figure, ploterrhist(e)
%figure, plotregression(t,y)
%figure, plotresponse(t,y)
%figure, ploterrcorr(e)
%figure, plotinerrcorr(x,e)

```

Comparativo entre MACs

```

%% Comparando os MACs

clear all
clc

modo1 = load('modos_v100.mat')
modo2 = load('modos_v125.mat')
modo3 = load('modos_v150.mat')
modo4 = load('modos_v175.mat')
modo5 = load('modos_v200.mat')

mac = crossMAC(modo1.phi0(1:4,1:6)',modo2.phi0');
xlabel('Modos de 10 m/s')
ylabel('Modos de 12,5 m/s')

mac = crossMAC(modo1.phi0(1:4,1:6)',modo3.phi0')
xlabel('Modos de 10 m/s')
ylabel('Modos de 15 m/s')

mac = crossMAC(modo1.phi0(1:4,1:6)',modo4.phi0')
xlabel('Modos de 10 m/s')
ylabel('Modos de 17,5 m/s')

mac = crossMAC(modo1.phi0(1:4,1:6)',modo5.phi0')
xlabel('Modos de 10 m/s')
ylabel('Modos de 20 m/s')
%
mac = crossMAC(modo2.phi0',modo3.phi0')
ylabel('Modos de 12,5 m/s')
xlabel('Modos de 15 m/s')

mac = crossMAC(modo2.phi0',modo4.phi0')
ylabel('Modos de 12,5 m/s')
xlabel('Modos de 17,5 m/s')

mac = crossMAC(modo2.phi0',modo5.phi0')
ylabel('Modos de 12,5 m/s')
xlabel('Modos de 20 m/s')
%
mac = crossMAC(modo3.phi0',modo4.phi0')
ylabel('Modos de 15 m/s')
xlabel('Modos de 17,5 m/s')

mac = crossMAC(modo3.phi0',modo5.phi0')
ylabel('Modos de 15 m/s')
xlabel('Modos de 20 m/s')
%
mac = crossMAC(modo4.phi0',modo5.phi0')
ylabel('Modos de 17,5 m/s')
xlabel('Modos de 20 m/s')

```

Diagrama de Estabilização:

```

function [h] = plotStabDiag(fn,Az,fs,stablity_status,Nmin,Nmax)
% -----
--
% [h] = plotStabDiag(fn,Az,fs,stablity_status,Nmin,Nmax) plots the
% stabilization diagram of the identified eigen frequencies as a function
% of the model order, calculated with the SSI-COV method.
% -----
--
% Input:
% fn: cell : eigen frequencies identified for multiple system orders.
% Az : vector: Time serie of acceleration response (illustrative purpose)
% fs: sampling frequency
% stablity_status: cell of stability status for each model order
% Nmin: scalar: minimal number of model order
% Nmax: scalar: maximal number of model order
% Output: h: handle of the figure
% -----
--
% See also: SSICOV.m
% -----
--
% Author: Etienne Cheynet, UIS
% Updated on: 08/03/2016
% -----
--
Npoles =Nmin:1:Nmax;
[Saz,f]=pwelch(Az,[],[],[],fs);

h = figure;
ax1 = axes;
hold on;box on
for jj=0:4,
    y = [];
    x = [];
    for ii=1:numel(fn)
        ind = find(stablity_status{ii}==jj);
        x = [x;fn{ii}(ind)'];
        y = [y;ones(numel(ind),1)..Npoles(ii)];
    end
    x1{jj+1}=x;
    y1{jj+1}=y;
end

h1=plot(x1{1},y1{1},'k+','markersize',5);% new pole
h2=plot(x1{2},y1{2},'ko','markerfacecolor','r','markersize',5); % stable
pole
h3=plot(x1{3},y1{3},'bo','markersize',5); % pole with stable frequency
and vector
h4=plot(x1{4},y1{4},'gsq','markersize',5); % pole with stable frequency
and damping
h5=plot(x1{5},y1{5},'gx','markersize',5); % pole with stable frequency
if isempty(h1), h1=0;
elseif isempty(h2), h2=0;
elseif isempty(h3), h3=0;
elseif isempty(h4), h4=0;
elseif isempty(h5), h5=0;
end

H = [h1(1);h2(1);h3(1);h4(1);h5(1)];
legend(H,...
'new pole',...

```

```

    'stable pole',...
    'stable freq. & MAC',...
    'stable freq. & damp.',...
    'stable freq. ');

ylabel('number of poles');
xlabel('frequency (Hz)')
xlim([0,max([fn{:}]).1.1])
% hold off

% ax2 = axes('YAxisLocation', 'Right');
% linkaxes([ax1,ax2])
% plot(ax2,f,Saz./max(Saz)..0.001,'k');
% ax2.YLim = [0,Nmax];
% ax2.XLim = [0,max([fn{:}]).1.1];
% set(ax2,'yscale','log')
% ax2.Visible = 'off';
% ax2.XTick = [];
% ax2.YTick = [];
% set(gcf,'color','w')

title('Stabilization Diagram')
grid on
yyaxis right
plot(f,10.log10(Saz./max(Saz)),'k');
ylabel('amplitude [dB]');
ax = gca;
ax.YAxis(1).Color = 'k';
ax.YAxis(2).Color = 'k';

end

```