



Universidade do Estado do Rio de Janeiro

Centro de Tecnologia e Ciência

Faculdade de Engenharia

Luis Antonio Rodrigues Lopes


Sistemas inteligentes aplicados em monitoramento de estrutura aeronáutica

Rio de Janeiro

2013

Luis Antonio Rodrigues Lopes

Sistemas inteligentes aplicados em monitoramento de estrutura aeronáutica



Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao programa de Pós-Graduação em Engenharia Eletrônica da Universidade do Estado do Rio de Janeiro. Área de concentração: Sistemas Inteligentes e Automação.

Orientadores: Prof. Dr. Jorge Luís Machado do Amaral
Prof. Dr. Paulo Bulkool Batalheiro

Rio de Janeiro

2013

CATALOGAÇÃO NA FONTE
UERJ / REDE SIRIUS / BIBLIOTECA CTC/B

L864 Lopes, Luis Antonio Rodrigues.
Sistemas inteligentes aplicados em monitoramento de
estrutura aeronáutica / Luis Antonio Rodrigues Lopes. - 2013.
100 f.

Orientadores: Jorge Luís Machado do Amaral. Paulo Bulkool
Batalheiro.

Dissertação (Mestrado) – Universidade do Estado do Rio de
Janeiro, Faculdade de Engenharia.

1. Engenharia Eletrônica. 2. Sistemas inteligentes –
Dissertação. 3. Aeronáutica - Engenharia de sistemas –
Dissertação. I. Amaral, Jorge Luís Machado do. II. Batalheiro,
Paulo Bulkool. III. Universidade do Estado do Rio de Janeiro.
IV. Título.

CDU 004.272.2

Autorizo, apenas para fins acadêmicos e científicos, a reprodução total ou parcial desta
dissertação, desde que citada a fonte.

Assinatura

Data

Luis Antonio Rodrigues Lopes

Sistemas inteligentes aplicados em monitoramento de estrutura aeronáutica

Dissertação apresentada como requisito parcial para obtenção do título de Mestre, ao programa de Pós-Graduação em Engenharia Eletrônica da Universidade do Estado do Rio de Janeiro. Área de concentração: Sistemas Inteligentes e Automação.

Aprovado em: 19 de Junho de 2013.

Banca Examinadora:

Prof. Dr. Jorge Luís Machado do Amaral (Orientador)
Faculdade de Engenharia - UERJ

Prof. Dr. Paulo Bulkool Batalheiro (Orientador)
Faculdade de Engenharia - UERJ

Prof. Dr. Carlos Roberto Hall Barbosa
Pontifícia Universidade Católica do RJ - PUC-RIO

Prof. Dr. José Gabriel Rodriguez Carneiro Gomes
Universidade Federal do Rio de Janeiro - UFRJ

Rio de Janeiro

2013

DEDICATÓRIA

Aos meus pais que sempre me apoiaram.
À minha esposa que me incentivou e encorajou a enfrentar esse desafio.
Aos meus filhos, minha razão de viver!

AGRADECIMENTOS

Aos Professores Jorge Amaral e Paulo Batalheiro, exemplos de disciplina, dedicação, paciência e amor pela Engenharia. Grandes professores e pesquisadores. Muito obrigado!

A todo o corpo Docente do PEL pela oportunidade que poucos podem ter de desfrutar de seus ensinamentos.

Aos amigos do Parque de Material Aeronáutico do Galeão que me auxiliaram todas as vezes que precisei.

A todos os meus amigos e familiares que contribuíram para essa importante etapa da vida.

RESUMO

LOPES, Luis Antonio Rodrigues. *Sistemas inteligentes aplicados em monitoramento de estruturas aeronáuticas*, 2013. 97f. Dissertação (Mestrado em Engenharia Eletrônica) – Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2013.

Este trabalho apresenta o desenvolvimento de sistemas inteligentes aplicados ao monitoramento de estruturas aeronáuticas abordando dois modelos distintos: o primeiro é a análise e classificação de imagens de ultrassom de estruturas aeronáuticas com objetivo de apoiar decisões em reparo de estruturas aeronáuticas. Foi definido como escopo do trabalho uma seção transversal da asa da aeronave modelo Boeing 707. Após a remoção de material superficial em áreas comprometidas por corrosão, é realizada a medição da espessura ao longo da área da peça. Com base nestas medições, a Engenharia realiza a análise estrutural, observando os limites determinados pelo manual de manutenção e determina a necessidade ou não de reparo. O segundo modelo compreende o método de impedância eletromecânica. É proposto o desenvolvimento de um sistema de monitoramento de baixo custo aplicado em uma barra de alumínio aeronáutico com 10 posições de fixação de porcas e parafusos. O objetivo do sistema é avaliar, a partir das curvas de impedância extraídas do transdutor PZT fixado na barra, sua capacidade de classificar a existência ou não de um dano na estrutura e, em caso de existência do dano, indicar sua localização e seu grau de severidade. Foram utilizados os seguintes classificadores neste trabalho: máquina de vetor de suporte, redes neurais artificiais e K vizinhos mais próximos.

Palavras-chave: Classificadores; Reparo estrutural; Ultrassom; Manutenção aeronáutica; Monitoramento de estruturas; Impedância eletromecânica; Sistemas inteligentes; Processamento multitaxas.

ABSTRACT

This work presents the development of intelligent systems applied to the monitoring of aircraft structures addressing two distinct models: the first is the analysis and classification of ultrasound images of aircraft structures in order to support decisions on repair of aircraft structures. A scope of work was defined as a cross section of the wing of the aircraft model Boeing 707. After the removal of surface material in damaged areas by corrosion, thickness measurements in the whole structure are evaluated. Based on the measurements, the Engineering performs structural analysis, observing the limits determined by the maintenance manual and determining the necessity of repair. The second model includes the method of electromechanical impedance. It is proposed to develop a low cost monitoring system applied to an aircraft aluminum bar with 10 positions for fixing nuts and bolts. The goal of the system is to classify an impedance curve in the condition of the aluminum bar if there is or not a damage to the structure and, in case of the existence of damage, indicating their position in the aluminum bar and if the damage is severe or not. The following classifiers were used in this work: support vector machines, artificial neural networks and K nearest neighbors.

Keywords: Classifiers; Structural repair; Ultrasound, Aircraft maintenance; Monitoring structures; Electromechanical impedance; Intelligent systems; Multi rate processing.

LISTA DE ILUSTRAÇÃO

Figura 1– Perda de parte da fuselagem do avião da <i>Aloha Airline</i> em 1988.....	17
Figura 2 - Transdutor PZT e a estrutura monitorada representados por um modelo eletromecânico do tipo massa-mola (Baptista, 2010).....	23
Figura 3– Diagrama esquemático do sistema de atenuação de vibrações (Junior e Silva, 2005).	26
Figura 4– Aparato experimental e detalhe do dano (Junior e Silva, 2005).	27
Figura 5– Diagrama com o modelo de classificação do sistema de monitoramento EMI proposto.	30
Figura 6– Representação gráfica de dados e limites de decisão (Polikar, 2006).....	32
Figura 7– Representação gráfica de uma classificação Bayesiano Normal (Kuncheva, 2004).	35
Figura 8– Representação gráfica de uma classificação KNN.....	35
Figura 9– Modelo genérico de um classificador RNA-MLP (Kuncheva, 2004).....	37
Figura 10– Unidade de processamento de uma RNA (Kuncheva, 2004).....	37
Figura 11– Representação gráfica de uma classificação SVM.....	38
Figura 12 – Analisador de impedância (HP4294A).	45
Figura 13 – Circuito sugerido por (Peairs <i>et al</i> , 2004) para a estimação da impedância do transdutor.	46
Figura 14 – Estrutura básica do classificador.	48
Figura 15 – DMS 2	51
Figura 16 – Exemplo de imagem de ultrassom (12 linhas x 20 colunas).....	51
Figura 17 – Seção danificada com remoção de material (BOEING – <i>service repair maintenance</i> , 1988).	52
Figura 18 – Exemplo de danos reais com os respectivos limites após a remoção de material (BOEING – <i>service repair maintenance</i> , 1988).....	53
Figura 19 – Esquema elétrico do sistema de aquisição de impedância.	56
Figura 20 – Fluxograma do algoritmo do sistema de medição.....	57
Figura 21 – Desenho da barra de alumínio aeronáutico a ser monitorada.	58
Figura 22 – Sistema de monitoramento de impedância eletromecânica montado para realização de medições.	59
Figura 23 – Barra de alumínio com o sensor piezoelétrico.	60

Figura 24 – Exemplo de curva de impedância extraída pelo sistema proposto na condição da barra sem dano.....	60
Figura 25 – Diagrama do Modelo 1 para cálculo da curva de impedância banda cheia.	63
Figura 26 – Diagrama do Modelo 2 para cálculo da curva de impedância sub-bandas (exemplo com L bandas).	64
Figura 27 – Decimador (Batalheiro, 2000).....	64
Figura 28 – Curva ROC dos resultados do experimento 1.....	68
Figura 29 – Curva ROC dos resultados do experimento 2.....	69
Figura 30 – Curva ROC dos resultados do experimento 3.....	69
Figura 31 – Curva ROC dos resultados do experimento 4.....	70
Figura 32 – Curvas de impedância de um circuito RC para resposta ao sinal <i>chirp</i> de excitação (constante de tempo (a) - 0,01 ms e (b) - 0,1 ms).....	72
Figura 33 – Curvas de impedância de um circuito RC para resposta ao sinal pseudoaleatório de excitação (constante de tempo (a) - 0,01 ms e (b) - 0,1 ms).....	73
Figura 34 – Diagrama com o modelo de classificação do sistema de monitoramento EMI proposto.	74
Figura 35 – Curva ROC para sinal de excitação pseudoaleatório, condição da barra <i>base line</i> e curva de impedância com 32 pontos.	85
Figura 36 – Curva ROC para sinal de excitação pseudoaleatório, condição da barra “dano à direita” e curva de impedância com 32 pontos.....	85
Figura 37 – Curva ROC para sinal de excitação pseudoaleatório, condição da barra “dano à esquerda” e curva de impedância com 32 pontos.....	86
Figura 38 – Curva ROC para sinal de excitação pseudoaleatório, condição da barra “dano longe” e curva de impedância com 32 pontos.	86
Figura 39 – Curva ROC para sinal de excitação pseudoaleatório, condição da barra “dano perto” e curva de impedância com 32 pontos.....	87
Figura 40 – Curva ROC para sinal de excitação pseudoaleatório, condição da barra “dano severo” e curva de impedância com 32 pontos.....	87
Figura 41 – Curva ROC para sinal de excitação pseudoaleatório, condição da barra <i>base line</i> e curva de impedância com 32 pontos com limitação de área (<i>zoom</i> da Figura 35).	88

LISTA DE TABELAS

Tabela 1 – Valores médios de acurácia.	54
Tabela 2 – Valor mínimo, médio e máximo de cada variável.	66
Tabela 3 – Resultados dos classificadores (Amaral & Lopes, 2011).	66
Tabela 4 – Resultados do classificador KNN.	67
Tabela 5 – Resultados do experimento 1 (atributos iniciais).	68
Tabela 6 – Resultados do experimento 2 (todos os pontos da imagem).	68
Tabela 7 – Resultados do experimento 3 (seleção dos pontos através de uma busca forçada).	69
Tabela 8 – Resultados do experimento 4 (novos atributos).	70
Tabela 9 – Valores de erro quadrático médio durante a validação com o circuito RC (sinal de excitação <i>chirp</i>).	73
Tabela 10 – Critérios de falhas da barra de alumínio.	75
Tabela 11 – Resultados dos classificadores para critério <i>base line</i>	76
Tabela 12 – Resultados dos classificadores para critério dano(s) à direita.	76
Tabela 13 – Resultados dos classificadores para critério dano(s) à esquerda.	77
Tabela 14 – Resultados dos classificadores para critério dano(s) longe.	77
Tabela 15 – Resultados dos classificadores para critério dano(s) perto.	77
Tabela 16 – Resultados dos classificadores para critério dano severo.	78
Tabela 17 – Resultados dos melhores classificadores por tipo de falha para avaliação banda cheia com 512 pontos.	78
Tabela 18 – Resultados dos classificadores para critério <i>base line</i>	80
Tabela 19 – Resultados dos classificadores para critério dano à direita.	81
Tabela 20 – Resultados dos classificadores para critério dano à esquerda.	81
Tabela 21 – Resultados dos classificadores para critério dano longe.	81
Tabela 22 – Resultados dos classificadores para critério dano perto.	82
Tabela 23 – Resultados dos classificadores para critério dano severo.	82
Tabela 24 – Ajuste do classificador RNA para o critério <i>base line</i>	82
Tabela 25 – Ajuste do classificador RNA para o critério “dano à direita”.	83
Tabela 26 – Ajuste do classificador RNA para o critério “dano à esquerda”.	83
Tabela 27 – Ajuste do classificador RNA para o critério “dano longe”.	83
Tabela 28 – Ajuste do classificador RNA para o critério “dano perto”.	83
Tabela 29 – Ajuste do classificador RNA para o critério “dano severo”.	83

Tabela 30 – Resultados do classificador KNN para sub-bandas critério “dano à direita”.....	90
Tabela 31 – Resultados do classificador KNN para sub-bandas critério “dano longe”.....	90
Tabela 32 – Resultados do classificador KNN para sub-bandas critério “dano severo”.....	91

LISTA DE ABREVIACÕES

- AUC — *Area Under ROC Curve*
- CCD — *Correlation Coefficient Deviation*
- CCDM — *Correlation Coefficient Deviation Metric*
- DAQ — *Data Aquisition*
- DFT — *Discrete Fourier Transform*
- DSP — *Digital Signal Processor*
- DTFT — *Discrete-Time Fourier Transform*
- EMI — *Eletromechanical Impedance Method*
- END — *Ensaio Não Destrutivo*
- FFT — *Fast Fourier Transform*
- FRF — *Funções de Resposta em Frequência*
- GA — *genetic algorithm*
- GPIB — *General Purpose Interface Bus*
- IDFT — *Inverse Discrete Fourier Transform*
- KNN — *K Nearest Neighbors*
- LDC — *Linear Discriminant Classifier*
- LIT — *Sistema Linear Invariante no Tempo*
- MAPD — *Mean Absolute Percentage Deviation*
- MLP — *multilayer perceptron*
- PZT — *Pb-Lead Zirconate Titanate (Titanato zirconato de chumbo)*
- RC — *Resistor Capacitor*
- RMSD — *Root Mean Square Deviation*
- RNA — *Rede Neural Artificial*
- ROC — *Receiver Operating Characteristic*
- SHM — *Structural Health Monitoring*
- SVM — *Support Vector Machines*
- TF — *Transformada de Fourier*
- WS — *wing station*

SUMÁRIO

INTRODUÇÃO.....	14
1. MONITORAMENTO DE ESTRUTURAS	16
1.1. Conceitos básicos	16
1.1.1. Monitoramento de Integridade Estrutural	17
1.1.2. <u>Prognóstico de dano</u>	18
1.2. Revisão da literatura.....	19
1.2.1. <u>Medição de espessura utilizando técnica de ultrassom</u>	21
1.2.2. <u>Monitoramento de estrutura baseado em impedância eletromecânica</u>	22
1.3. Desafios na detecção de falhas em estruturas aeronáuticas	25
1.4. Contribuições deste trabalho	28
2. FUNDAMENTOS DE RECONHECIMENTO DE PADRÕES.....	31
2.1. Conceitos básicos	31
2.2. Projeto de um sistema classificador	33
2.3. Descrição dos algoritmos de reconhecimento de padrões.....	34
3. SISTEMAS DE AQUISIÇÃO DE IMPEDÂNCIA.....	41
3.1. Sinais discretos e sistemas lineares	41
3.2. Transformada de Fourier	42
3.2.1. <u>A transformada de Fourier no tempo discreto</u>	43
3.2.2. <u>A Transformada Discreta de Fourier</u>	44
3.3. Sistemas de aquisição de impedância eletromecânica aplicados em monitoramento de estruturas	45
4. SISTEMA PROPOSTO	48
4.1. Estrutura básica do classificador	48
4.2. Sistema classificador para apoio à decisão em reparo estrutural de componentes aeronáuticos.....	49
4.2.1. <u>Extração de imagens de ultrassom</u>	49
4.2.2. <u>Medição de espessura</u>	50
4.2.3. <u>Crterios de análise das medições de espessura</u>	52
4.2.4. <u>Pré-processamento das imagens de ultrassom</u>	53
4.3. Sistema de monitoramento de impedância eletromecânica.....	54
4.3.1. <u>Protótipo de um sistema de monitoramento de impedância eletromecânica</u>	55
4.3.2. <u>Sinal de excitação do sistema</u>	61
4.3.3. <u>Pré-processamento das curvas de impedância</u>	62

4.3.4.	<u>Escolha da faixa de frequência e uso de banco de filtros</u>	62
5.	RESULTADOS	65
5.1.	Resultados do sistema classificador para apoio a decisão em reparo estrutural de componentes aeronáuticos.....	66
5.2.	Resultados do sistema inteligente de monitoramento de integridade estrutural baseado em impedância eletromecânica.....	70
5.2.1.	<u>Validação do sistema de aquisição de impedância</u>	71
5.2.2.	<u>Validação do sistema de monitoramento de integridade estrutural</u>	74
5.2.3.	<u>Avaliação do sistema para banda cheia</u>	75
5.2.4.	<u>Avaliação do sistema para banda cheia com curva de 32 pontos</u>	80
5.2.5.	<u>Avaliação do sistema para sub-bandas</u>	88
6.	CONCLUSÃO.....	92
	REFERÊNCIAS	94

INTRODUÇÃO

Nas diferentes áreas da Engenharia, o interesse nas técnicas e métodos aplicados no monitoramento de estruturas aumenta continuamente em função de diferentes motivos: aumento da segurança operacional, redução de custos com manutenção e reparo, eficiência logística, dentre outros. O monitoramento de estruturas possibilita dentro de uma análise mais específica benefícios efetivos, tais como o apoio a reparos estruturais e a realização do prognóstico de dano, ou seja, saber no presente qual a vida útil de um determinado componente ou por quanto tempo a estrutura poderá operar até a necessidade de realização de um reparo ou inspeção.

Em especial, a manutenção aeronáutica tem evoluído rapidamente. Novas tecnologias surgem a todo instante e o apelo por redução de custos e cronogramas cada vez mais dinâmicos obriga toda a engenharia envolvida na manutenção aeronáutica a buscar soluções para os diversos tipos de problemas.

Neste contexto, esta dissertação apresenta o desenvolvimento de sistemas inteligentes capazes de monitorar estruturas e classificá-las quanto às diferentes condições. Em um primeiro momento é feita uma análise e classificação de imagens de ultrassom de estruturas aeronáuticas com o objetivo de apoiar decisões sobre reparos estruturais. Foi definido como escopo do trabalho uma seção transversal da asa da aeronave modelo Boeing 707. Em função da remoção de material superficial em áreas comprometidas por corrosão, é realizada a medição da espessura ao longo da área da peça. Com base nessas medições, a Engenharia realiza a análise estrutural, observando os limites determinados pelo manual de manutenção e determinando a necessidade ou não de reparo.

Um segundo modelo compreende o método de impedância eletromecânica aplicado no desenvolvimento de um sistema inteligente de monitoramento de baixo custo. Esse sistema irá monitorar uma barra de alumínio aeronáutico com 10 posições para fixação de porcas e parafusos. O objetivo do sistema é avaliar sua capacidade de classificar uma curva de impedância quanto à condição da barra de alumínio, no caso, se existe ou não um dano na estrutura e, em caso da existência do dano, indicar a sua posição na barra de alumínio e se o dano é severo ou não.

Na estruturação deste trabalho, no Capítulo 1 é feita uma revisão bibliográfica de trabalhos anteriores que apresentam o desenvolvimento de métodos aplicados nesta dissertação, como por exemplo, o método de monitoramento de impedância eletromecânica.

Neste mesmo capítulo são apresentados os desafios na detecção de falhas estruturais e as contribuições deste trabalho.

O Capítulo 2 apresenta os fundamentos do reconhecimento de padrões. São descritas as bases para o desenvolvimento de um sistema classificador inteligente e os algoritmos utilizados durante o trabalho.

A fundamentação matemática utilizada neste trabalho para a extração de curvas de impedância no domínio da frequência é apresentada no Capítulo 3. Em seguida, alguns sistemas de aquisição de impedância encontrados na bibliografia são apresentados, bem como o sistema desenvolvido para esta dissertação.

Por sua vez, o Capítulo 4 inicia com a apresentação da estrutura básica do classificador utilizado pelo sistema proposto. Em seguida são apresentados os modelos utilizados tanto na classificação das imagens de ultrassom como também no sistema de monitoramento de impedância eletromecânica. Neste capítulo também são abordados os modelos de classificação das curvas de impedância, com propostas para realização em banda cheia e em sub-bandas.

No Capítulo 5 são apresentados os resultados das avaliações dos classificadores e seus respectivos desempenhos. A partir dessa análise, é possível extrair as conclusões a respeito do problema apresentado inicialmente e da capacidade do sistema proposto em classificar as condições apresentadas na estrutura.

Por fim, no Capítulo 6 encontram-se as conclusões desta dissertação e algumas propostas para trabalhos futuros.

1. MONITORAMENTO DE ESTRUTURAS

Este capítulo descreve os conceitos básicos de monitoramento de estruturas, em especial o monitoramento de estruturas aeronáuticas. Será abordado um importante processo de diagnóstico de dano denominado *Structural Health Monitoring* (Farrar *et al*, 2005) e como as suas diferentes técnicas aplicadas nas mais diversas áreas da Engenharia contribuem para o aperfeiçoamento da indústria de manutenção.

Ainda, é apresentada uma breve revisão de literatura, descrevendo diferentes trabalhos nessa área e como o desenvolvimento de sistemas inteligentes pode contribuir com novas técnicas e soluções.

1.1. Conceitos básicos

Nas diferentes áreas da Engenharia, o interesse nas técnicas e métodos aplicados no monitoramento de estruturas aumenta continuamente em função de diferentes motivos: aumento da segurança operacional, redução de custos com manutenção e reparo, eficiência logística, dentre outros. O monitoramento de estruturas possibilita, dentro de uma análise mais específica, a realização do prognóstico de dano, ou seja, saber no presente qual é a vida útil de um determinado componente ou por quanto tempo a estrutura poderá operar até a necessidade de realização de um reparo ou inspeção.

Conhecer o momento mais apropriado para interromper a operação de um sistema para realizar um reparo ou uma inspeção programada traz enormes benefícios para o operador, sobretudo em relação aos aspectos logísticos e de redução de custos. (Hall *apud* Franco, 2009) menciona os altos custos de manutenção e reparo no ciclo de vida de um avião de médio porte, podendo chegar a 27% dos gastos totais.

Além da redução de custo, a questão da segurança operacional é sempre um fator relevante, sobretudo, no caso da indústria aeronáutica, onde a segurança de voo é fator prioritário em função do risco de vida para passageiros e tripulação em caso de acidentes. Neste contexto, o monitoramento de estruturas torna-se ainda mais relevante e apresenta-se como um potencial substituto dos conceitos de manutenção programada por tempo ou horas de voo, visto que falhas imprevistas podem acontecer em diferentes sistemas e estruturas.

(Palomino, 2008) cita, como exemplo, um acidente aeronáutico ocorrido em abril de 1988 com uma aeronave da *Aloha Airlines*, modelo Boeing 737. Em pleno voo uma parte da fuselagem se separou da estrutura da aeronave, conforme visto na Figura 1, provocando uma aterrissagem de emergência.



Figura 1– Perda de parte da fuselagem do avião da *Aloha Airline* em 1988.

É mister a determinação da vida útil de um sistema ou componente bem como a possibilidade de detectar em tempo real uma falha desse mesmo sistema ou componente. Porém, muitos autores questionam a aplicabilidade dos métodos existentes, no tocante à eficiência dos sistemas de monitoramento e à viabilidade de implementação dos mesmos. O processo conhecido como Monitoramento de Integridade Estrutural (SHM, do inglês *Structural Health Monitoring*) possui atualmente um avanço considerável em produção científica no mundo todo, visto que engloba todos os conceitos citados anteriormente, como monitoramento de estrutura e diagnóstico de dano (Farrar *et al*, 2005), (Júnior e Silva, 2005) e (Park e Inman, 2005).

1.1.1. Monitoramento de Integridade Estrutural

O Monitoramento de Integridade Estrutural, de acordo com (Farrar *et al*, 2005), é o processo de detecção de dano dentro do contexto de aplicações voltadas para diversas áreas da engenharia como aeroespacial, civil e mecânica. O SHM envolve a observação de um sistema por meio de amostragens periódicas de sua resposta dinâmica utilizando um conjunto de sensores e a análise estatística dos atributos dessas medições com o objetivo de determinar a presente condição do sistema.

O conceito de monitoramento em tempo real é a essência do SHM, porém algumas técnicas de avaliação de estruturas e localização de danos são aplicadas periodicamente e alguns autores abordam tais conceitos como sendo um método de monitoramento de estrutura. Um bom exemplo são os ensaios não destrutivos (testes radiográficos, ensaios por ultrassom, líquidos penetrantes, partículas magnéticas e outros) realizados em inspeções periódicas.

Segundo (Doebbling *apud* Junior, 2005) o processo do SHM pode ser dividido em quatro níveis:

1. Detectar a existência do dano;
2. Detectar e localizar o dano;
3. Detectar, localizar e quantificar o dano;
4. Detectar, localizar e quantificar o dano e estimar a vida útil remanescente.

A aplicabilidade define qual nível atende ao objetivo proposto para solução do problema. Porém sabe-se que normalmente os níveis 1 e 2 não atendem a uma solução necessária.

1.1.2. Prognóstico de dano

Conforme (Farrar *et al*, 2005), prognóstico de dano é definido como um conceito relevante dentro do SHM e uma tentativa de estimar a vida útil remanescente de uma estrutura danificada quando submetida a diferentes cargas. Esta estimativa é baseada na produção de modelos preditivos que se desenvolvem por meio da correlação entre informações do monitoramento de uso do sistema, SHM, condições ambientais passadas, presentes e futuras, condições operacionais e projeto.

Ainda segundo (Farrar *et al*, 2005), um dano em uma estrutura ou em um sistema mecânico deve ser definido como uma mudança intencional ou não intencional do material e/ou das propriedades geométricas do sistema, incluindo as mudanças nas condições de

contorno e nos sistemas conectados, os quais afetam em geral negativamente o desempenho atual e futuro daquele sistema. Como exemplo, uma trinca formada em uma peça mecânica produz uma mudança geométrica que altera as suas características de rigidez. Dependendo da localização da trinca e da carga aplicada ao sistema, o efeito adverso desse dano no desempenho do sistema pode ser imediato ou levar algum tempo para ser observado.

1.2. Revisão da literatura

Diante do cenário apresentado, foi realizada uma revisão da literatura na busca de trabalhos feitos dentro dessa linha de pesquisa e com objetivo de fundamentar uma contribuição para a área de monitoramento de integridade estrutural por meio do desenvolvimento de sistemas inteligentes.

O monitoramento de estruturas se caracteriza pela aplicação de diferentes conhecimentos em diversas disciplinas. (Farrar *et al*, 2005) descreve de uma forma resumida as áreas de conhecimento aplicadas ao SHM e ao prognóstico de dano: Engenharia Mecânica, Confiabilidade, Engenharia Elétrica, Ciência da Computação, Informática, Ciência dos Materiais, Matemática e Estatística. Dentro do grupo Matemática e Estatística, (Farrar *et al*, 2005) cita ainda o reconhecimento de padrões como uma disciplina aplicada.

Durante a pesquisa de artigos publicados na área, foi observado que o desenvolvimento de sistemas inteligentes em trabalhos de monitoramento de estruturas ainda não é tão difundido quanto a utilização de modelos estatísticos. Estes, por sua vez, são largamente utilizados no uso da análise das medições dos sensores dos sistemas de SHM ou mesmo para a extração de atributos desses mesmos sistemas de monitoramento, conforme observado nas descrições resumidas das referências ao longo deste capítulo.

Foi mencionado anteriormente que em um processo de SHM é necessária a extração de atributos das medições obtidas pelos sensores responsáveis pelo monitoramento do sistema. A extração dos atributos remete aos modelos de reconhecimento de padrões, porém, em geral, para os métodos que utilizam a análise de impedância de sensores, é recorrente o uso de modelos estatísticos. Estes modelos determinam uma métrica, normalmente conhecida como métrica de dano, que tem como conceito básico a medição de dano por meio da relação entre um sinal medido com a estrutura em condição sem dano (*base line*) e o sinal medido com a estrutura em condição com dano. Diversos trabalhos como (Baptista, 2011), (Baptista,

2010), (Finzi Neto, 2010), (Bhalla, 2009), (Franco, 2009), (Giurgiutiu, 2005), (Giurgiutiu, 2003), (Koo, 2008), (Park, 2003), (Sun, 1995), dentre outros, demonstram o uso de modelos estatísticos para a extração de atributos dos sinais observados pelos sensores.

O Desvio da Raiz Média Quadrática (RMSD, do inglês *Root Mean Square Deviation*) que é utilizado como uma métrica de falha (sua formulação é descrita no item 1.2.2) tem grande aplicação nos trabalhos pesquisados e reforça a afirmação acima. (Bhalla, 2009) utiliza o RMSD para avaliar o uso de diferentes componentes do sistema como condutância, valor absoluto da impedância e valor absoluto da admitância e com isso validar um sistema de baixo custo de aquisição de impedância.

(Finzi Neto, 2010), também buscou em seu trabalho o desenvolvimento de um sistema de aquisição de impedância de baixo custo, porém multiplexado para permitir o monitoramento de sinais de diferentes sensores. O uso do RMSD novamente é aplicado na avaliação das curvas de impedância, sendo que inicialmente foi estabelecido o uso do valor absoluto da impedância para a aquisição dos índices de métrica de dano.

Uma grande quantidade de trabalhos referenciados nesta dissertação utiliza a técnica de monitoramento de impedância eletromecânica (a técnica é descrita no item 1.2.2) que tem grande aplicação em sistemas SHM. (Giurgiutiu, 2005) desenvolveu um trabalho de detecção de danos em estruturas aeroespaciais que utiliza a métrica de dano como um índice para avaliar sua severidade. Novamente o índice RMSD foi utilizado, porém outros índices também foram avaliados como o Desvio Médio Percentual Absoluto (MAPD, do inglês *Mean Absolute Percentage Deviation*) e o Desvio do Coeficiente de Correlação (CCD, do inglês *Correlation Coefficient Deviation*). O uso de diferentes índices é uma tentativa de extrair um número maior de atributos e, conseqüentemente, melhorar as avaliações e classificações que são realizadas pelo autor.

Ainda dentro de uma linha de trabalho com foco no desenvolvimento de sistemas de baixo custo de aquisição de impedância, (Koo, 2008) desenvolveu um sistema capaz de compensar automaticamente os efeitos da temperatura sobre o sistema de monitoramento por meio do deslocamento de frequência. Novamente o uso do índice RMSD é aplicado nas análises das curvas de impedância, desta vez com a avaliação adicional das compensações dos efeitos de temperatura.

Assim como (Koo, 2008), (Baptista, 2011) também desenvolveu um sistema de compensação de temperatura para monitoramento de impedância eletromecânica, porém em tempo real e multiplexado para vários sensores. Neste trabalho, (Baptista, 2011) utilizou o índice Métrica de Desvio do Coeficiente de Correlação (CCDM, do inglês *Correlation*

Coefficient Deviation Metric) descrito mais à frente no item 1.2.2. (Baptista, 2011) cita o índice RMSD e o porquê da escolha do índice CCDM.

(Palomino, 2008) fez um trabalho voltado para a análise de métricas de dano. O estudo se aprofunda na avaliação do índice RMSD e suas variações. A utilização do índice é feita em diferentes estudos, particularmente em ensaios não destrutivos e em monitoramento de impedância eletromecânica em estruturas aeronáuticas.

(Park, 2003) desenvolve novamente um trabalho de monitoramento de estruturas, mais especificamente na detecção de perda de parafusos em linhas de pressão. O uso do índice RMSD mais uma vez é mencionado, bem como outros índices.

1.2.1. Medição de espessura utilizando técnica de ultrassom

Os métodos de avaliação de integridade estrutural, geralmente denominados como Ensaios Não Destrutivos (END), são caracterizados por manter, após a realização do ensaio de avaliação, as mesmas características da estrutura determinadas anteriormente ao ensaio (Bray, 1992). Geralmente estas técnicas são empregadas no diagnóstico e monitoramento de danos estruturais e a sua capacidade de avaliação de danos pode ser aplicada de duas formas: (1) monitorar as mudanças de sua condição e, se necessário, interromper a operação do equipamento antes que tais condições se deteriore; e (2) garantir que o dano iniciado não se estenda para uma situação de risco (Furtado, 2004).

Os ensaios por ultrassom são caracterizados como uma técnica de avaliação não destrutiva que utiliza ondas ultrassônicas de alta frequência. A faixa normalmente utilizada na detecção de danos varia entre 10^6 a 10^7 Hz, mas testes de ultrassom podem ser utilizados entre 20.000 Hz a 10^9 Hz. Esta técnica é amplamente utilizada e possui um custo de aplicação baixo. Sua principal dificuldade é encontrar um profissional qualificado que seja capaz de calibrar o equipamento e que possa analisar os resultados de forma correta (Bray, 1992).

A dificuldade e o custo com o profissional qualificado necessário na aplicação do método motivam o estudo e o desenvolvimento de sistemas inteligentes para extração e análise automática de imagens de ultrassom.

(Amaral & Lopes, 2011) propõem um método de análise de imagens de ultrassom de estruturas aeronáuticas por meio de sistemas inteligentes. O objetivo da análise é apoiar a decisão quanto à necessidade ou não de reparo da peça. O sistema inteligente incorpora os

critérios de análise previstos no manual do fabricante e, com isso, estabelece uma opção para o auxílio à análise de Engenharia por um sistema autônomo.

1.2.2. Monitoramento de estrutura baseado em impedância eletromecânica

Conforme (Park e Inman, 2005) descrevem, o monitoramento de integridade estrutural baseado na impedância eletromecânica (EMI, do inglês *Eletromechanical Impedance Method*) foi desenvolvido utilizando as propriedades dos materiais piezoelétricos no acoplamento eletromecânico com a estrutura a ser monitorada (Sun *et al*, 1995) de forma a conceber um novo método de avaliação não destrutiva. A concepção básica dessa abordagem é monitorar a variação da impedância mecânica da estrutura causada pela presença de um dano. Em função da dificuldade de obter a medição da impedância mecânica, o método EMI utiliza a impedância elétrica dos materiais piezoelétricos, a qual está diretamente relacionada com a impedância mecânica da estrutura e, conseqüentemente, será afetada pela presença de um dano estrutural. Por meio do monitoramento da impedância elétrica e a comparação com uma medida inicial, é possível determinar quantitativamente se um dano estrutural ocorreu ou é iminente. A técnica EMI fez avanços significativos nos domínios do SHM e END nos últimos 15 anos (Bhalla, 2009).

Para garantir uma alta sensibilidade a um dano pequeno ou incipiente, a impedância mecânica é mensurada em uma faixa de alta frequência (tipicamente maior que 30 kHz). Com isso, o comprimento de onda do sinal de excitação é pequeno e sensível o bastante para detectar pequenas mudanças na integridade estrutural. Como fator positivo adicional, um sinal de excitação na faixa dos *quilohertz* requer um nível de tensão baixo (em muitos casos, menor que 1 volt). Ao integrar o método EMI com transdutores produzidos com materiais inteligentes (Dosch, 1992), ficou demonstrado que o método EMI é adequado para aplicações variadas em SHM.

Isto posto, (Park e Inman, 2005) descrevem os princípios de construção e funcionamento do método EMI. O método de monitoramento da integridade utiliza a impedância elétrica de transdutores, normalmente constituídos de pequenas pastilhas piezoelétricas (PZT, do inglês *Pb-Lead Zirconate Titanate*), para monitorar mudanças na estrutura como rigidez, massa e outras.

Os transdutores piezoelétricos produzem uma carga elétrica quando sofrem estresse mecânico (vibração, compressão ou tração). Por outro lado, uma vibração mecânica é produzida quando o transdutor é excitado com um sinal elétrico. O método EMI utiliza ambas as direções onde cada transdutor permite a excitação forçada da estrutura e, simultaneamente, a medição da impedância elétrica.

Quando um PZT é fixado na estrutura e então excitado por uma corrente elétrica alternada, uma pequena deformação é produzida na pastilha PZT. A resposta da região da estrutura próxima ao PZT à vibração mecânica é transferida de volta ao PZT na forma de uma resposta elétrica. Quando um dano na estrutura causa uma mudança na resposta dinâmica, essa mudança é manifestada na resposta elétrica do PZT.

(Park e Inman, 2005) apresentam o modelo eletromecânico que descreve quantitativamente o processo EMI (vide Figura 2). O PZT normalmente é colado na estrutura a ser monitorada por meio de um adesivo de alta rigidez que pode ser uma cola instantânea à base de cianoacrilato ou uma resina de epóxi.




Figura 2 - Transdutor PZT e a estrutura monitorada representados por um modelo eletromecânico do tipo massa-mola (Baptista, 2010).

O modelo elétrico do PZT conectado à estrutura pode ser descrito pela admitância elétrica no domínio da frequência (Liang *et al*, 1994):

$$Y(\omega) = i\omega a \left(\bar{\epsilon}_{33}^T (1 - i\delta) - \frac{Z_s(\omega)}{Z_s(\omega) + Z_a(\omega)} d_{3x}^2 \hat{Y}_{xx}^E \right), \quad (1)$$

sendo i a unidade imaginária, Y a admitância elétrica (inverso da impedância), Z_a e Z_s as impedâncias mecânicas do PZT e da estrutura, respectivamente, \hat{Y}_{xx}^E o módulo de Young (ou módulo de elasticidade, ou seja, um parâmetro intrínseco do material que descreve a relação entre a tensão aplicada ao material e sua deformação elástica) a um campo elétrico constante, d_{3x} a constante piezoeétrica de acoplamento, $\bar{\epsilon}_{33}^T$ a constante dielétrica a uma tensão

mecânica constante, a uma constante geométrica e δ a perda dielétrica tangente do PZT. Esta equação indica que a impedância elétrica do PZT fixado à estrutura é diretamente relacionada com a impedância mecânica da estrutura a ser monitorada. A variação da impedância elétrica do PZT dentro de uma faixa de frequência é análoga à Função de Resposta em Frequência (FRF) da estrutura a qual contém informações vitais sobre a sua integridade estrutural.

Um dano presente na estrutura causa mudanças diretas em sua rigidez e elasticidade, alterando as características dinâmicas locais. Com efeito, a impedância mecânica é modificada pelo dano estrutural. Desde que as outras propriedades do PZT permaneçam constantes, Z_s determina unicamente a admitância global. Enfim, qualquer mudança na impedância elétrica do PZT é considerada um indicativo de mudança na integridade estrutural.

Implementações experimentais utilizando o método EMI têm sido bem sucedidos em suas conduções em diferentes estruturas: unidades de treliças (Sun *et al*, 1995), estrutura aeronáutica (Chaudhry *et al*, 1995), conjunto de peças de precisão (Lalande *et al*, 1996), juntas estruturais soldadas (Giurgiutiu *et al*, 1999), componentes estruturais de obras civis (Park *et al*, 2000) e ponte de concreto armado (Soh *et al*, 2000).

A identificação e, por vezes, a quantificação do dano é feita por meio da análise das alterações da referida curva de impedância. Realiza-se uma comparação entre a curva de impedância do transdutor com a estrutura em uma condição inicial, considerada íntegra, e a curva de impedância do transdutor após a estrutura receber um dano, gerando assim índices de falha de métrica, como o RMSD, sendo este o mais utilizado, e o CCDM.

Segundo (Giurgiutiu e Rogers, 1998), o índice RMSD é baseado na norma Euclidiana, sendo que alguns pesquisadores ao longo do tempo sugeriram algumas modificações. A forma mais utilizada é calculada por

$$RMSD = \sum_n^N \sqrt{\frac{(Z_{n,d} - Z_{n,h})^2}{Z_{n,h}^2}}, \quad (2)$$

sendo $Z_{n,h}$ a impedância elétrica do transdutor com a estrutura íntegra, e $Z_{n,d}$ a impedância após a ocorrência de um possível dano, ambas medições na frequência n . N é o número total de amostras.

O índice CCDM é obtido por (Marqui *et al*, 2008)

$$CCDM = 1 - \left| \frac{\sum_n^N (Z_{n,h} - \bar{Z}_h)(Z_{n,d} - \bar{Z}_d)}{\sqrt{\sum_n^N (Z_{n,h} - \bar{Z}_h)^2} \sqrt{\sum_n^N (Z_{n,d} - \bar{Z}_d)^2}} \right|, \quad (3)$$

sendo \overline{Z}_h e \overline{Z}_d as médias da impedância na faixa de frequência considerada, obtida antes e depois do dano, respectivamente, dadas por

$$\overline{Z}_h = \frac{1}{N} \sum_n^N Z_{n,h} \quad (4)$$

e

$$\overline{Z}_d = \frac{1}{N} \sum_n^N Z_{n,d} . \quad (5)$$

1.3. Desafios na detecção de falhas em estruturas aeronáuticas

Conforme descrito no início deste capítulo, as grandes áreas da Engenharia e, em especial, a área de manutenção aeronáutica, encontram na necessidade de detecção de falhas em estruturas um grande desafio. Diferentes técnicas foram mencionadas inicialmente, mas esta dissertação se propõe a abordar a contribuição que o desenvolvimento de sistemas inteligentes aplicados a técnicas já conhecidas e experimentadas pode alcançar.

O uso de algoritmos inteligentes é abordado em alguns trabalhos. (Junior e Silva, 2005) propõem um método de monitoramento com uso de transdutores PZT, sendo aplicados algoritmos baseados em inteligência computacional, no caso, algoritmos genéticos e redes neurais artificiais.

Como descrito durante os conceitos básicos de um sistema de monitoramento de estrutura, os modelos conhecidos requerem um grande conjunto de transdutores. (Junior e Silva, 2005) propõem o desenvolvimento de um sistema de controle em malha fechada, mostrado na Figura 3, para atenuação de vibrações em uma chapa metálica. A atenuação é realizada por atuadores piezoelétricos que respondem ao controle realizado por um sistema com sensores igualmente piezoelétricos que monitoram a vibração da chapa.

O modelo do controlador é inicialmente desenvolvido por meio da obtenção das Funções de Resposta em Frequência (FRF) para duas situações: perturbação da chapa por meio de um impacto externo e perturbação da chapa pelos atuadores piezoelétricos. A partir das FRFs é obtida uma matriz de controle. (Junior e Silva, 2005) propõem então a quantificação do dano por meio de um algoritmo genético (GA, do inglês *genetic algorithm*). A escolha dos parâmetros que serão utilizados para quantificar o dano é feita após a

localização da região onde se encontra o dano. Após a definição dos parâmetros, o ajuste da curva FRF na situação com dano é feito por meio da técnica de otimização utilizando GA. Quando a diferença entre as curvas FRF com dano e sem dano (*base line*) é menor que um valor especificado, o processo é encerrado. A diferença entre o sistema de matriz *base line* e o sistema de matriz com dano fornece a quantificação do dano.

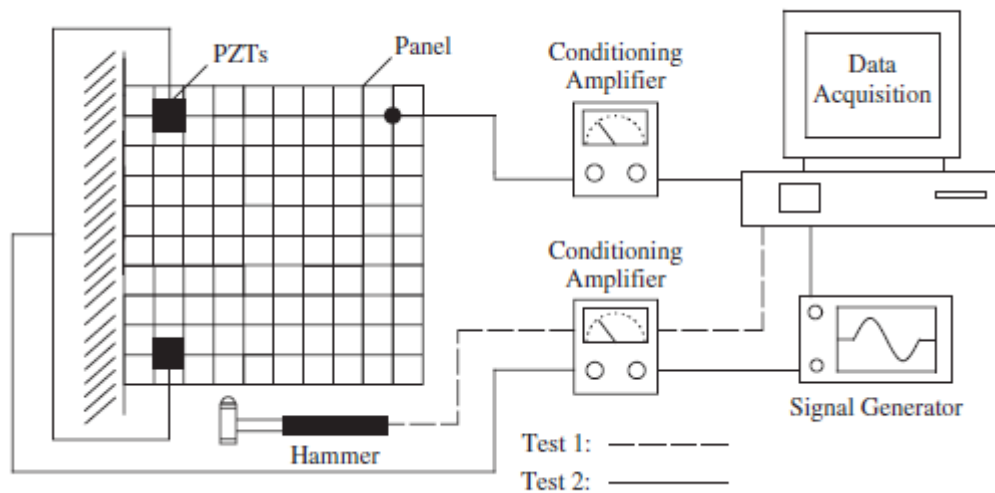


Figura 3– Diagrama esquemático do sistema de atenuação de vibrações (Junior e Silva, 2005).

Para a localização do dano, (Junior e Silva, 2005) propõem o uso de redes neurais e o método de impedância elétrica (EMI). A rede neural é treinada para cada tipo de dano utilizando o sinal de impedância do transdutor PZT e o número de redes neurais é igual ao número de transdutores PZT. Esta mesma técnica utilizando redes neurais é descrita por (Junior e Silva, 2005) em um ensaio com uma estrutura de armação cúbica, conforme visualizado na Figura 4.

Ainda dentro da abordagem do sistema apresentado na Figura 4, diversos transdutores PZT foram colados em diferentes locais na estrutura, preferencialmente nas junções dos tubos. O monitoramento de cada transdutor foi feito individualmente em uma faixa de frequência específica e foi definido um nível limiar para indicação de dano em cada posição. O treinamento da rede foi realizado utilizando um conjunto de dados extraídos a partir de um conjunto de testes realizados, onde cada exemplo possuía uma classificação definida.




Figura 4– Aparato experimental e detalhe do dano (Junior e Silva, 2005).

Após a realização de um pré-processamento, foram definidos os seguintes atributos como entrada para a rede:

- A área entre a curva de impedância com dano e a curva de impedância *base line*
- A média quadrada de cada curva
- A média quadrada da diferença entre a curva com dano e a curva *base line*
- O coeficiente de correlação entre a curva com dano e a curva *base line*

É importante observar que o treinamento da rede neural é feito utilizando os mesmos atributos extraídos por outros autores para a aplicação da métrica de dano. (Junior e Silva, 2005) buscam com este método quantificar o dano e também classificar o mesmo quanto a sua severidade. A localização do dano é feita com base na aplicação de uma rede com vários transdutores. Para o transdutor que sinalizar através de seu indicador a existência de um dano, o sistema automaticamente saberá em qual região está localizado o dano, ou seja, a mesma região onde o transdutor está instalado. Porém o autor não evoluiu quanto à extração de atributos e a outras classificações para o transdutor isoladamente. Por vezes, a instalação de uma numerosa rede de PZT pode inviabilizar um projeto financeiramente e operacionalmente, principalmente pelo aumento do número dos modos de falha do próprio sistema de monitoramento.

(Furtado, 2004) realiza um trabalho similar em que descreve o uso de uma rede neural artificial para quantificar o dano em uma barra de alumínio, utilizando as próprias métricas de falhas para o treinamento da rede e, com isso, alcançar uma capacidade de generalização para quantificar o dano.

O uso de algoritmos inteligentes é descrito em outros trabalhos, nos quais a técnica EMI (descrita no item 1.2.2) foi utilizada com uma finalidade de normalização dos atributos ou uma classificação de métricas. (Park, 2008) utiliza um algoritmo de “clusterização” para definir as regiões de interesse em um espaço amostral a partir de uma gama de ensaios extraídos de um experimento. Por meio do uso de um sistema de reconhecimento de padrões foi possível avaliar os diferentes sistemas de monitoramento. O resultado da classificação são áreas de agrupamento dos índices de métrica obtidos por meio da correlação entre as métricas de 7 (sete) diferentes falhas extraídas de dois diferentes sistemas de monitoramento.

Ficam evidentes as limitações quanto à identificação de outras variáveis do próprio dano como localização, por exemplo, e principalmente a dificuldade em classificar o dano quanto a sua severidade.

Por fim, deve-se ressaltar que, quase na sua totalidade, os modelos de monitoramento EMI avaliam os possíveis danos a partir de uma curva de impedância de referência na condição da estrutura sem dano. Este modelo possui uma grande limitação, pois em condições reais o comportamento de uma estrutura é consideravelmente diverso. Trazendo para o campo da indústria aeronáutica, há dezenas de variáveis que afetam o comportamento mecânico da estrutura, como condições ambientais (temperatura, pressão, etc), diferentes condições de fadiga da própria estrutura para cada aeronave, condições operacionais (volume e peso de carga, características do plano de voo, etc), condições de manutenção, entre outras. Destaca-se que diferentes autores desenvolveram trabalhos direcionados sobre compensações e avaliações do método EMI para alguma condição específica mencionada acima. Há como exemplo (Baptista *et al*, 2011) que desenvolveu um estudo sobre métodos de compensação para os efeitos de temperatura sobre o sistema de monitoramento. Outro exemplo é um estudo feito por (Bitencourt *et al*, 2007) sobre a avaliação das falhas de estruturas em ensaios de fadiga. Todos esses aspectos mencionados implicam em dificuldade para o desenvolvimento de sistemas robustos, capazes de generalizar as avaliações e classificações dos sinais provenientes do sistema de monitoramento.

1.4. Contribuições deste trabalho

Este trabalho propõe o desenvolvimento de 2 (dois) sistemas distintos que possam contribuir com os estudos sobre monitoramento de integridade estrutural na indústria de manutenção aeronáutica, principalmente na área de reparo estrutural.

Inicialmente será proposto o desenvolvimento de um sistema classificador para apoio à decisão em reparo estrutural. O sistema classificador analisa imagens de ultrassom originadas de ensaios não destrutivos. Em geral, a análise desse tipo de exame é feito por mão de obra especializada e um sistema inteligente capaz de realizar esta mesma análise poderia propiciar um ganho considerável à cadeia de manutenção aeronáutica.

Em um segundo momento é desenvolvido um sistema inteligente capaz de classificar os sinais provenientes de um sistema de monitoramento de integridade estrutural. Este estudo propõe inicialmente uma nova metodologia para o monitoramento utilizando o método EMI. Será feita a classificação utilizando como dado de entrada a própria curva de impedância, ao contrário de quase a totalidade dos trabalhos realizados até o momento que utilizam atributos extraídos da relação entre a curva da estrutura em condição sem dano e a curva da estrutura na condição com dano. Os ensaios do sistema proposto neste trabalho foram realizados em uma barra de alumínio, conforme detalhado no item 4.3.1, com a fixação de um transdutor neste protótipo, mais precisamente no centro da barra.

O sistema inicialmente classifica a curva de impedância como falha ou não falha, sendo esta a avaliação primária de qualquer sistema de monitoramento de estruturas. Em seguida, o sistema classificador é direcionado para as classes distribuídas entre posição, distância e severidade. A Figura 5 mostra o diagrama em blocos do modelo da classificação a ser implementado.

Cabe ressaltar que o sistema proposto foi desenvolvido por meio de ensaios realizados em diferentes condições ambientais de forma que possa reconhecer um padrão de falha independente da condição da barra e das condições ambientais. Foram utilizados diferentes conjuntos de porcas e parafusos, bem como realizados ensaios em dias diferentes, com condições alteradas de temperatura e umidade. Este ensaio é particularmente interessante, pois a capacidade de identificar padrões de falha em uma estrutura, em geral, é consideravelmente limitado para aplicações com apenas um transdutor ou mesmo para aplicações que utilizam o método EMI.

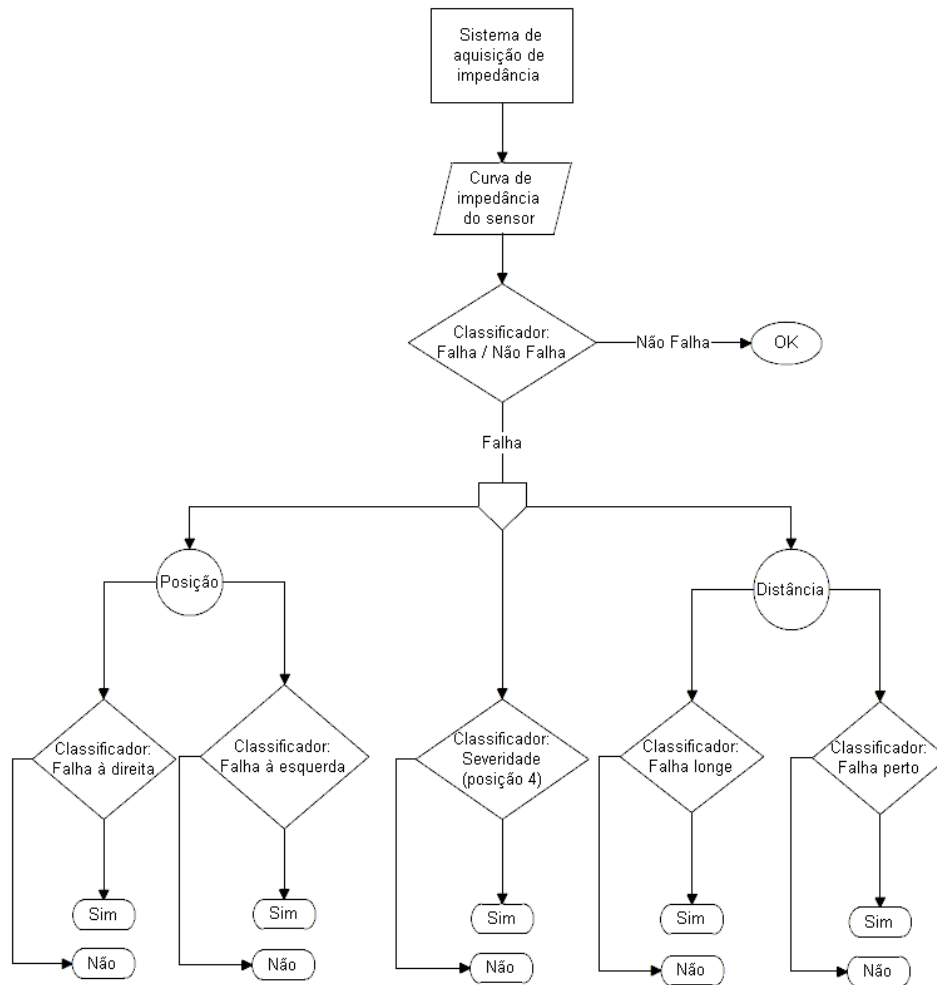


Figura 5– Diagrama com o modelo de classificação do sistema de monitoramento EMI proposto.

O reconhecimento de um padrão de falha torna-se igualmente interessante para a indústria aeronáutica, pois em estruturas de aeronaves, por vezes, deseja-se monitorar determinados pontos ou áreas críticas conforme definido pelo fabricante. A criticidade de determinados pontos ou áreas advém tanto do histórico de falhas da própria estrutura como também de estudos do fabricante durante o desenvolvimento do projeto.

2. FUNDAMENTOS DE RECONHECIMENTO DE PADRÕES

O estudo sobre reconhecimento de padrões deriva da necessidade de automatizar a identificação de objetos, sinais e imagens, ou de automatizar tomadas de decisões a partir de um conjunto de parâmetros. Mesmo após meio século de produção científica, reconhecimento de padrões continua a ser uma área rica em pesquisas em função de diversos casos não solucionados assim como do rápido crescimento do número de aplicações que podem se beneficiar por esse estudo (Polikar, 2006).

2.1. Conceitos básicos

Um sistema de reconhecimento de padrões possui uma terminologia própria para diferentes componentes que tipicamente o formam. (Polikar, 2006) descreve individualmente cada componente, conforme a seguir:

- *Atributos* – conjunto de variáveis (mensuradas ou observadas) que se acredita conterem informações características sobre o objeto a ser identificado.
- *Vetor de atributos* – um grupo de d atributos, ordenados em um determinado modo em d -dimensões. O espaço d -dimensional em que se encontra o vetor de atributos é conhecido como espaço de atributos.
- *Classe* – categoria a qual um dado objeto pertence.
- *Padrão* – conjunto de atributos de um objeto considerado junto com a informação correta de suas classes.
- *Exemplo* – qualquer amostra do padrão de um objeto.

O objetivo de um sistema de reconhecimento de padrões é estimar de forma correta a classe correspondente, com base no vetor de atributos e no conhecimento *a priori* obtido por meio de um treinamento.

- *Treinamento* – procedimento pelo qual um sistema de reconhecimento de padrões aprende a relação de mapeamento entre vetores de atributos e suas correspondentes classes.

- *Limites de decisão* – limites definidos dentro do espaço de atributos e durante o treinamento, que são responsáveis por separar os padrões nas diferentes classes correspondentes.

A Figura 6 ilustra essas concepções em um hipotético espaço bidimensional, para um problema de 4 classes.

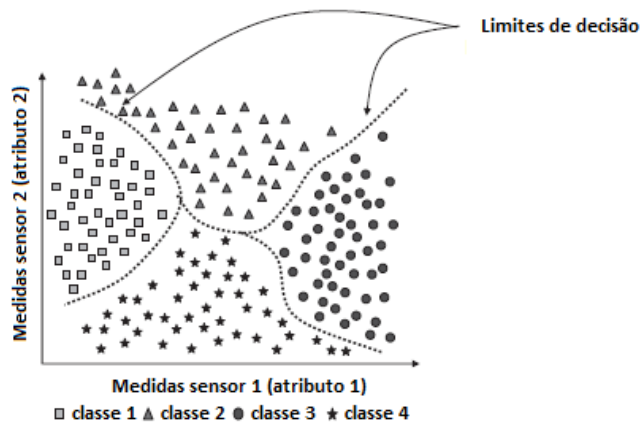


Figura 6– Representação gráfica de dados e limites de decisão (Polikar, 2006).

(Polikar, 2006) cita ainda que o algoritmo de reconhecimento de padrões é usualmente treinado utilizando dados de treinamento, sendo que *a priori* a classe de cada exemplo é conhecida. O desempenho do algoritmo é então avaliado em um conjunto de teste à parte ou em uma validação de dados, sendo que os dados utilizados nesses testes são coletados na mesma época ou então retirados dos dados de treinamento existentes.

Uma medida quantitativa que representa o custo de fazer uma classificação errada é chamada de função custo. O algoritmo de reconhecimento de padrões é especificamente treinado para minimizar esta função. Um classificador é um sistema de reconhecimento de padrões que ajusta seus parâmetros para achar corretamente os limites de decisão por meio de um algoritmo de aprendizado e utilizando um conjunto de dados de treinamento, de tal forma que uma função custo é minimizada. Uma classificação incorreta de um dado feito pelo classificador é considerada um erro e o custo de realizar uma decisão incorreta é chamado de custo do erro. Porém, pode-se notar que nem todo erro possui o mesmo custo. Por exemplo, considera-se um problema de estimação de acometimento de enfarto do miocárdio em pacientes por meio da análise de um grupo de atributos obtidos a partir de exames recentes. Neste caso, dois tipos de erro podem existir:

- *Falso positivo* – o paciente está de fato saudável, porém o classificador indica que ele tem potencial para o acometimento de um enfarto. O custo do erro será a dosagem de medicamentos desnecessários.
- *Falso negativo* – o classificador não reconhece os alertas demonstrados nos exames e declara o paciente como saudável. O custo desse erro pode incluir a morte do paciente.

Para situações onde existe diferença de custo de erro entre as classes, os algoritmos de reconhecimento de padrões possuem a capacidade de balancear as funções durante o treinamento. Dois parâmetros são frequentemente utilizados na avaliação do funcionamento de um sistema de treinamento:

- *Desempenho de treinamento* – capacidade do classificador em identificar corretamente as classes de dados de treinamento previamente apresentados para o classificador.
- *Desempenho de generalização* – capacidade do classificador em identificar as classes de padrões não apresentados previamente.

2.2. Projeto de um sistema classificador

A concepção deste projeto passa pelo desenvolvimento de um sistema classificador. Métodos baseados em aprendizado de máquinas têm sido amplamente utilizados no desenvolvimento de classificadores. Esses sistemas podem extrair informações de diferentes avaliações de danos após terem sido treinados a partir de um grupo de exemplos (Kuncheva, 2004), (Amaral *et al*, 2012).

As etapas para o desenvolvimento e avaliação de um sistema classificador compreendem:

- Definição dos classificadores
- Ajuste dos classificadores
- Seleção dos melhores parâmetros
- Comparação entre o desempenho dos diferentes classificadores

A definição dos classificadores passa inicialmente pela experiência do pesquisador e, durante os experimentos, a avaliação da necessidade de substituição de um determinado classificador. Por exemplo, durante os experimentos desta dissertação com os dados dos ensaios do sistema de monitoramento de impedância eletromecânica, foi observado que o

Classificador Linear Bayesiano Normal (do inglês, *Linear Bayes Normal Classifier*) ou Classificador Linear Discriminante (LDC, do inglês *Linear Discriminant Classifier*) apresentou um desempenho insatisfatório. Foi decidido pela substituição do referido classificador por outro de característica similar, no caso as Máquinas de Vetor de Suporte ou SVM Linear (do inglês *Support Vector Machines*). Assim, foram definidos os seguintes classificadores:

- SVM Linear.
- K Vizinhos Mais Próximos (KNN, do inglês *K Nearest Neighbors*).
- Rede Neural Artificial (RNA).
- SVM Radial.

A descrição de cada classificador se encontra no item 2.3.

O ajuste dos classificadores é realizado por meio de um procedimento estabelecido com o objetivo de identificar o desempenho de cada um para uma ampla faixa de parâmetros ou por meio do uso de algoritmos de treinamento. Ao final do processo de ajuste é possível selecionar os melhores parâmetros e, em seguida, realizar a análise dos classificadores por meio de um método comparativo.

2.3. Descrição dos algoritmos de reconhecimento de padrões

O uso de classificadores e seus respectivos algoritmos em um sistema inteligente faz parte da proposta de desenvolvimento desta dissertação. Os seguintes classificadores foram avaliados e em alguns casos testados: LDC (Kuncheva, 2004), (Duda *et al*, 2000) (será visto mais à frente que o classificador LDC foi substituído pelo classificador Máquina de Vetor de Suporte linear), KNN (Kuncheva, 2004), RNA (Haykin, 1999) e SVM (Heijden *et al*, 2004), (Vapnik, 2000).

O classificador Bayesiano Normal (vide Figura 7) apresenta o erro mínimo de acordo com a Teoria de Decisão Bayesiana, quando as classes têm distribuição normal, com matrizes de covariância iguais. Ele é um classificador bastante rápido e pode ser obtido facilmente a partir de um conjunto de treinamento. Ele fornece uma interpretação bastante direta, uma vez que a fronteira de decisão é um hiperplano. Apesar de sua simplicidade, ele é razoavelmente

robusto, e pode prover resultados surpreendentes mesmo quando as classes não apresentam uma distribuição normal (Kuncheva, 2004).




Figura 7– Representação gráfica de uma classificação Bayesiano Normal (Kuncheva, 2004).

O classificador KNN é um dos algoritmos de reconhecimento de padrões mais simples e elegantes que existe (Kuncheva, 2004). Ele possui o que se chama de “aprendizado preguiçoso”, porque o estágio de aprendizado consiste somente no armazenamento de instâncias rotuladas (conjunto de treinamento). Quando uma nova instância tem que ser classificada, o algoritmo encontra as K instâncias de treinamento mais próximas, e a classificação é efetuada, verificando qual rótulo possui a maioria entre as K instâncias. Se $K = 1$, então o rótulo do objeto é igual ao do seu vizinho mais próximo (vide Figura 8).

Exemplo durante execução de teste do classificador




Figura 8– Representação gráfica de uma classificação KNN.

As Redes Neurais Artificiais têm origem na idéia de modelar matematicamente as habilidades intelectuais humanas (Haykin, 1999). Semelhante a um verdadeiro cérebro, uma RNA possui uma estrutura massivamente paralela, e seu modelo busca a capacidade de adquirir, armazenar e utilizar conhecimento experimental. Com efeito, uma RNA exhibe características semelhantes ao do comportamento biológico humano, tais como:

- Procura paralela e endereçamento pelo conteúdo
- Aprendizado
- Associação
- Generalização
- Abstração
- Robustez e degradação gradual

Segundo (Kuncheva, 2004), considerando um problema de reconhecimento de padrões de n -dimensões com c classes, uma rede neural recebe o vetor de atributos $\mathbf{x} = [x_1, \dots, x_n]^T \in \mathfrak{R}^n$ em sua entrada e produz os valores para as c funções discriminantes $g_1(\mathbf{x}), \dots, g_c(\mathbf{x})$ em sua saída. Tipicamente as Redes Neurais Artificiais são treinadas para minimizar o erro quadrático em um conjunto de treinamento supervisionado $\mathbb{Z} = \{z_1, \dots, z_n\}, z_j \in \mathfrak{R}^n$, e $l(z_j) \in \Omega$, dado por

$$E = \frac{1}{2} \sum_{j=1}^N \sum_{i=1}^c \left\{ g_i(z_j) - \mathcal{T}(\omega_i, l(z_j)) \right\}^2, \quad (6)$$

onde $\mathcal{T}(\omega_i, l(z_j))$ é uma função indicadora que toma o valor igual a 1 se a classe de z_j for ω_i , e 0 (zero) caso contrário. Este modelo caracteriza uma RNA *perceptron* de múltiplas camadas (MLP, do inglês *multi layer perceptron*), sendo esta a mais popular entre as RNA, a qual é aplicada nesta dissertação. A estrutura de uma RNA-MLP é melhor visualizada na Figura 9.

As unidades de processamento em um cérebro humano são os neurônios. Estas unidades possuem diferentes especializações e funções. Um esquema básico de um neurônio de uma RNA pode ser observado na Figura 10.

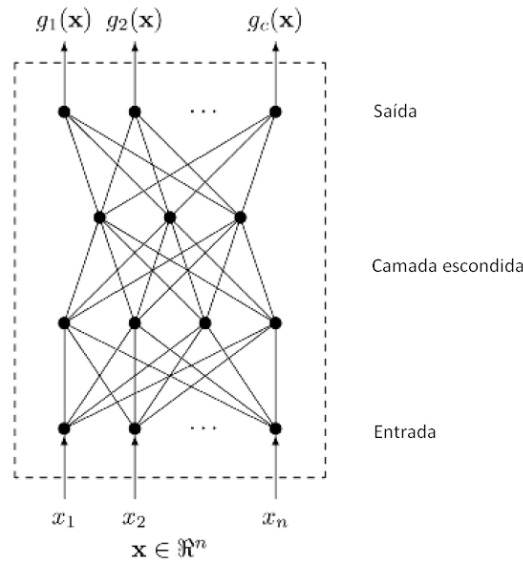


Figura 9– Modelo genérico de um classificador RNA-MLP (Kuncheva, 2004).




Figura 10– Unidade de processamento de uma RNA (Kuncheva, 2004).

Seja $\mathbf{u} = [u_0, \dots, u_q]^T \in \mathbb{R}^{q+1}$ o vetor de entrada para o referido nó e $v \in \mathbb{R}$ sendo sua saída. $\mathbf{w} = [w_0, \dots, w_q]^T \in \mathbb{R}^{q+1}$ é chamado de vetor de *pesos das sinapses*. O elemento de processamento implementa as funções

$$v = \phi(\xi); \quad \xi = \sum_{i=0}^q w_i u_i, \quad (7)$$

onde $\phi: \mathbb{R} \rightarrow \mathbb{R}$ é a *função de ativação* e ξ é a *função de propagação*. Escolhas típicas para ϕ são

- Função threshold

$$\phi(\xi) = \begin{cases} 1, & \text{se } \xi \geq 0, \\ 0, & \text{em outros casos} \end{cases} \quad (8)$$

- Função sigmóide

$$\phi(\xi) = \frac{1}{1 + \exp(-\xi)} \quad (9)$$

- Função identidade

$$\phi(\xi) = \xi \quad (10)$$

As Máquinas de Vetor de Suporte são sistemas de aprendizado baseados na teoria de aprendizado estatístico (Vapnik, 2000) e foram bem sucedidas em diversos problemas de classificação e regressão. Para um problema de classificação com duas classes, em sua forma elementar, o SVM é um classificador linear que realiza a classificação construindo um hiperplano que separa as classes de modo ótimo. A Figura 11 ilustra os vetores de suporte do classificador SVM.

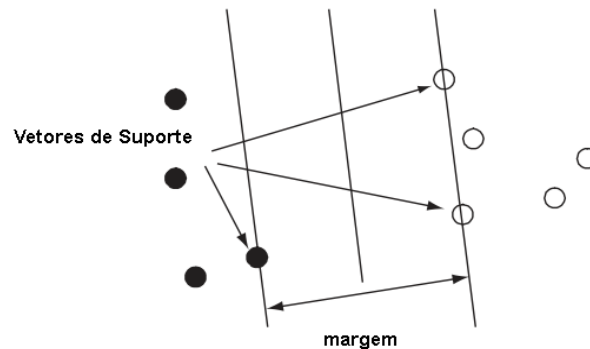


Figura 11– Representação gráfica de uma classificação SVM.

O hiperplano ótimo é aquele que fornece a margem máxima (a margem é definida como a distância entre uma amostra e o hiperplano). Pode-se provar que esta solução em particular tem a maior capacidade de generalização, ou seja, a capacidade de classificar corretamente exemplo futuros. Matematicamente, isto pode ser escrito da seguinte forma (Heijden *et al*, 2004): suponha que as amostras de treinamento são z_n , $n = 1, \dots, N_s$ e que cada amostra é rotulada pelo rótulo $c_n \in \{-1, 1\}$, indicando a qual das duas classes elas pertencem. Então o classificador linear $g(z) = w^T z_n + b$ classificará as amostras do seguinte modo:

$$w^T z_n + b \geq 1 \text{ se } c_n = +1 \quad (11)$$

e

$$w^T z_n + b \leq -1 \text{ se } c_n = -1.$$

Essas duas restrições podem ser escritas usando apenas uma inequação:

$$c_n(w^T z_n + b) \geq 1. \quad (12)$$

O gradiente de $g(z)$ é w . Logo o quadrado da margem é inversamente proporcional a $\|w^2\| = w^T w$. Para maximizar a margem tem-se que minimizar $\|w^2\|$. Usando multiplicadores de Lagrange, pode-se incorporar as restrições da equação (12) e escrever:

$$L = \frac{1}{2} \|w\|^2 + \sum_{n=1}^{N_s} a_n (c_n [w^T z_n + b] - 1), a_n \geq 0, \quad (13)$$

onde L deve ser minimizado em relação a w e b e maximizado em relação aos multiplicadores de Lagrange a_n . Fazendo com que as derivadas parciais de L em relação a w e b sejam iguais a zero, tem-se as seguintes restrições:

$$w = \sum_{n=1}^{N_s} a_n c_n z_n$$

e (14)

$$\sum_{n=1}^{N_s} a_n c_n = 0,$$

o que permite que L possa ser escrito em sua forma dual:

$$L = \sum_{n=1}^{N_s} a_n - \frac{1}{2} \sum_{n=1}^{N_s} \sum_{m=1}^{N_s} c_n c_m a_n a_m z_n^T z_m, a_n \geq 0, \quad (15)$$

devendo, neste caso, L ser maximizado em relação a a_n . Este é um problema de otimização quadrática. Após a otimização, os a_n serão usados para encontrar w . As amostras z_n para as quais $a_n \geq 0$, formam os vetores de suporte. No caso de classes que se sobrepõem, o SVM pode ser estendido para permitir que algumas amostras de treinamento sejam classificadas incorretamente. Neste caso, as restrições são escritas como:

$$w^T z_n + b \geq 1 - \xi_n \text{ se } c_n = +1$$

e (16)

$$w^T z_n + b \leq -1 + \xi_n \text{ se } c_n = -1,$$

onde as variáveis de relaxamento ξ_n são introduzidas. O problema de otimização, agora, passa a ser escrito da seguinte forma:

$$L = \frac{1}{2} w^2 + C \sum_{n=1}^{N_s} \xi_n + \sum_{n=1}^{N_s} a_n (c_n [w^T z_n + b] - 1 + \xi_n) + \sum_{n=1}^{N_s} \gamma_n \xi_n, a_n, \gamma_n \geq 0, \quad (17)$$

onde o parâmetro de regularização C representa o compromisso de se obter uma margem maior ao custo de se ter um maior número de exemplos de treinamento classificados incorretamente, ou ter uma margem menor (menor generalização) e um menor número de erros de classificação no treinamento. Para que seja possível obter fronteiras de decisão não

lineares, um mapeamento não linear pode ser aplicado ao conjunto de treinamento. Esta transformação faz com que os dados sejam representados em um novo espaço de dimensão maior onde as classes possam ser mais facilmente separadas. Isto pode ser facilmente realizado, observando que na Equação (15), a expressão para L está escrita em função de $K(z_n, z_m) = z_n^T z_m$. Logo para que um mapeamento não linear seja aplicado, usando, por exemplo, uma função de base radial, a expressão para $K(z_n, z_m)$ deve ser reescrita como:

$$K(z_n, z_m) = e^{\left(\frac{-\|z_n - z_m\|^2}{r^2}\right)}, \quad (18)$$

onde r é o raio das funções de base radial. Funções polinomiais e de base radial são normalmente os primeiros mapeamentos não lineares a considerar. Embora a superfície de decisão (hiperplano) seja linear neste espaço de dimensão mais alta, quando é vista no espaço original de dimensão mais baixa, ele não é mais linear, permitindo que o SVM também possa ser aplicado a dados que não são linearmente separáveis.

3. SISTEMAS DE AQUISIÇÃO DE IMPEDÂNCIA

Os sistemas de monitoramento de estruturas normalmente empregam sistemas de aquisição de dados, principalmente os sistemas de monitoramento em tempo real. A finalidade é extrair as informações do conjunto de transdutores e, posteriormente, extrair os atributos para avaliação, reconhecimento e classificação. Esta dissertação propõe o desenvolvimento de um sistema de aquisição de impedância simples e barato, visto que para aplicações aeroembarcadas se torna inviável a utilização de sistemas complexos, caros ou pesados, conforme será melhor descrito no item 3.3. Diversos autores têm realizado trabalhos e pesquisas neste sentido e, na maioria dos casos, os sistemas desenvolvidos alcançam um resultado satisfatório.

Este capítulo irá inicialmente descrever as análises de sistemas lineares e a Transformada de Fourier que é uma importante ferramenta matemática para a análise de sinais contínuos e discretos no domínio da frequência. Posteriormente, será feita uma revisão de literatura sobre os sistemas de aquisição de impedância de baixo custo desenvolvidos em trabalhos anteriores e o modelo utilizado nesta dissertação.

3.1. Sinais discretos e sistemas lineares

Dentre as diversas propriedades básicas dos sistemas, duas delas, a invariância no tempo e a linearidade, possuem papel fundamental na análise dos sinais e sistemas por duas razões principais. A primeira diz respeito ao fato de muitos processos físicos terem essas propriedades e, por isso, poderem ser modelados como Sistemas Lineares Invariantes no Tempo (LIT). Além disso, os sistemas LIT podem ser analisados de forma detalhada, facilitando a compreensão de suas propriedades e também fornecendo um conjunto de ferramentas poderosas que formam a base da análise de sinais e sistemas (Oppenheim e Willsky, 2010).

Uma das principais razões dos sistemas LIT serem passíveis de análise é o fato de qualquer sistema desse tipo atender à propriedade de superposição. Como consequência, se for possível representar a entrada de um sistema LIT em termos de uma combinação linear de um conjunto de sinais básicos, então se pode usar o teorema da superposição para computar a

saída do sistema em termos de suas respostas a esses sinais básicos (Oppenheim e Willsky, 2010).

Para este trabalho, haverá um enfoque nos sinais discretos, pois o monitoramento do sistema mecânico é realizado por meio da análise das curvas de impedância de um transdutor que por sua vez é representado por sinais discretos adquiridos por um Dispositivo de Aquisição de Dados (DAQ, do inglês *Data Acquisition*). Portanto, todo o tratamento dos sinais, suas representações e classificações ocorrem em sinais discretos. O item 3.2 descreve os modelos de transformada de Fourier que são importantes ferramentas na análise de sinais no domínio da frequência e nesse mesmo item será dada especial atenção à transformada discreta de Fourier.

3.2. Transformada de Fourier

A análise de Fourier é uma das formas mais tradicionais para tratamento de sinais e séries temporais. Esta técnica foi criada por Jean Baptiste Joseph Fourier e publicada em 1822 no seu trabalho intitulado *Théorie Analytique de la Chaleur*. Fourier dedicou-se na resolução das equações diferenciais que regem a transferência de calor utilizando uma técnica de séries de senos e cossenos (Série de Fourier) para resolver seus problemas.

O que emergiu desse estudo é uma estrutura poderosa e coesa para a análise de séries, sinais e sistemas de tempo contínuo e de tempo discreto, e um conjunto extraordinariamente amplo de aplicações existentes e potenciais.

Segundo (Oppenheim e Willsky, 2010), é vantajoso, no estudo de sistemas Lineares Invariantes no Tempo, representar sinais como combinações lineares de sinais básicos, que possuam as seguintes propriedades:

- O conjunto de sinais básicos pode ser usado para construir uma classe ampla e útil de sinais.
- A resposta de um sistema LIT para cada sinal deve ser simples o suficiente na sua estrutura para fornecer, com uma representação conveniente, a resposta a qualquer sinal construído como uma combinação linear dos sinais básicos.

Grande parte da importância da análise de Fourier resulta do fato de que essas duas propriedades são satisfeitas pelo conjunto de sinais exponenciais complexos no tempo

contínuo e no discreto, ou seja, sinais na forma e^{st} em tempo contínuo e z^n em tempo discreto, sendo s e z números complexos.

3.2.1. A transformada de Fourier no tempo discreto

Conforme (Oppenheim e Willsky, 2010), a utilidade da Transformada de Fourier consiste em permitir a análise de um sinal no domínio do tempo por meio do conteúdo da sua frequência. A transformada funciona levando uma função do domínio do tempo ou espaço para o domínio da frequência. O sinal pode ser analisado então pelo seu conteúdo em termos da frequência, porque os coeficientes de Fourier da função transformada representam a contribuição de cada seno e cosseno a cada frequência. Uma transformada inversa converte a função no domínio da frequência para o domínio do tempo.

A Transformada de Fourier no tempo discreto (DTFT, do inglês *Discrete-Time Fourier Transform*), ou doravante denominada Transformada de Fourier (TF), é a representação de uma sequência discreta arbitrária $x(n)$ em termos de uma sequência de exponenciais complexas $\{e^{-j\omega n}\}$, onde ω é uma frequência real variável. A TF de uma sequência $x(n)$ é contínua e periódica com período 2π (Mitra, 1998), e definida por

$$X(e^{j\omega}) = \sum_{n=-\infty}^{\infty} x(n)e^{-j\omega n}. \quad (19)$$

Em geral $X(e^{j\omega})$ é uma função complexa e pode ser descrita como

$$X(e^{j\omega}) = X_{RE}(e^{j\omega}) + jX_{IM}(e^{j\omega}), \quad (20)$$

onde $X_{RE}(e^{j\omega})$ e $X_{IM}(e^{j\omega})$ são, respectivamente, as partes real e imaginária de $X(e^{j\omega})$.

Alternativamente, pode ser expressa por

$$X(e^{j\omega}) = |X(e^{j\omega})|e^{j\theta(\omega)} \quad (21)$$

sendo $|X(e^{j\omega})| = \sqrt{X_{RE}^2(e^{j\omega}) + X_{IM}^2(e^{j\omega})}$ a função magnitude e $\theta(\omega) = \arg\{X(e^{j\omega})\} = \tan^{-1} \frac{X_{IM}(e^{j\omega})}{X_{RE}(e^{j\omega})}$ a função fase.

O MATLAB[®] dispõe da função *freqz* para computar a Transformada de Fourier, o que permite agilizar o processamento e resultar em ganhos significativos no desenvolvimento do sistema.

3.2.2. A Transformada Discreta de Fourier

Para sequências $x(n)$ de comprimento finito N , existe uma relação mais simples entre esta sequência e sua TF ($X(e^{j\omega})$). Neste caso, somente N valores de $X(e^{j\omega})$, chamados de amostras, são calculados em N pontos discretos de frequência, sendo suficientes para determinar $x(n)$. Isto nos leva ao conceito da Transformada Discreta de Fourier (DFT, do inglês *Discrete Fourier Transform*), que é obtida pela amostragem uniforme de $X(e^{j\omega})$ no eixo ω , entre $0 \leq \omega \leq 2\pi$, em $\omega_k = \frac{2\pi k}{N}$, com $k = 0, 1, \dots, N - 1$. Desta forma a DFT é uma sequência de comprimento finito no domínio da frequência, definida como

$$X(k) = X(e^{j\omega}) \Big|_{\omega_k = \frac{2\pi k}{N}} = \sum_{n=0}^{N-1} x(n) e^{-j\frac{2\pi k}{N}n} \quad (22)$$

A sequência $x(n)$ pode ser recuperada através da Transformada Discreta de Fourier Inversa (IDFT, do inglês *Inverse Discrete Fourier Transform*) dada por

$$x(n) = \frac{1}{N} \sum_{k=0}^{N-1} X(k) e^{j\frac{2\pi k}{N}n} \quad (23)$$

O MATLAB[®] dispõe das funções *fft* e *ifft* para calcular, respectivamente, a DFT e a IDFT.

(Oppenheim e Willsky, 2010) destacam que a DFT desempenha papel fundamental em diversos campos da ciência, como o processamento digital de sinais, a resolução de equações diferenciais parciais, bem como a multiplicação rápida de polinômios e inteiros grandes. Por muitos anos, entretanto, pensou-se que a DFT exigisse $O(N^2)$ operações, onde N é o número de pontos do vetor de entrada. Esta ideia parecia óbvia, já que a Transformada de Fourier pode ser vista como uma multiplicação de uma matriz $N \times N$ por um vetor, entretanto alguns pesquisadores mudaram este cenário drasticamente quando foram formulados algoritmos para cálculo da DFT que realizavam apenas $O(N \log N)$ operações. A estes algoritmos, bem como as suas variantes, dá-se o nome de Transformada de Fourier Rápida (FFT, do inglês *Fast Fourier Transform*).

Este ganho de desempenho é obtido através de uma abordagem conhecida em Ciência da Computação como *dividir para conquistar*. Nesta abordagem, o problema inicial é dividido sucessivamente até que sejam atingidos cálculos elementares, quando então os

resultados parciais são reagrupados para obtenção do resultado final. No caso da DFT, estas divisões são possíveis pelo Lema de *Danielson Lanczos* conforme descrito por (Oppenheim e Willsky, 2010).

3.3. Sistemas de aquisição de impedância eletromecânica aplicados em monitoramento de estruturas

Sistemas de monitoramento de estruturas baseados em impedância eletromecânica requerem um sistema de aquisição de impedância capaz de excitar ao menos um transdutor e medir sua impedância elétrica. O aparelho comercial, que gera o sinal de excitação, adquire o sinal de resposta e processa os dois sinais é denominado analisador de impedância ou impedancímetro. Os analisadores de impedância comerciais, como o HP4294A mostrado na Figura 12, são os mais utilizados em pesquisas no meio acadêmico.



Figura 12 – Analisador de impedância (HP4294A).

Porém, algumas características como o grande peso e volume impossibilitam a utilização destes aparelhos em aplicações aeroembarcadas. Pesa desfavoravelmente também o alto custo destes analisadores comerciais e o uso de apenas um conjunto pequeno de suas funções na técnica da impedância eletromecânica.

Algumas alternativas têm sido propostas com o intuito de substituir o uso de aparelhos como o HP4294A. (Peairs *et al*, 2004) desenvolveram um método que utiliza um pequeno circuito com um custo de apenas US\$ 10,00 e um analisador de sinais com FFT que é comumente encontrado em laboratórios de pesquisa e, ao contrário do impedancímetro, é um instrumento portátil.

(Finzi Net *et al*, 2010) desenvolveu um sistema de aquisição de impedância de baixo custo, inclusive com um sistema multiplexado que permite monitorar os sinais de diferentes sensores ao mesmo tempo. Testes foram realizados com sucesso em estruturas aeronáuticas, mais precisamente em painéis de alumínio de uma aeronave. Como esta dissertação tem foco no estudo da determinação de diferentes classificações, foi adotada uma estrutura com apenas um sensor. Cabe ressaltar ainda que a contribuição de estudos no desenvolvimento de sistemas mais simplificados contribui para o avanço das pesquisas nesta área, visto que a robustez e a redução de custos são elementos relevantes em qualquer projeto industrial.

(Baptista, 2010) descreve resumidamente alguns sistemas de aquisição e suas principais limitações. Em (Peairs *et al*, 2004) foi utilizado um analisador de espectro e um circuito auxiliar simples e de baixo custo, como apresentado na Figura 13. De acordo com os autores, se a resistência R_s é considerada pequena a impedância elétrica do transdutor PZT é dada aproximadamente por $Z = R_s V_i / V_o$, sendo V_i o sinal de excitação e V_o o sinal de resposta do transdutor. Para obter a impedância no domínio da frequência, a TF dos sinais V_i e V_o (considerados na forma discreta) é computada por meio de um analisador de espectro.

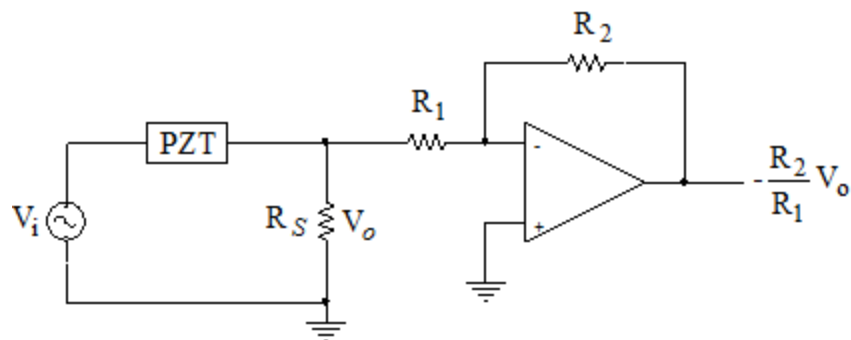


Figura 13 – Circuito sugerido por (Peairs *et al*, 2004) para a estimação da impedância do transdutor.

(Baptista, 2010) cita ainda o analisador de impedância proposto por (Xu e Giurgiutiu, 2005) que usa apenas um resistor como circuito auxiliar e a aquisição do sinal de resposta do transdutor feita por meio de um dispositivo DAQ controlado pelo software LabVIEW[®]. Inicialmente o circuito se apresenta mais simples que o anterior, porém o sinal de excitação é fornecido por um gerador de funções externo que precisa de uma placa GPIB (do inglês *General Purpose Interface Bus*) para ser controlado, tornando assim o sistema mais caro e menos versátil.

Em um momento seguinte, dispositivos sem fio de baixo custo e baixo consumo de energia foram desenvolvidos para a análise de impedância. (Baptista, 2010) cita o sistema sugerido por (Kim *et al*, 2007) o qual é baseado em um Processador Digital de Sinais (DSP, do inglês *Digital Signal Processor*) que utiliza um algoritmo para eliminar o uso de conversores analógico/digital e conversores digital/analógico. Entretanto, a faixa e o passo de frequência em que a impedância pode ser analisada são limitados pela pouca memória do DSP. Como uma consequência, um analisador de impedância comercial de alto custo ainda é necessário para determinar a faixa de frequência mais sensível ao dano estrutural e viabilizar o uso do sistema.

Por fim, (Baptista, 2010) cita os dispositivos propostos por (Park *et al*, 2008), (Overly *et al*, 2007) os quais são baseados no modelo AD5933, um circuito integrado de medição de impedância desenvolvido pela *Analog Devices*. Embora esses dispositivos sejam muito compactos e de baixo custo, o AD5933 permite a medição da impedância elétrica em uma frequência de até 100 kHz, o que pode limitar muitas aplicações em SHM.

4. SISTEMA PROPOSTO

Com base nas observações realizadas nos capítulos anteriores, foram propostos dois sistemas de monitoramento de estruturas aeronáuticas. Primeiramente, é descrita a metodologia empregada para a extração das imagens de ultrassom que formam o conjunto de exemplos utilizados na classificação de estruturas aeronáuticas quanto à necessidade ou não de reparo, bem como o desenvolvimento do sistema proposto para a realização dos ensaios de monitoramento de impedância eletromecânica. Também são descritos os recursos utilizados, o desenvolvimento de protótipos, os processos de levantamento de dados e os classificadores aplicados.

4.1. Estrutura básica do classificador

O desenvolvimento de sistemas inteligentes para monitoramento de integridade estrutural abrange o desenvolvimento de classificadores capazes de apoiar decisões em manutenção através da classificação de atributos extraídos de dados provenientes dos respectivos sistemas de monitoramento.

Isto posto, foi definido um modelo de estrutura básica do classificador, conforme observado na Figura 14.




Figura 14 – Estrutura básica do classificador.

A estrutura básica prevê a classificação dos exemplos em duas classes (falha e não falha). Este modelo é aplicável nos diferentes sistemas de monitoramento desenvolvidos neste

trabalho. A caracterização do classificador com apenas duas classes simplifica a análise do desempenho e permite a inclusão de classificadores para outros objetivos sem a necessidade de realizar novo treinamento nos classificadores existentes, desde que o conjunto de dados permaneça o mesmo. Com efeito, esta estrutura básica atende satisfatoriamente ao objetivo da aplicação de sistemas inteligentes em monitoramento de estruturas, que seria apoiar decisões nas diferentes ações de manutenção.

4.2. Sistema classificador para apoio à decisão em reparo estrutural de componentes aeronáuticos

Conforme descrito no item 1.2.1, o custo no emprego de mão-de-obra qualificada em técnicas de ensaio não destrutivo motivam estudos de otimização destes processos. No caso da indústria de manutenção aeronáutica, resultados de ensaios em geral passam pela avaliação de engenheiros, o que eleva o custo com mão-de-obra, sobrecarrega o pessoal especializado e causa atrasos no processo de manutenção.

Esta dissertação propõe o desenvolvimento de um sistema inteligente capaz de realizar a análise de imagens de ultrassom de estruturas aeronáuticas e classificá-las quanto à necessidade ou não de reparo.

4.2.1. Extração de imagens de ultrassom

Este trabalho direcionou o estudo para as medições de espessura da asa da aeronave modelo Boeing 707. Foi definida uma área específica, mais precisamente a seção transversal da asa da aeronave. A escolha de uma seção transversal específica se deve ao fato de que diferentes seções transversais possuem critérios de análise com diferentes parâmetros para reparo ou não reparo (BOEING – *service repair maintenance*, 1988).

Dentro do plano de manutenção da frota, estão previstas inspeções programadas, nas quais se realizam tarefas de manutenção, também conhecidas como cartões de inspeção. As inspeções na estrutura da aeronave são feitas visualmente ou por meio de ensaios não destrutivos. Quando é encontrada uma região da peça com corrosão, realiza-se um

procedimento de remoção do material superficial da peça. Evidentemente, após a remoção do material, a peça sofre uma perda na sua espessura. Esta perda de espessura precisa ser mensurada, pois se a redução for relevante existe a necessidade de realizar um reparo estrutural, no caso um reforço na área trabalhada.

4.2.2. Medição de espessura

A medição de espessura do painel da asa é realizada por um equipamento que utiliza uma técnica com ultrassom. Vários pontos são medidos, formando uma grade de dados que posteriormente são utilizados para preencher uma planilha. Ao final, a planilha é fornecida à Engenharia, a quem compete analisar e determinar a necessidade ou não de realizar um reparo.

O Parque de Material Aeronáutico do Galeão (PAMAGL) possui um setor de ensaio não destrutivo responsável pelo levantamento dos dados de espessura. Esse setor utiliza para esta inspeção o medidor de ultrassom modelo DMS 2 *Thickness Gage*, da fabricante GE *measurement & control solutions*, conforme apresentado na Figura 15.

Este equipamento é capaz de realizar a medição de espessura de um componente estrutural sem a necessidade de acessar a outra face da peça, pois utiliza uma técnica de ultrassom. Este processo de medição é importante na indústria de manutenção aeronáutica, pois desta forma, a inspeção pode ser realizada sem a necessidade de executar desmontagens de estruturas complexas, o que poderia acarretar em atrasos substanciais dos prazos.

Foram levantadas então planilhas com dados de medições de espessura arquivadas na Engenharia do PAMAGL. Os exemplos são apresentados em planilhas de Excel[®] que contém cada uma a distribuição espacial dos pontos medidos, formando uma matriz 12x20. Cada ponto na planilha possui o valor da diferença entre a medida original da peça e o valor mensurado efetivamente.



Figura 15 – DMS 2

A Figura 16 apresenta um exemplo de imagem de ultrassom após uma primeira etapa do pré processamento. Quanto maior a diferença entre a espessura original e a espessura mensurada, mais escuro fica o ponto (ou pixel).



Figura 16 – Exemplo de imagem de ultrassom (12 linhas x 20 colunas).

4.2.3. Critérios de análise das medições de espessura

Os critérios de análise dos dados de medições de espessura estão definidos no manual de manutenção da aeronave (BOEING – *service repair maintenance*, 1988). O manual de manutenção descreve os procedimentos de análise e reparo da asa para casos de dano e corrosão. Nestes casos o procedimento definido no manual é a remoção de material na superfície danificada.

Conforme observado na Figura 17, esta remoção deve ser feita de forma a manter uma suavização na inclinação do aprofundamento na área onde se encontra o dano. A Figura 18 mostra uma ilustração de danos reais.

Após a remoção do material, são feitas as medições de espessura da área e a Engenharia realiza a análise dos dados. O manual de manutenção define critérios para a análise da peça ou seção da peça. Esses critérios, aliados à análise do Engenheiro, definem a necessidade ou não de reparo da peça.




Figura 17 – Seção danificada com remoção de material (BOEING – *service repair maintenance*, 1988).

A seção transversal definida para o escopo deste trabalho foi a área compreendida entre a WS 340 e a WS 360 (WS, do inglês *wing station*).




Figura 18 – Exemplo de danos reais com os respectivos limites após a remoção de material (BOEING – *service repair maintenance*, 1988).

4.2.4. Pré-processamento das imagens de ultrassom

A análise das imagens de ultrassom passa pela avaliação dos critérios estabelecidos no Manual de Manutenção do fabricante. A partir desses critérios é possível realizar a extração dos atributos das imagens de ultrassom e, em seguida, realizar a classificação quanto à existência ou não de falha. Durante o trabalho realizado em (Amaral & Lopes, 2011), em um primeiro momento foram definidos os seguintes atributos:

- Ponto com maior dano.
- Número de áreas com perda crítica.
- Razão entre o somatório das áreas com perdas e a área total.

Seguiram-se as etapas de desenvolvimento do sistema classificador. Foram utilizados os seguintes classificadores: LDC, KNN, SVM Polinomial (Kuncheva, 2004) e SVM Radial. Por meio do método de validação cruzada foram definidos os parâmetros conforme a seguir:

- LDC – não possui parâmetro de ajuste.
- KNN – número K de vizinhos.
- SVM Polinomial – grau do polinômio e parâmetro de regularização C (compromisso com a generalização).
- SVM Radial – Valor do raio e parâmetro de regularização C.

Após o ajuste dos parâmetros, foram realizados os experimentos com o conjunto de 247 exemplos, com os valores médios de acurácia mostrados na Tabela 1.

Tabela 1 – Valores médios de acurácia.

Classificador	Acurácia média
LDC	80%
KNN (11)	82%
SVM polinomial	83%
SVM radial	83%

Considerando os resultados apresentados, foram reavaliados os critérios de análise a partir de uma nova leitura do Manual de Manutenção e por meio do contato com profissionais e Engenheiros da área. Foram redefinidos os atributos e estabelecidos conforme a seguir:

- Ponto com maior dano (atributo antigo)
- Valor da área do maior dano (atributo novo)
- Valor do somatório das áreas com dano (atributo novo)

A extração dos atributos de valor de área de um dano e somatório de áreas dos pontos de um dano foi possível por meio de funções de rotulação e segmentação de imagens.

Ainda, com o objetivo de aprofundar o trabalho realizado em (Amaral & Lopes, 2011), foram propostos dois outros modelos para extração de atributos: o uso da própria matriz de dados da imagem de ultrassom e a aplicação de seleção de variáveis sobre a matriz de entrada. Uma comparação dos resultados obtidos pelo processamento proposto em (Amaral & Lopes, 2011) com os resultados obtidos pela incorporação dos novos critérios será feita no capítulo de Resultados.

4.3. Sistema de monitoramento de impedância eletromecânica

Dentre todos os métodos de monitoramento de estrutura apresentados, o método de monitoramento de impedância apresenta uma das melhores relações custo/benefício, desde que implementado com um sistema de aquisição de impedância de baixo custo e um número limitado de transdutores. O EMI ainda possui a capacidade de se apresentar como um modelo de monitoramento em tempo real, permitindo assim o desenvolvimento de sistemas de prognóstico de dano mais eficientes.

Para esta dissertação foi proposto o desenvolvimento da instrumentação por meio da construção de um sistema que emita um sinal de excitação para o transdutor PZT e seja capaz de realizar a leitura do sinal de retorno. Após a etapa de pré-processamento, os dados são

fornecidos ao classificador que classifica o dano quanto à distância, localização e severidade. Os referidos dados basicamente são as curvas de impedância do transdutor.

4.3.1. Protótipo de um sistema de monitoramento de impedância eletromecânica

Para o desenvolvimento do sistema proposto, foram definidas inicialmente algumas ferramentas necessárias para construção do sistema de aquisição de impedância. O sistema de monitoramento é composto por um dispositivo DAQ (*Data Acquisition*) da *National Instruments* (modelo USB-6211) em conjunto com uma ferramenta computacional, no caso o MATLAB[®]. O dispositivo DAQ é conectado eletricamente ao PZT através de uma saída analógica e em série com um resistor, conforme Figura 19, de forma a realizar a atuação elétrica na estrutura.

O transdutor PZT foi escolhido pelas suas características elétricas e mecânicas particulares que, inclusive, o faz ser denominado como um tipo de material inteligente. Conforme descreve (Baptista, 2010), no efeito piezelétrico surge um campo elétrico no material submetido a uma distribuição de tensão mecânica. Também ocorre o efeito reverso, isto é, ao se aplicar uma tensão elétrica entre os dois lados do material piezelétrico surge uma deformação mecânica. Ambos os efeitos foram descobertos por Jacques e Pierre Curie em 1880-1881. O termo piezelétrico vem do grego *piezein* que significa pressionar.

Para este estudo foi definido o transdutor PZT-4 tipo disco com 25 mm de diâmetro e 0,6 mm de espessura. Este modelo de transdutor possui um bom alcance para efeitos de monitoramento em barras de alumínio. Em função de possuir uma frequência de ressonância em 3 MHz, o transdutor opera em região linear na faixa de interesse do EMI (entre 10 kHz e 200 kHz).

O dispositivo DAQ, modelo USB-6211, possui as funcionalidades adequadas para o sistema de aquisição de impedância, principalmente pela presença de um relógio interno responsável pelo sincronismo entre as portas analógicas de saída e entrada. O algoritmo para execução da rotina de testes foi desenvolvido no software MATLAB[®] com a função de controlar o DAQ, que por sua vez atua eletricamente no transdutor PZT. Ainda sobre o sincronismo entre as portas analógicas, o algoritmo habilita a porta analógica de saída com o sinal de excitação e aguarda o sinal de disparo emitido pela porta analógica de entrada assim que esta estiver habilitada para a leitura.

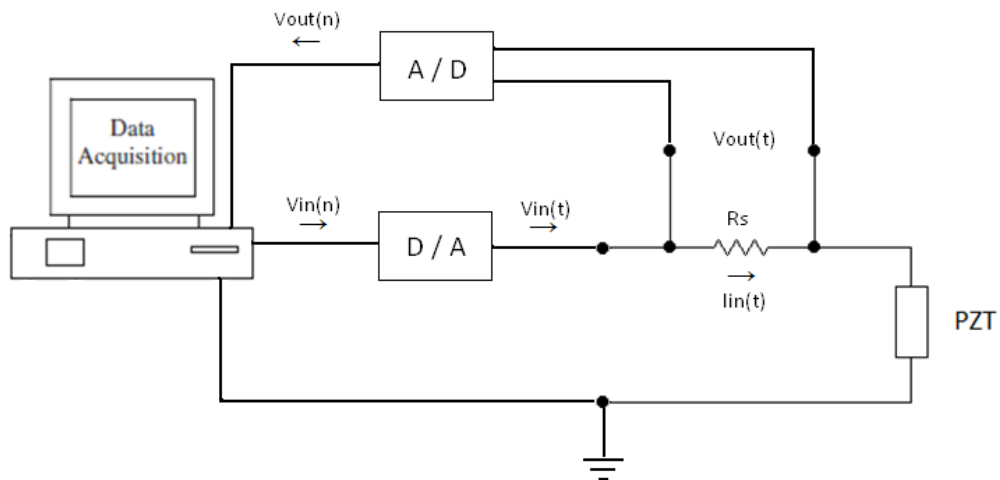


Figura 19 – Esquema elétrico do sistema de aquisição de impedância.

Ao contrário de outros trabalhos citados na bibliografia que utilizam uma função de resposta em frequência para obter a curva de impedância, esta dissertação utiliza um modelo mais simples, porém eficiente, que consiste em utilizar um resistor de baixo valor (no caso R_s , conforme Figura 19) em série com o transdutor que possibilita a medição da corrente do circuito. A impedância no domínio da frequência é obtida pela divisão entre a TF da tensão de entrada e a TF da corrente de entrada. Optou-se por realizar a medição da tensão do circuito e não do transdutor, pois sabe-se que a tensão do circuito é igual ao sinal de excitação (ou sinal de entrada) e, desta forma, simplifica-se ainda mais o circuito, pois se tornam necessárias apenas 2 (duas) portas analógicas do DAQ. Após a extração da curva de impedância, basta subtrair o valor do resistor R_s da curva de impedância real do circuito para obter a curva do transdutor. A corrente de entrada é extraída a partir da seguinte equação

$$I_{in}(n) = \frac{V_{out}(n)}{R_s}. \quad (24)$$

Um modelo similar foi desenvolvido por (Peairs *et al*, 2004) conforme citado no item 3.3. As limitações abordadas por (Baptista, 2010) sobre este método não possuem impacto nos resultados deste trabalho, visto que o transdutor definido para uso no sistema possui um valor de impedância consistentemente maior que o valor de R_s e o sistema não foi projetado para trabalhar com altas frequências em face, inclusive, da limitação de banda do DAQ.

O cálculo para a obtenção das curvas de impedância do circuito é expresso por:

$$Z(e^{j\omega}) = \frac{V_{in}(e^{j\omega})}{I_{in}(e^{j\omega})} = |Z(e^{j\omega})|e^{j\theta(\omega)} \quad (25)$$

sendo

$$|Z(e^{j\omega})| = \sqrt{Z_{re}^2(e^{j\omega}) + Z_{im}^2(e^{j\omega})} = \text{Função Magnitude} \quad (26)$$

e

$$\theta(\omega) = \tan^{-1} \frac{Z_{im}(e^{j\omega})}{Z_{re}(e^{j\omega})} = \text{Função Fase} \quad (27)$$

Para este trabalho, a fase da impedância do PZT foi desconsiderada e todos os experimentos foram realizados com os valores de magnitude da curva de impedância. Com isso, os módulos das curvas de impedância foram extraídos conforme a seguinte expressão:

$$|Z(e^{j\omega})| = \frac{|V_{in}(e^{j\omega})|}{|I_{in}(e^{j\omega})|} - R_s . \quad (28)$$

A definição da metodologia de extração da curva de impedância foi seguida pelo desenvolvimento do algoritmo de execução das medições e realização dos cálculos propostos. O algoritmo foi desenvolvido no software MATLAB[®], conforme definido inicialmente. A estrutura básica foi acrescida pela capacidade do sistema de realizar a repetição de n medições para cada curva, que é obtida pela média destas n medições. Inicialmente foram definidas $n = 3$ repetições para os ensaios propostos. O algoritmo pode ser visualizado na Figura 20.




Figura 20 – Fluxograma do algoritmo do sistema de medição.

Foi definido como estrutura a ser monitorada uma barra de alumínio aeronáutico contendo em 10 posições equidistantes a fixação de parafusos com porca. A peça pode ser visualizada na Figura 21. A barra possui 70,1 mm de comprimento, 36 mm de largura e 4 mm de espessura. Cada uma das 10 posições possui um furo com rosca para fixação de parafuso com porca. A simulação de um dano pode ser feita de diferentes formas para cada posição, como, por exemplo, a retirada de uma porca ou a retirada de uma porca e parafuso. Pode-se ainda padronizar a posição inicialmente com uma, duas ou três porcas, dependendo do comprimento do parafuso. O protótipo dispõe também, para cada posição, de 3 a 4 peças (porca e parafuso) de mesmo modelo, tamanho e liga. Isto se faz necessário para a realização de diferentes simulações para a condição *base line* (sem danos) pela troca de uma mesma peça, porém de fabricação distinta.




Figura 21 – Desenho da barra de alumínio aeronáutico a ser monitorada.

Definiu-se por confeccionar diferentes diâmetros para cada posição, conforme observado na Figura 21. O objetivo é diversificar ainda mais as condições da barra e avaliar a capacidade do sistema generalizar as diferentes severidades de dano.

A caracterização de um dano em uma estrutura é bastante abrangente e por vezes intrínseca a cada estrutura. Os tipos de dano mais conhecidos são trinca, perda de rebite, perda de massa por corrosão e deformação da estrutura (BOEING, 2003). A proposta deste ensaio requer a análise de um grupo numeroso de exemplos e, para alcançar este objetivo, seria inevitável a realização de um número razoável de medições com diferentes simulações de dano. Determinados danos são destrutivos para a estrutura, o que compromete a proposta de

repetição do experimento. Foi definida, então, a inserção de dano(s) na barra de alumínio por meio da perda de uma porca ou mesmo o parafuso. Desta forma o dano se equivale com outros conhecidos como perda de massa ou perda de rebite. As Figuras 22 e 23 ilustram o aparato montado para a realização dos ensaios.

O transdutor PZT foi fixado na barra de alumínio por um adesivo epóxi de alta resistência, da marca SCOTH que, por suas características rígidas, após a secagem é capaz de transmitir com maior eficiência a vibração do transdutor para a estrutura. Para a conexão elétrica foi necessário uso de uma solda eletrônica de baixo ponto de fusão para conectar um par de fios nos 2 pontos elétricos do PZT (positivo – face superior e negativo – face inferior).




Figura 22 – Sistema de monitoramento de impedância eletromecânica montado para realização de medições.

Para a realização dos ensaios, a barra não foi fixada em outra estrutura. Ela permaneceu suspensa por um par de elásticos de forma que pudesse ficar livre para a vibração característica deste método.

A Figura 24 ilustra um exemplo de uma curva de impedância extraída pelo sistema proposto durante um dos experimentos realizados. Foram extraídas, ao todo, 470 curvas de impedância para diferentes condições da barra de alumínio.



Figura 23 – Barra de alumínio com o sensor piezoelétrico.

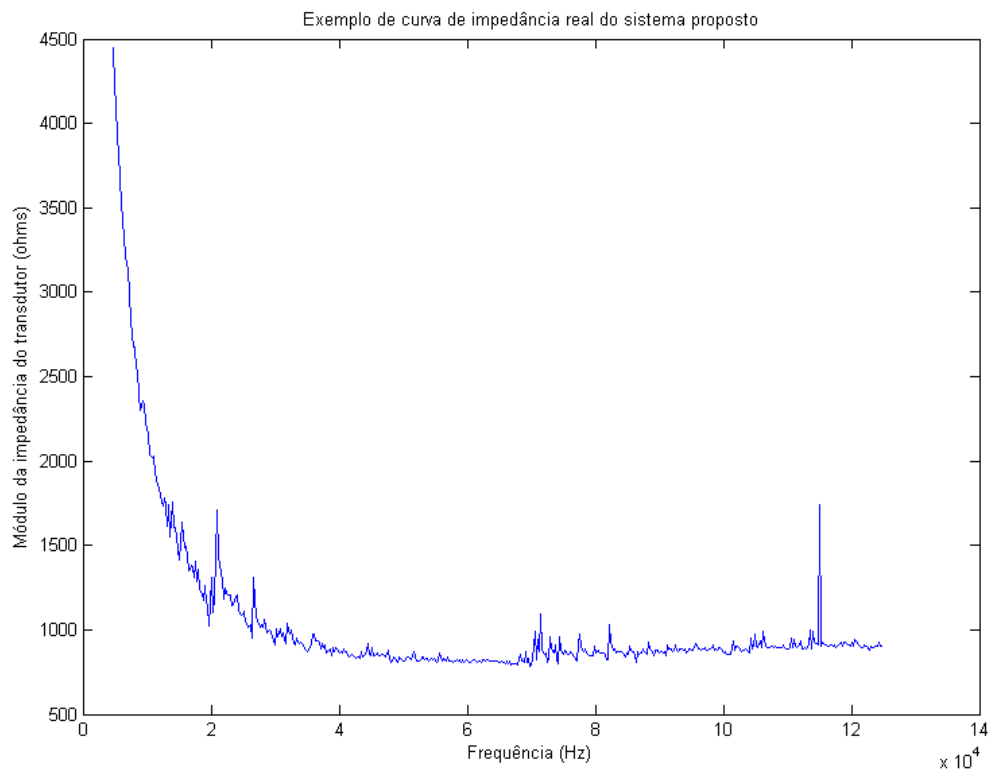


Figura 24 – Exemplo de curva de impedância extraída pelo sistema proposto na condição da barra sem dano.

4.3.2. Sinal de excitação do sistema

Para o modelo EMI proposto, faz-se necessária a geração de um sinal capaz de excitar o transdutor e, conseqüentemente, estimular o sistema de monitoramento para a aquisição do sinal de retorno. Este sinal de excitação deve ser configurado pelo software e gerado pelo DAQ. Inicialmente alguns parâmetros foram definidos em função das características do modelo do transdutor. O sinal gerado para os ensaios propostos possuem 2 volts de amplitude (1 volt de pico) e duração de 1 segundo. Um aspecto preponderante é a necessidade do sinal de excitação ser capaz de varrer uma faixa de interesse do espectro de frequência. Existem diversas opções de sinais que atendem a esta característica. Para este trabalho foram propostos 3 sinais distintos: *chirp*, pseudoaleatório e pseudoaleatório binário.

Conforme (Baptista, 2010) descreve, o sinal *chirp* faz uma varredura desde uma frequência inicial de baixo valor até uma frequência final de valor mais alto, ou vice-versa. A sequência $x(n)$ de um sinal *chirp* é dada por

$$x(n) = A \cdot \sin\left(\frac{2\pi}{F_s} n \left(\frac{(f_2 - f_1)}{2N} n + f_1\right)\right), \quad (29)$$

sendo $n = 0, 1, \dots, N - 1$, onde f_1 e f_2 representam a frequência inicial e final, respectivamente, A é a amplitude, N é o número de amostras e F_s é a taxa de amostragem. Embora o dispositivo DAQ utilizado permita uma taxa de amostragem de 250 kS/s e a frequência de Nyquist seja de $F_s/2$ (125 kHz), bons resultados experimentais observados durante os primeiros ensaios foram obtidos com o sinal a 25% desse valor, ou seja, desde um nível DC ($f_1 = 0$) até $F_s/8$ ($f_2 = 31,25$ kHz).

O sinal pseudoaleatório é gerado inicialmente pela função *randn* do MATLAB® e seria similar a um ruído branco aleatório. Este sinal possui como características importantes a média igual a 0 (zero) e variância igual a 1 (um).

O sinal pseudoaleatório binário é gerado pela função *idinput* do MATLAB®. Esta função foi configurada para gerar um sinal binário pseudoaleatório com uma banda predefinida.

4.3.3. Pré-processamento das curvas de impedância

O sistema de aquisição de impedância após a extração das curvas de impedância apresenta um sinal discreto que, dependendo da função utilizada para a realização da Transformada de Fourier, poderá representar este mesmo sinal com um grande número de amostras no domínio da frequência. Em função da proposta de classificação da curva, propõe-se o tratamento do sinal antes de realizar a classificação para adequar o número de pontos ao tamanho do vetor de entrada do classificador.

Um método proposto que apresentou um desempenho bastante satisfatório foi a função *freqz* do MATLAB[®]. Esta função realiza a Transformada de Fourier do sinal retornando dois vetores: um vetor com a magnitude da resposta em frequência do sinal e outro vetor com a frequência angular correspondente. O vetor com a frequência angular possui valores que variam entre 0 (zero) e π radianos. Para este trabalho foi inicialmente definido o número padrão da função, no caso, 512 amostras e posteriormente foram realizados experimentos com apenas 32 amostras. Para a apresentação das curvas em gráficos é necessário normalizar o eixo das frequências. No caso da apresentação em *hertz* pode-se dividir o vetor por π e multiplicar pela frequência de *Nyquist*, no caso 125 kHz.

4.3.4. Escolha da faixa de frequência e uso de banco de filtros

Dentro do método de EMI, usualmente escolhe-se uma faixa de frequência ótima para a avaliação de métrica ou, como na proposta deste trabalho, a classificação das curvas de impedância. A bibliografia mostra que esta escolha da faixa de frequência em geral é feita por tentativa e erro ou por meio de uma avaliação visual da curva, observando os picos da curva de impedância que representam as frequências naturais do transdutor. As faixas usualmente utilizadas encontram-se entre 20 kHz e 200 kHz e podem variar em intervalos de 10 kHz a 20 kHz.

Em um primeiro momento os classificadores serão ajustados e avaliados para classificar toda a curva, ou seja, toda a banda de frequência do sinal. Isso será possível pelo uso da função *freqz* do MATLAB[®] que transforma a curva de impedância em um vetor com apenas 512 pontos, viabilizando o processamento realizado pelos algoritmos dos

classificadores. Este modelo descrito pode ser visualizado na Figura 25, também rotulado como Modelo 1.

Posteriormente será feito um estudo sobre o desempenho do sistema de monitoramento utilizando um modelo em sub-bandas por meio de um banco de filtros e decimação do sinal. Para este modelo será ajustado e avaliado apenas o classificador KNN, para $k = 1$. O uso do banco de filtros permite que a curva de impedância apresente valores em faixas específicas de frequência.

Com esse modelo é possível avaliar o desempenho do sistema para diversas faixas de frequência por uma metodologia mais pragmática e menos empírica. Desta forma, pretende-se avaliar se é mais vantajoso monitorar uma faixa específica de frequência ou se o uso de toda a banda é efetivamente o mais adequado. A Figura 26 ilustra o modelo 2 proposto para esta dissertação.




Figura 25 – Diagrama do Modelo 1 para cálculo da curva de impedância banda cheia.

O uso de banco de filtros foi possível por meio de algoritmos desenvolvidos no MATLAB[®] que aplicam princípios de banco de filtros modulados por cosseno. Alguns protótipos desenvolvidos por (Batalheiro, 2000) compõem os algoritmos mencionados. O banco de filtros de L canais (ou sub-bandas) é aplicado em sinais no domínio do tempo e, por isso, há a necessidade de utilizar a Transformada Discreta de Fourier Inversa, conforme observado na Figura 26.

Na etapa de decimação atua o decimador (compressor) que reduz a taxa de amostragem do sinal, adequando-a a sua largura de banda. A Figura 27 mostra o esquemático de um compressor de taxa de amostragem. Supondo um sinal $x(n)$ presente na entrada do decimador, pode-se definir a saída do compressor $y_D(n)$ como sendo

$$y_D(n) = x(nM), \quad (30)$$

onde M é um número inteiro.

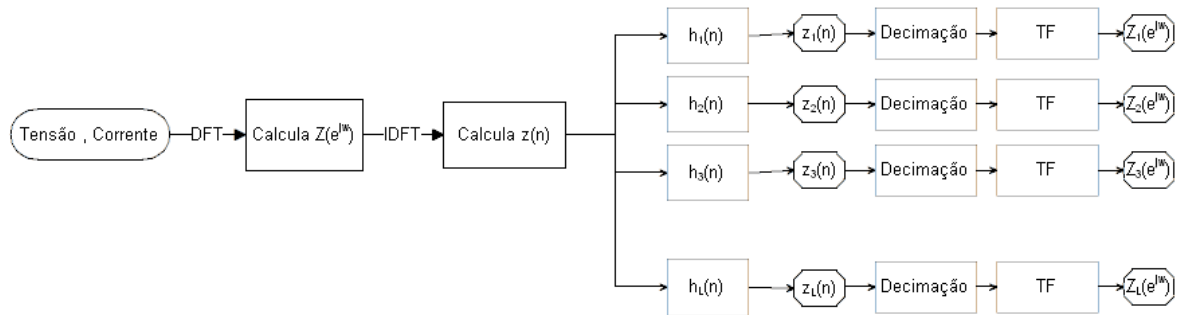


Figura 26 – Diagrama do Modelo 2 para cálculo da curva de impedância sub-bandas (exemplo com L bandas).




Figura 27 – Decimador (Batalheiro, 2000).

Foi definido inicialmente para este trabalho utilizar 4 (quatro) bancos de filtros distintos com $L = 2, 4, 8$ e 16 canais. Também foi definido utilizar 2 Fatores de Decimação distintos para cada caso: $M = L/2$ e $M = L$ e vetor de atributos de entrada com 32 pontos.

5. RESULTADOS

Ao final do desenvolvimento e teste dos sistemas propostos para esta dissertação, são apresentados os resultados para fins de avaliação de ambos os sistemas. Para cada sistema classificador, são apresentados os resultados de suas respectivas avaliações conforme metodologia apresentada no Capítulo 2. Os resultados terão como foco os seguintes elementos: acurácia (Witten & Frank, 2005), sensibilidade (Witten & Frank, 2005), especificidade (Witten & Frank, 2005) e área abaixo da curva ROC (ROC, do inglês *Receiver Operating Characteristic*) (Witten & Frank, 2005). Os referidos elementos são indicadores de desempenho dos classificadores e servem de parâmetro tanto na fase de ajuste dos classificadores quanto na sua avaliação final de desempenho.

Durante as fases de ajuste e avaliação foi adotado como padrão o uso do método de validação cruzada em face principalmente do fato do conjunto de dados apresentar um número reduzido de exemplos.

Segundo (Witten & Frank, 2005), a validação cruzada é um método capaz de avaliar o erro de generalização de um classificador. O conjunto de dados é dividido em p partições, sendo que $p - 1$ partições são usadas para treinamento e uma para teste. Este procedimento é repetido p vezes. Ao final dos experimentos é feita uma média dos resultados de cada teste. Este procedimento impede, por exemplo, que um resultado com uma taxa de acurácia eventualmente muito alta ou muito baixa, devido a uma divisão específica dos dados em conjunto de treino e teste, represente o desempenho do classificador.

Os indicadores de desempenho apresentados no início deste capítulo são regularmente utilizados em classificadores inteligentes. A acurácia é um indicador simples que representa a taxa de acerto do classificador, independente se a avaliação é referente à falha ou não falha ou, em outra análise, pelo positivo verdadeiro ou negativo verdadeiro. A sensibilidade é conhecida como a taxa de positivos verdadeiros enquanto que a especificidade é conhecida como a taxa de negativos verdadeiros. A curva ROC ilustra o desempenho de um classificador por meio de um gráfico sensibilidade versus (1 - especificidade) (Fawcett, 2005). Usualmente utiliza-se a Área Abaixo da Curva ROC (AUC, do inglês *Area Under ROC Curve*) como indicador de desempenho do classificador. Este indicador torna-se muito útil quando se quer comparar o desempenho entre 2 classificadores.

5.1. Resultados do sistema classificador para apoio a decisão em reparo estrutural de componentes aeronáuticos

O primeiro passo realizado para a obtenção dos resultados foi a determinação dos parâmetros utilizados pelos classificadores. (Amaral & Lopes, 2011) definiram os parâmetros por meio da comparação do valor do erro de classificação obtido com 10 repetições de uma validação cruzada com cinco partições. A validação cruzada foi utilizada porque o conjunto disponível de dados é relativamente pequeno e para estes casos a validação cruzada fornece uma boa estimativa do erro de generalização do classificador (Witten & Frank, 2005). Neste primeiro estudo, foram coletadas informações de 247 peças (vide item 4.2). Nos experimentos, o conjunto de treinamento usado na validação cruzada tem suas variáveis normalizadas. Isto é necessário para remover os efeitos causados pelo fato das variáveis possuírem diferentes faixas de variação, conforme pode ser visto na Tabela 2, onde se pode observar os valores mínimo, médio e máximo para as três variáveis: a maior diferença de profundidade encontrada na placa (MDP); número de áreas com perda crítica (NAPC) e a razão entre o somatório das áreas com perdas e a área total (RS).

Tabela 2 – Valor mínimo, médio e máximo de cada variável.

Variável	Mín	Médio	Máx
MDP	0,0092	0,0239	0,1560
NAPC	0	14,6414	77
RS	0	0,2773	0,7458

Uma vez que os parâmetros foram escolhidos, os classificadores foram avaliados usando-se como métrica a média do erro de classificação obtida em 10 repetições de validação cruzada com cinco partições. A Tabela 3 mostra os resultados obtidos em (Amaral & Lopes, 2011). Na coluna dos classificadores entre parênteses têm-se os parâmetros utilizados.

Tabela 3 – Resultados dos classificadores (Amaral & Lopes, 2011).

Classificadores	Erro de classificação (desvio padrão)
LDC	0,20 (0,01)
KNN (K=11)	0,18 (0,01)
SVM Polinomial ($p=7$ e $C=90,50$)	0,17 (0,01)
SVM Radial ($r=0,7071$ e $C=128$)	0,17 (0,01)

Conforme mencionado anteriormente (ver seção 4.2.4), para a continuação do trabalho desenvolvido foram realizados quatro experimentos para que fosse possível fazer uma

comparação entre eles. O primeiro experimento foi feito com os atributos iniciais utilizados em (Amaral & Lopes, 2011). O segundo experimento foi realizado utilizando como vetor de entrada as diferenças de profundidades mensuradas em toda a área. O terceiro experimento utilizou uma busca dos melhores pontos das diferenças de profundidade com o objetivo de minimizar o erro e finalmente o quarto experimento foi feito com os novos atributos propostos (vide item 4.2).

Os experimentos com o classificador KNN e o classificador RNA utilizaram a normalização para obter média igual a 0 e variância unitária, enquanto que nos experimentos com o SVM a normalização realizada colocou as faixas de variação das variáveis entre 0 e 1, conforme recomendado em (Hsu *et al*, 2010). Os classificadores foram implementados com o auxílio de uma *toolbox* para MATLAB[®] chamada *prtools* (Duin *et al*, 2007). O classificador KNN tem como parâmetro a ser escolhido o número K de vizinhos.

Tabela 4 – Resultados do classificador KNN


K	Partições	Repetições	Acurácia	AUC
1	10	3	0,97 (0,04)	0,99 (0,01)
3	10	3	0,97 (0,04)	0,98 (0,03)
5	10	3	0,97 (0,03)	0,99 (0,03)
7	10	3	0,97 (0,03)	0,99 (0,02)
9	10	3	0,97 (0,04)	0,99 (0,02)

No KNN, o parâmetro a ser ajustado é o número de vizinhos e na RNA, é o número de neurônios na camada escondida. No caso do SVM, tanto o linear quanto de base radial, foi feita uma busca para encontrar os parâmetros. No caso do SVM linear, deseja-se encontrar apenas o parâmetro de regularização C . Esta busca foi realizada como sugerido em (Hsu *et al.*, 2010). Para o SVM de base radial, a busca foi realizada em uma malha formada pelos valores do raio $r = 2^{-15}, 2^{-13}, \dots, 2^3$ e $C = 2^{-5}, 2^{-3}, \dots, 2^{15}$. Uma vez encontrada a melhor região, foi realizada uma busca local encontrando os melhores valores de C e r .

Uma vez que os parâmetros foram escolhidos, os classificadores foram avaliados usando como métricas a acurácia, sensibilidade, especificidade e AUC. Estas métricas foram obtidas por meio de 3 repetições de validação cruzada com 10 partições. Cabe destacar que todas as classificações foram avaliadas tendo como referência a presença de falha, ou em outras palavras a classe 2 (positivo), (ver Seção 4.1). As Tabelas 5, 6, 7 e 8, e as respectivas curvas ROC mostram os resultados obtidos após os ajustes de parâmetros. Na linha dos classificadores entre parênteses têm-se os parâmetros utilizados. Na linha das taxas de acerto as métricas acurácia, sensibilidade, especificidade e AUC estão ordenadas de cima para baixo e entre parênteses encontra-se o desvio padrão.

Tabela 5 – Resultados do experimento 1 (atributos iniciais).

Indicadores	SVM-LINEAR (C=11,31)	KNN (11)	RNA (n=2)	SVM-r (C=76,11 r=0,59)
Acurácia	0.81 (0.07)	0.82 (0.07)	0.83 (0.07)	0.83 (0.08)
Sensibilidade	0.77 (0.14)	0.70 (0.14)	0.71 (0.14)	0.73 (0.13)
Especificidade	0.86 (0.08)	0.94 (0.08)	0.95 (0.06)	0.94 (0.09)
AUC	0.89 (0.06)	0.86 (0.07)	0.89 (0.06)	0.88 (0.06)

**Figura 28 – Curva ROC dos resultados do experimento 1.****Tabela 6 – Resultados do experimento 2 (todos os pontos da imagem).**

Indicadores	SVM-LINEAR (C=1)	KNN (1)	RNA (n=5)	SVM-r (C=16 r=4)
Acurácia	0.86 (0.08)	0.83 (0.07)	0.84 (0.07)	0.89 (0.08)
Sensibilidade	0.82 (0.12)	0.80 (0.12)	0.80 (0.12)	0.87 (0.13)
Especificidade	0.89 (0.08)	0.86 (0.10)	0.88 (0.11)	0.91 (0.10)
AUC	0.91 (0.08)	0.89 (0.07)	0.92 (0.07)	0.95 (0.05)




Figura 29 – Curva ROC dos resultados do experimento 2.

Tabela 7 – Resultados do experimento 3 (seleção dos pontos através de uma busca forçada).

Indicadores	SVM-LINEAR (C=2)	KNN (1)	RNA (n=2)	SVM-r (C=1,68 r=1)
Acurácia	0.74 (0.09)	0.76 (0.07)	0.75 (0.08)	0.84 (0.09)
Sensibilidade	0.71 (0.13)	0.66 (0.14)	0.73 (0.13)	0.88 (0.09)
Especificidade	0.78 (0.11)	0.85 (0.10)	0.78 (0.13)	0.80 (0.13)
AUC	0.79 (0.10)	0.84 (0.08)	0.79 (0.09)	0.91 (0.06)


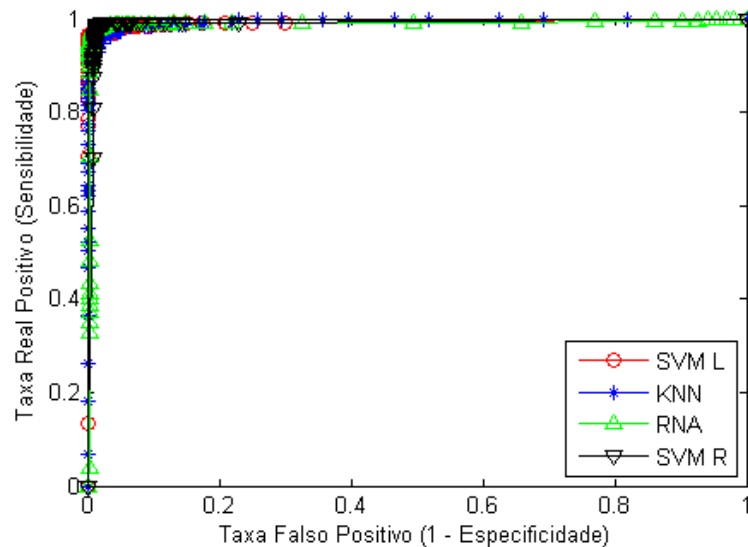


Figura 30 – Curva ROC dos resultados do experimento 3.

Tabela 8 – Resultados do experimento 4 (novos atributos).

Indicadores	SVM-LINEAR (C=152,22)	KNN (1)	RNA (n=3)	SVM-r (C=0,5 r=0,07)
Acurácia	0.97 (0.03)	0.97 (0.04)	0.99 (0.03)	0.99 (0.02)
Sensibilidade	0.97 (0.04)	0.96 (0.06)	0.98 (0.04)	0.99 (0.03)
Especificidade	0.98 (0.04)	0.98 (0.05)	0.99 (0.03)	0.99 (0.04)
AUC	0.99 (0.01)	0.99 (0.01)	0.99 (0.02)	0.99 (0.02)

**Figura 31 – Curva ROC dos resultados do experimento 4.**

Os resultados apresentam claramente um desempenho melhor quando são extraídos os atributos do experimento 4. Isso evidencia a importância da avaliação do especialista dentro do processo de desenvolvimento dos sistemas inteligentes. O índice de acerto nos diferentes indicadores do experimento 4 demonstra que o sistema possui potencial para que em trabalhos futuros se desenvolvam modelos de apoio à decisão em reparo estrutural.

5.2. Resultados do sistema inteligente de monitoramento de integridade estrutural baseado em impedância eletromecânica

Nesta etapa serão apresentados os ensaios de validação do sistema proposto para monitoramento de estruturas. Inicialmente foi realizada a validação do sistema de aquisição de impedância utilizando um circuito Resistor Capacitor (RC). Em seguida, foram propostos os ensaios para a classificação do possível dano quanto à distância e posição. Finalmente foi

realizado um ensaio para analisar a capacidade do sistema proposto em identificar um dano severo específico dentro de condições diversas da estrutura.

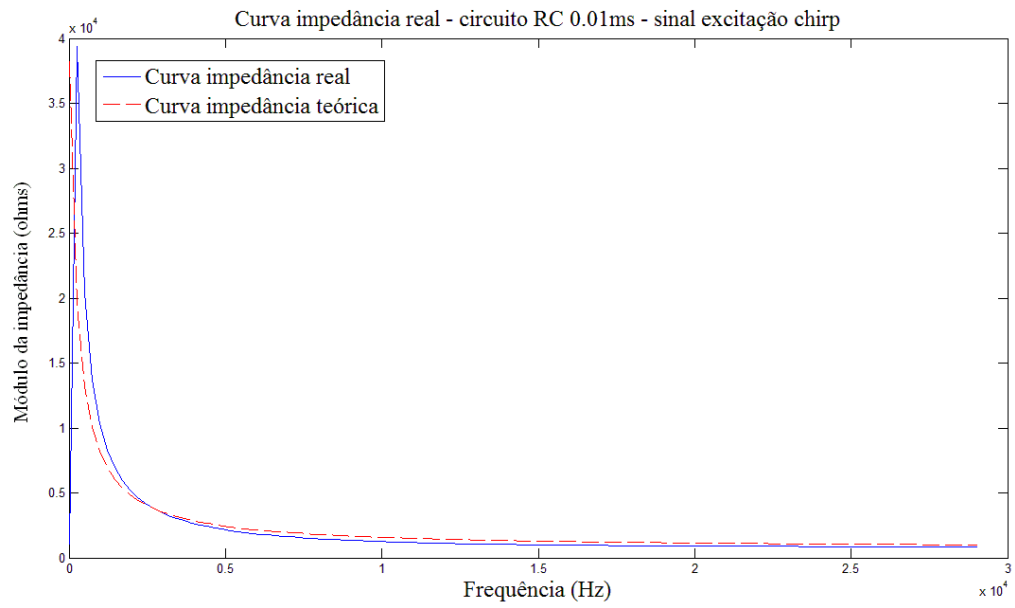
5.2.1. Validação do sistema de aquisição de impedância

Inicialmente, antes de realizar a validação do sistema classificador em questão, foi realizado um ensaio com o objetivo de validar o sistema de aquisição de impedância. O ensaio proposto foi a realização de medições da curva de impedância de um circuito RC com o levantamento da medida de erro utilizando como referência a curva teórica.

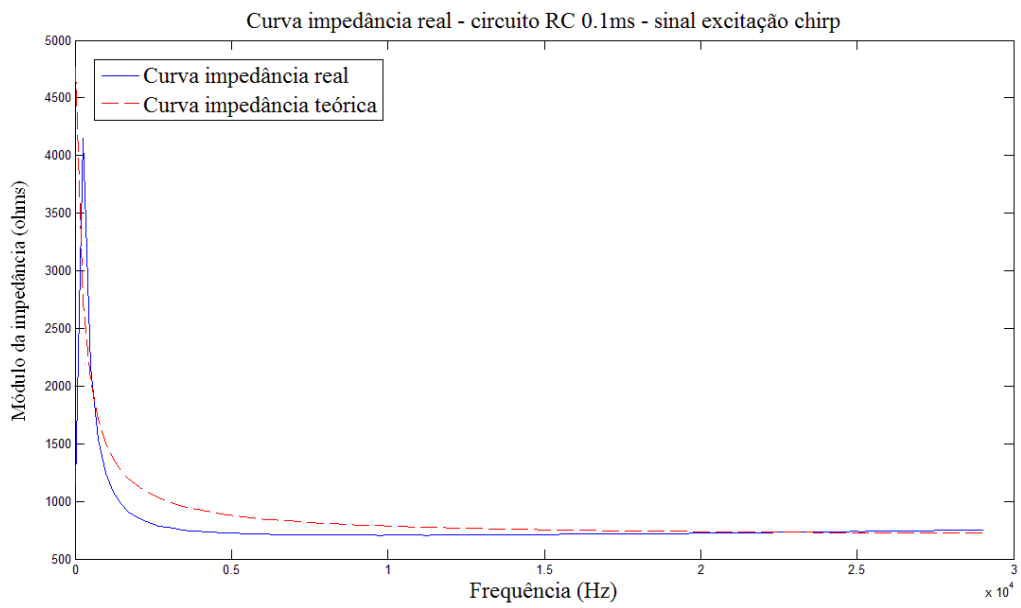
Foram definidos 4 (quatro) circuitos RC com 4 diferentes constantes de tempo: 0,01 ms, 0,1 ms, 1 ms e 10 ms. Foram utilizadas 2 (duas) décadas, 1 resistiva e outra capacitiva. Ambos os dispositivos foram medidos por um multímetro digital modelo ICEL MD-6450 e os valores medidos foram utilizados como padrão (valores reais) durante todos os ensaios.

As Figuras 32 e 33 mostram os resultados dos ensaios para os circuitos com constante de tempo 0,01 ms e 0,1 ms, utilizando 2 (dois) sinais de excitação, o sinal *chirp* e o sinal pseudoaleatório. É possível observar que, para o circuito de constante de tempo 0,1 ms, a curva apresenta um desvio elevado na região de baixa frequência. Os circuitos com constante de tempo 1 ms e 10 ms apresentaram resultados piores que o apresentado pelo circuito com constante de tempo 0,1 ms. Ressalta-se também que os resultados apresentados pelos ensaios com o sinal de excitação pseudoaleatório binário foram similares aos resultados dos ensaios com o sinal de excitação pseudoaleatório.

Com base nos gráficos apresentados e nos valores de erro para o pior sinal, no caso o sinal *chirp*, descritos na Tabela 9, constata-se que o sistema proposto apresenta um desempenho satisfatório para as condições encontradas durante os ensaios de monitoramento de impedância eletromecânica, bem como para a faixa de frequência de interesse. Com efeito, a simplicidade deste sistema de aquisição de impedância, aliado à sua aplicação no modelo EMI, caracteriza-o como um sistema dedicado e de baixo custo.




(a)

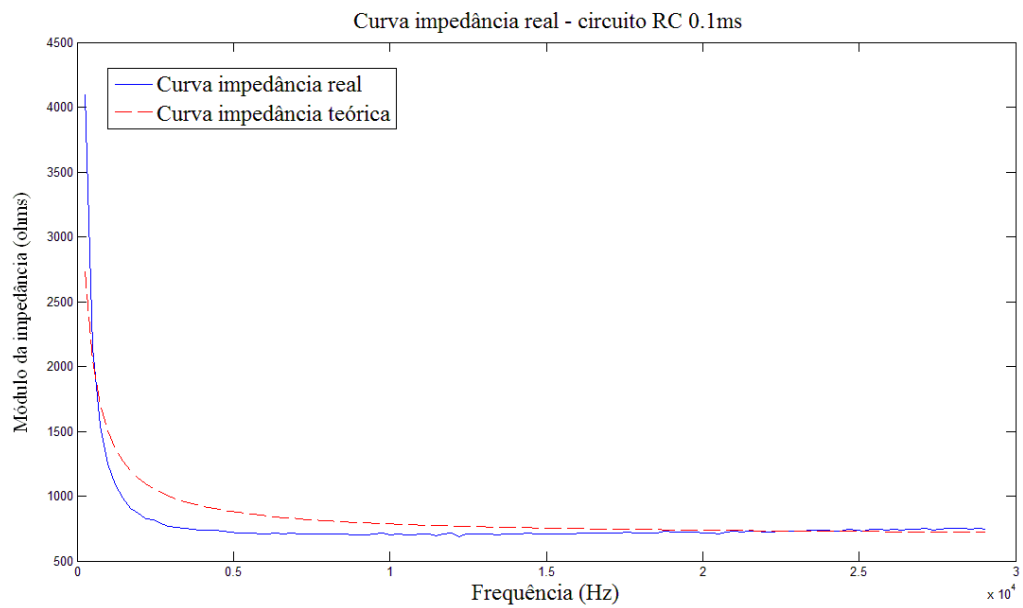


(b)

Figura 32 – Curvas de impedância de um circuito RC para resposta ao sinal *chirp* de excitação (constante de tempo (a) - 0,01 ms e (b) - 0,1 ms).



(a)



(b)

Figura 33 – Curvas de impedância de um circuito RC para resposta ao sinal pseudoaleatório de excitação (constante de tempo (a) - 0,01 ms e (b) - 0,1 ms).

Tabela 9 – Valores de erro quadrático médio durante a validação com o circuito RC (sinal de excitação *chirp*).

Faixa de frequência	Circuito RC para 0,01 ms (constante de tempo)	Circuito RC para 0,1 ms (constante de tempo)
1k até 2kHz	21,33%	19,03%
8k até 10kHz	12,48%	7,21%
20kHz até 25kHz	9,25%	1,71%

5.2.2. Validação do sistema de monitoramento de integridade estrutural

Considerando a estrutura apresentada e a classificação proposta, foi definida uma metodologia de ensaios para a composição do conjunto de dados de treinamento e teste. Esta metodologia compreendeu a realização de um grupo de 470 ensaios com a barra de alumínio nas condições sem dano, dano(s) à direita, dano(s) à esquerda, dano(s) longe do transdutor, dano(s) perto do transdutor e dano severo. Os danos poderiam estar presentes isoladamente ou em conjunto.

Conforme descrito no item 1.4, o modelo de classificação é ilustrado na Figura 34. Este modelo abrange áreas de interesse na manutenção aeronáutica, bem como permite que a avaliação do sistema classificador alcance diferentes classes e condições.

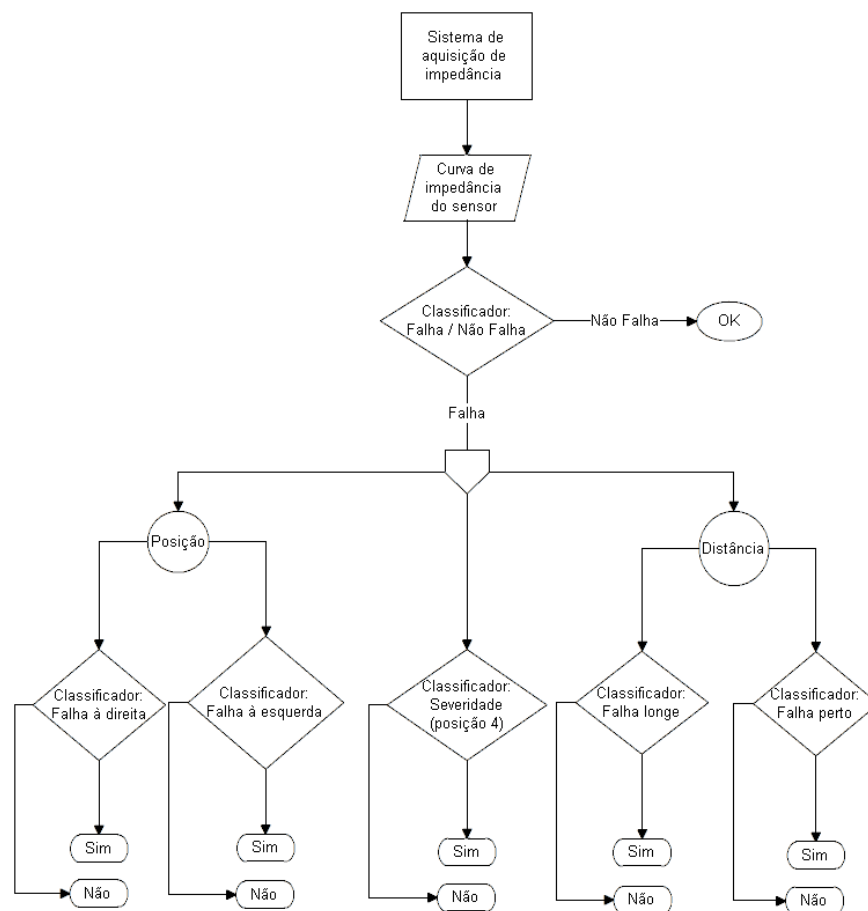


Figura 34 – Diagrama com o modelo de classificação do sistema de monitoramento EMI proposto.

Os ensaios foram realizados de forma que os exemplos com a barra na condição de falha poderiam conter um ou vários danos. Os critérios de análise da falha podem ser observados na Tabela 10. As posições indicadas podem ser verificadas na Figura 21.

Tabela 10 – Critérios de falhas da barra de alumínio.

Critério de falha	Posição do(s) dano(s) na barra de alumínio
<i>Base line</i>	Nenhuma posição
Dano(s) à direita	Posições 6 a 10
Dano(s) à esquerda	Posições 1 a 5
Dano(s) longe do transdutor	Posições 1, 2, 9 e 10
Dano(s) perto do transdutor	Posições 3 a 8
Dano severo	Posição 4

Com os critérios de falha definidos foi possível estabelecer para cada exemplo uma classe para cada classificação. Desta forma foi obtido ao final dos experimentos um conjunto de exemplos a serem avaliados em alguns classificadores pré-estabelecidos.

Similarmente à metodologia desenvolvida na avaliação do sistema de apoio à decisão na classificação de imagens de ultrassom, a avaliação foi procedida por meio de repetições de uma validação cruzada com dez partições, pois neste caso há disponível um conjunto relativamente pequeno de dados.

Os ensaios realizados extraíram dados de tensão e corrente que permitiram construir as curvas de impedância (ver Equação 28). Para efeitos de classificação, há 2 grupos, conforme descrito no item 4.3.4, ou seja, no modelo 1 é considerada a banda cheia da curva de impedância e no modelo 2 considera-se uma faixa de frequência específica.

5.2.3. Avaliação do sistema para banda cheia

A avaliação do sistema inteligente e seus classificadores é iniciada pelo método de ajuste, conforme descrito anteriormente. Para o modelo 1 (banda cheia) foi definida inicialmente a utilização da função *freqz* com o padrão de 512 pontos. O ajuste seguiu o mesmo procedimento descrito no item 5.1. Após a análise de desempenho dos classificadores para os melhores parâmetros ajustados, é possível extrair algumas informações. Nas Tabelas 11 a 16 é possível observar o resultado após ajuste dos classificadores para a avaliação dos diferentes critérios de falha.

Cabe destacar que inicialmente foi adotado o classificador LDC como o único classificador linear do grupo de classificadores definidos durante a fase de experimentos. Entretanto, ele apresentou um baixo desempenho quando comparado com os outros classificadores. Isso não significa que o caso em estudo seja efetivamente não linear, mas sim possivelmente que o classificador escolhido não seja adequado para a avaliação desse problema. Será visto mais à frente a substituição do classificador LDC pelo classificador SVM linear, o que permitiu obter melhores resultados.

Tabela 11 – Resultados dos classificadores para critério *base line*.

Sinais de excitação e resultados dos classificadores		LDC	KNN	RNA	SVM radial
Sinal Pseudoaleatório	Acurácia	0.50	0.98	0.98	1.00
	Sensibilidade	0.00	1.00	1.00	1.00
	Especificidade	1.00	0.96	0.96	1.00
	AUC	0.50	1.00	0.98	1.00
Sinal <i>Chirp</i>	Acurácia	0.50	0.98	0.96	1.00
	Sensibilidade	0.00	1.00	1.00	1.00
	Especificidade	1.00	0.95	0.91	1.00
	AUC	0.50	1.00	0.96	1.00
Sinal Pseudoaleatório binário	Acurácia	0.50	0.98	0.97	1.00
	Sensibilidade	0.00	1.00	1.00	1.00
	Especificidade	1.00	0.95	0.94	1.00
	AUC	0.50	1.00	0.97	1.00

Tabela 12 – Resultados dos classificadores para critério dano(s) à direita.

Sinais de excitação e resultados dos classificadores		LDC	KNN	RNA	SVM radial
Sinal Pseudoaleatório	Acurácia	0.50	0.93	0.92	0.94
	Sensibilidade	0.00	0.97	0.92	0.95
	Especificidade	1.00	0.89	0.92	0.93
	AUC	0.50	0.97	0.98	0.98
Sinal <i>Chirp</i>	Acurácia	0.50	0.95	0.94	0.94
	Sensibilidade	0.00	0.97	0.95	0.97
	Especificidade	1.00	0.93	0.92	0.92
	AUC	0.50	0.97	0.97	0.96
Sinal Pseudoaleatório binário	Acurácia	0.50	0.94	0.93	0.95
	Sensibilidade	0.00	0.96	0.93	0.96
	Especificidade	1.00	0.92	0.93	0.93
	AUC	0.50	0.97	0.96	0.97

Tabela 13 – Resultados dos classificadores para critério dano(s) à esquerda.

Sinais de excitação e resultados dos classificadores		LDC	KNN	RNA	SVM radial
Sinal Pseudoaleatório	Acurácia	0.50	0.94	0.92	0.93
	Sensibilidade	0.00	0.93	0.90	0.92
	Especificidade	1.00	0.96	0.94	0.93
	AUC	0.50	0.97	0.95	0.96
Sinal <i>Chirp</i>	Acurácia	0.50	0.95	0.93	0.95
	Sensibilidade	0.00	0.96	0.90	0.95
	Especificidade	1.00	0.94	0.96	0.96
	AUC	0.50	0.97	0.96	0.98
Sinal Pseudoaleatório binário	Acurácia	0.50	0.94	0.92	0.96
	Sensibilidade	0.00	0.94	0.90	0.96
	Especificidade	1.00	0.93	0.93	0.96
	AUC	0.50	0.96	0.95	0.95

Tabela 14 – Resultados dos classificadores para critério dano(s) longe.

Sinais de excitação e resultados dos classificadores		LDC	KNN	RNA	SVM radial
Sinal Pseudoaleatório	Acurácia	0.50	0.91	0.89	0.90
	Sensibilidade	0.00	0.88	0.85	0.86
	Especificidade	1.00	0.95	0.92	0.94
	AUC	0.50	0.95	0.93	0.90
Sinal <i>Chirp</i>	Acurácia	0.50	0.92	0.85	0.91
	Sensibilidade	0.00	0.90	0.80	0.88
	Especificidade	1.00	0.94	0.91	0.94
	AUC	0.50	0.94	0.91	0.97
Sinal Pseudoaleatório binário	Acurácia	0.50	0.90	0.87	0.91
	Sensibilidade	0.00	0.84	0.84	0.87
	Especificidade	1.00	0.95	0.90	0.95
	AUC	0.50	0.94	0.89	0.96

Tabela 15 – Resultados dos classificadores para critério dano(s) perto.

Sinais de excitação e resultados dos classificadores		LDC	KNN	RNA	SVM radial
Sinal Pseudoaleatório	Acurácia	0.50	0.93	0.92	0.92
	Sensibilidade	0.00	0.97	0.95	0.99
	Especificidade	1.00	0.88	0.89	0.85
	AUC	0.50	0.96	0.95	0.96
Sinal <i>Chirp</i>	Acurácia	0.50	0.94	0.90	0.93
	Sensibilidade	0.00	0.97	0.93	0.97
	Especificidade	1.00	0.90	0.87	0.89
	AUC	0.50	0.96	0.94	0.96
Sinal Pseudoaleatório binário	Acurácia	0.50	0.92	0.92	0.91
	Sensibilidade	0.00	0.97	0.93	0.97
	Especificidade	1.00	0.87	0.91	0.85
	AUC	0.50	0.95	0.94	0.95

Tabela 16 – Resultados dos classificadores para critério dano severo.

Sinais de excitação e resultados dos classificadores		LDC	KNN	RNA	SVM radial
Sinal Pseudoaleatório	Acurácia	0.50	0.90	0.88	0.90
	Sensibilidade	0.00	0.86	0.82	0.86
	Especificidade	1.00	0.94	0.93	0.94
	AUC	0.50	0.95	0.92	0.96
Sinal Chirp	Acurácia	0.50	0.87	0.90	0.92
	Sensibilidade	0.00	0.80	0.85	0.88
	Especificidade	1.00	0.93	0.94	0.95
	AUC	0.50	0.94	0.94	0.95
Sinal Pseudoaleatório binário	Acurácia	0.49	0.88	0.88	0.88
	Sensibilidade	0.01	0.85	0.85	0.85
	Especificidade	0.99	0.91	0.91	0.92
	AUC	0.49	0.95	0.93	0.94

Na Tabela 17 encontram-se os resultados dos melhores classificadores para cada tipo de falha, dentro da avaliação banda cheia da curva de impedância com 512 pontos, reforçando ainda que a classificação foi realizada tendo como referência a classe 2, ou a condição com falha. Destaca-se que a partir da Tabela 17, todos os valores entre parênteses representam os respectivos desvios padrões.

Tabela 17 – Resultados dos melhores classificadores por tipo de falha para avaliação banda cheia com 512 pontos.

Sinais de excitação		Base line SVM radial	Dano à direita SVM radial	Dano à esquerda SVM radial	Dano longe KNN	Dano perto SVM radial	Dano severo SVM radial
Sinal pseudoaleatório	Acurácia	1.00 (0.00)	0.94 (0.06)	0.93 (0.05)	0.91 (0.10)	0.92 (0.09)	0.90 (0.07)
	Sensibilidade	1.00 (0.00)	0.95 (0.08)	0.92 (0.09)	0.88 (0.18)	0.99 (0.03)	0.86 (0.12)
	Especificidade	1.00 (0.00)	0.93 (0.09)	0.93 (0.07)	0.95 (0.07)	0.85 (0.17)	0.94 (0.06)
	AUC	1.00 (0.00)	0.98 (0.04)	0.96 (0.04)	0.95 (0.07)	0.96 (0.07)	0.96 (0.04)
Sinal chirp	Acurácia	1.00 (0.00)	0.94 (0.05)	0.95 (0.05)	0.92 (0.09)	0.93 (0.10)	0.92 (0.07)
	Sensibilidade	1.00 (0.00)	0.97 (0.06)	0.95 (0.08)	0.90 (0.17)	0.97 (0.06)	0.88 (0.13)
	Especificidade	1.00 (0.00)	0.92 (0.10)	0.96 (0.05)	0.94 (0.08)	0.89 (0.17)	0.95 (0.04)
	AUC	1.00 (0.00)	0.96 (0.05)	0.98 (0.03)	0.94 (0.08)	0.96 (0.08)	0.95 (0.05)
Sinal pseudoaleatório binário	Acurácia	1.00 (0.00)	0.95 (0.05)	0.96 (0.04)	0.90 (0.13)	0.91 (0.10)	0.88 (0.05)
	Sensibilidade	1.00 (0.00)	0.96 (0.08)	0.96 (0.06)	0.84 (0.25)	0.97 (0.08)	0.85 (0.11)
	Especificidade	1.00 (0.00)	0.93 (0.09)	0.96 (0.05)	0.95 (0.10)	0.85 (0.19)	0.92 (0.06)
	AUC	1.00 (0.00)	0.97 (0.05)	0.95 (0.06)	0.94 (0.08)	0.95 (0.09)	0.94 (0.06)

Os resultados da Tabela 17 demonstram que o classificador SVM radial apresentou o melhor desempenho entre os classificadores avaliados, com exceção da condição “dano longe” em que o classificador KNN indicou o melhor desempenho, porém tendo o classificador SVM radial nesta mesma condição obtido resultados muito próximos. Considerando ainda as Tabelas de 11 a 17 onde o classificador RNA apresentou um

desempenho ligeiramente inferior ao classificador SVM radial para classificações com apenas 1 neurônio na camada escondida uma vez que o número de atributos de entrada é grande (512), a RNA tem um grande número de parâmetros livres que poderiam levar a um *overfit* se a validação cruzada não fosse utilizada. O modelo gerado com apenas 1 neurônio é aquele que apresenta a melhor generalização nestas condições.

Nesta primeira avaliação, os resultados foram bastante satisfatórios para as classificações quanto às condições sem dano, “dano à direita” e “dano à esquerda”. Para as classificações “dano longe”, “dano perto” e “dano severo” os resultados foram menos satisfatórios, porém também com taxas altas de acurácia e AUC. O sistema atende muito bem à sua proposta inicial, ou seja, monitorar a estrutura e classificá-la quanto à existência ou não de uma falha. Além disso, é capaz de identificar se existe ou não um dano à direita ou à esquerda do transdutor com uma taxa de acurácia bastante elevada. O sistema apresenta uma dificuldade ligeiramente superior para uma identificação de localização quanto à distância, principalmente na condição “dano longe”. Esta dificuldade está relacionada à limitação do sistema de aquisição de impedância e do método EMI para danos em estruturas localizados em regiões distantes do transdutor PZT. Este componente do sistema tem um alcance limitado devido principalmente a trabalhar em uma condição de frequência alta. Existem diferentes transdutores PZT no mercado e a escolha do modelo está condicionada à funcionalidade do sistema. (Júnior e Silva, 2005) indicam que sistemas que trabalham com faixas de frequência maiores possuem maior sensibilidade, porém menor alcance. Por outro lado, sistemas que trabalham com faixas de frequência menores e possuem maior capacidade de transmitir energia durante a vibração da estrutura possuem maior alcance, porém menor sensibilidade.

Ainda dentro desta avaliação, a condição “dano severo” também apresentou uma dificuldade ligeiramente superior de classificar corretamente a classe com falha em relação às condições “dano à direita” e “dano à esquerda”. Esta dificuldade aparenta estar relacionada ao fato de que esta condição é mais específica do que as outras condições, pois é a identificação de um dano em uma única posição, enquanto que as outras condições reúnem um grupo de condições de dano em diferentes posições. Ressalta-se ainda que os ensaios foram realizados com diferentes conjuntos de porcas e parafusos. Para o método EMI, uma pequena variação de massa entre dois parafusos ou porcas iguais, porém de lotes de fabricação diferentes, acarreta em uma variação na curva de impedância.

5.2.4. Avaliação do sistema para banda cheia com curva de 32 pontos

No passo seguinte, foi colocada a proposta de avaliar a execução do pré-processamento para extração de curvas de impedância com menos pontos. Isso permitiria uma redução considerável de esforço computacional, visto que dentro da proposta do vetor de atributos ser a própria curva de impedância, uma condição da curva com 512 amostras implica em um vetor de atributos com 512 pontos o que configura uma dimensão grande para um vetor de entrada em determinados classificadores. A diminuição do número de atributos no vetor de entrada possibilita a obtenção de modelos com maior capacidade de generalização, uma vez que o número de parâmetros livres a ser ajustados é menor. Isto posto, tem-se que a própria função *freqz* possui um parâmetro de ajuste de saída. Com isso, foram repetidos os mesmos ensaios realizados para banda cheia com 512 pontos, porém ajustando a função para gerar curvas com 256, 128, 64 e 32 pontos. Inicialmente foram realizados experimentos com o classificador KNN que demonstraram a não ocorrência de uma degradação significativa para curvas de impedância com menos amostras, inclusive para a condição de 32 amostras.

Após esta etapa de experimentos, foi realizado um novo ajuste de classificadores para as curvas com 32 amostras utilizando o mesmo procedimento dos experimentos com 512 amostras. As Tabelas 18 a 23 comparam os resultados entre os 4 classificadores avaliados para a condição de vetor de atributos com 32 pontos e o melhor resultado para a condição de 512 pontos.

Tabela 18 – Resultados dos classificadores para critério *base line*.

Sinais de excitação	Métrica	32 pontos				512 pontos
		SVM linear	KNN	RNA	SVM radial	SVM radial
Pseudoaleatório	Acurácia	0.79 (0.06)	0.97 (0.02)	0.97 (0.03)	1.00 (0.00)	1.00 (0.00)
	Sensibilidade	0.79 (0.13)	1.00 (0.00)	1.00 (0.00)	1.00 (0.00)	1.00 (0.00)
	Especificidade	0.80 (0.10)	0.94 (0.04)	0.94 (0.06)	1.00 (0.00)	1.00 (0.00)
	AUC	0.85 (0.06)	1.00 (0.00)	0.97 (0.03)	1.00 (0.00)	1.00 (0.00)
Chirp	Acurácia	0.62 (0.08)	0.96 (0.03)	0.95 (0.04)	1.00 (0.00)	1.00 (0.00)
	Sensibilidade	0.42 (0.13)	1.00 (0.00)	1.00 (0.00)	1.00 (0.00)	1.00 (0.00)
	Especificidade	0.83 (0.10)	0.92 (0.05)	0.89 (0.08)	1.00 (0.00)	1.00 (0.00)
	AUC	0.69 (0.09)	1.00 (0.00)	0.94 (0.05)	1.00 (0.00)	1.00 (0.00)
Pseudoaleatório binário	Acurácia	0.81 (0.07)	0.97 (0.03)	0.96 (0.03)	1.00 (0.00)	1.00 (0.00)
	Sensibilidade	0.84 (0.12)	1.00 (0.00)	1.00 (0.00)	1.00 (0.00)	1.00 (0.00)
	Especificidade	0.78 (0.10)	0.93 (0.06)	0.92 (0.06)	1.00 (0.00)	1.00 (0.00)
	AUC	0.85 (0.07)	1.00 (0.00)	0.95 (0.04)	1.00 (0.00)	1.00 (0.00)

Tabela 19 – Resultados dos classificadores para critério dano à direita.

Sinais de excitação	Métrica	32 pontos				512 pontos
		SVM linear	KNN	RNA	SVM radial	SVM radial
Pseudoaleatório	Acurácia	0.86 (0.07)	0.95 (0.05)	0.92 (0.07)	0.94 (0.06)	0.94 (0.06)
	Sensibilidade	0.87 (0.11)	0.97 (0.06)	0.93 (0.08)	0.95 (0.08)	0.95 (0.08)
	Especificidade	0.85 (0.12)	0.93 (0.09)	0.91 (0.11)	0.93 (0.09)	0.93 (0.09)
	AUC	0.94 (0.06)	0.96 (0.05)	0.97 (0.03)	0.98 (0.02)	0.98 (0.04)
Chirp	Acurácia	0.86 (0.07)	0.91 (0.05)	0.85 (0.09)	0.92 (0.06)	0.94 (0.05)
	Sensibilidade	0.86 (0.12)	0.91 (0.10)	0.85 (0.13)	0.92 (0.09)	0.97 (0.06)
	Especificidade	0.86 (0.13)	0.92 (0.08)	0.85 (0.13)	0.93 (0.09)	0.92 (0.10)
	AUC	0.92 (0.07)	0.96 (0.04)	0.91 (0.08)	0.95 (0.05)	0.96 (0.05)
Pseudoaleatório binário	Acurácia	0.91 (0.09)	0.93 (0.06)	0.93 (0.05)	0.95 (0.05)	0.95 (0.05)
	Sensibilidade	0.91 (0.12)	0.91 (0.10)	0.91 (0.08)	0.96 (0.10)	0.96 (0.08)
	Especificidade	0.91 (0.10)	0.94 (0.08)	0.94 (0.07)	0.94 (0.07)	0.93 (0.09)
	AUC	0.94 (0.06)	0.96 (0.05)	0.95 (0.05)	0.97 (0.03)	0.97 (0.05)

Tabela 20 – Resultados dos classificadores para critério dano à esquerda.

Sinais de excitação	Métrica	32 pontos				512 pontos
		SVM linear	KNN	RNA	SVM radial	SVM radial
Pseudoaleatório	Acurácia	0.90 (0.08)	0.92 (0.06)	0.89 (0.07)	0.94 (0.05)	0.93 (0.05)
	Sensibilidade	0.91 (0.11)	0.90 (0.13)	0.87 (0.09)	0.92 (0.11)	0.92 (0.09)
	Especificidade	0.89 (0.11)	0.94 (0.07)	0.90 (0.10)	0.95 (0.06)	0.93 (0.07)
	AUC	0.95 (0.05)	0.95 (0.04)	0.93 (0.07)	0.96 (0.04)	0.96 (0.04)
Chirp	Acurácia	0.84 (0.09)	0.90 (0.06)	0.85 (0.09)	0.91 (0.07)	0.95 (0.05)
	Sensibilidade	0.83 (0.14)	0.93 (0.09)	0.84 (0.16)	0.89 (0.14)	0.95 (0.08)
	Especificidade	0.85 (0.11)	0.88 (0.10)	0.85 (0.11)	0.93 (0.08)	0.96 (0.05)
	AUC	0.88 (0.10)	0.94 (0.06)	0.93 (0.07)	0.96 (0.05)	0.98 (0.03)
Pseudoaleatório binário	Acurácia	0.89 (0.08)	0.92 (0.05)	0.93 (0.05)	0.94 (0.06)	0.96 (0.04)
	Sensibilidade	0.89 (0.14)	0.91 (0.10)	0.93 (0.09)	0.96 (0.10)	0.96 (0.06)
	Especificidade	0.90 (0.11)	0.93 (0.08)	0.93 (0.06)	0.93 (0.08)	0.96 (0.05)
	AUC	0.94 (0.06)	0.97 (0.04)	0.95 (0.05)	0.94 (0.08)	0.95 (0.06)

Tabela 21 – Resultados dos classificadores para critério dano longe.

Sinais de excitação	Métrica	32 pontos				512 pontos
		SVM linear	KNN	RNA	SVM radial	KNN
Pseudoaleatório	Acurácia	0.86 (0.11)	0.88 (0.15)	0.86 (0.12)	0.90 (0.13)	0.91 (0.10)
	Sensibilidade	0.79 (0.19)	0.84 (0.29)	0.85 (0.21)	0.86 (0.25)	0.88 (0.18)
	Especificidade	0.94 (0.08)	0.92 (0.11)	0.88 (0.15)	0.94 (0.08)	0.95 (0.07)
	AUC	0.88 (0.15)	0.93 (0.11)	0.90 (0.11)	0.96 (0.07)	0.95 (0.07)
Chirp	Acurácia	0.83 (0.12)	0.91 (0.12)	0.82 (0.12)	0.90 (0.10)	0.92 (0.09)
	Sensibilidade	0.77 (0.21)	0.89 (0.18)	0.75 (0.25)	0.89 (0.19)	0.90 (0.17)
	Especificidade	0.89 (0.13)	0.93 (0.09)	0.88 (0.12)	0.91 (0.12)	0.94 (0.08)
	AUC	0.89 (0.11)	0.92 (0.13)	0.91 (0.11)	0.96 (0.06)	0.94 (0.08)
Pseudoaleatório binário	Acurácia	0.90 (0.09)	0.90 (0.09)	0.89 (0.09)	0.92 (0.09)	0.90 (0.13)
	Sensibilidade	0.85 (0.17)	0.88 (0.15)	0.85 (0.17)	0.88 (0.18)	0.84 (0.25)
	Especificidade	0.95 (0.08)	0.93 (0.10)	0.92 (0.10)	0.96 (0.07)	0.95 (0.10)
	AUC	0.96 (0.08)	0.94 (0.08)	0.93 (0.09)	0.95 (0.06)	0.94 (0.08)

Tabela 22 – Resultados dos classificadores para critério dano perto.

Sinais de excitação	Métrica	32 pontos				512 pontos
		SVM linear	KNN	RNA	SVM radial	SVM radial
Pseudoaleatório	Acurácia	0.88 (0.10)	0.94 (0.08)	0.91 (0.10)	0.93 (0.08)	0.92 (0.09)
	Sensibilidade	0.94 (0.12)	0.98 (0.06)	0.95 (0.08)	0.97 (0.08)	0.99 (0.03)
	Especificidade	0.82 (0.17)	0.90 (0.14)	0.87 (0.19)	0.90 (0.16)	0.85 (0.17)
	AUC	0.93 (0.13)	0.97 (0.05)	0.95 (0.10)	0.96 (0.06)	0.96 (0.07)
Chirp	Acurácia	0.83 (0.12)	0.91 (0.10)	0.89 (0.09)	0.93 (0.09)	0.93 (0.10)
	Sensibilidade	0.92 (0.10)	0.97 (0.06)	0.90 (0.15)	0.99 (0.04)	0.97 (0.06)
	Especificidade	0.75 (0.25)	0.84 (0.18)	0.88 (0.14)	0.87 (0.17)	0.89 (0.17)
	AUC	0.89 (0.13)	0.93 (0.10)	0.89 (0.13)	0.94 (0.09)	0.96 (0.08)
Pseudoaleatório binário	Acurácia	0.93 (0.09)	0.92 (0.10)	0.91 (0.09)	0.93 (0.08)	0.91 (0.10)
	Sensibilidade	0.98 (0.05)	0.97 (0.06)	0.93 (0.13)	0.99 (0.03)	0.97 (0.08)
	Especificidade	0.87 (0.18)	0.87 (0.19)	0.89 (0.16)	0.87 (0.17)	0.85 (0.19)
	AUC	0.95 (0.07)	0.94 (0.08)	0.94 (0.10)	0.95 (0.09)	0.95 (0.09)

Tabela 23 – Resultados dos classificadores para critério dano severo.

Sinais de excitação	Métrica	32 pontos				512 pontos
		SVM linear	KNN	RNA	SVM radial	SVM radial
Pseudoaleatório	Acurácia	0.71 (0.07)	0.89 (0.07)	0.84 (0.08)	0.89 (0.06)	0.90 (0.07)
	Sensibilidade	0.51 (0.15)	0.83 (0.13)	0.79 (0.18)	0.83 (0.12)	0.86 (0.12)
	Especificidade	0.91 (0.07)	0.95 (0.06)	0.88 (0.07)	0.96 (0.04)	0.94 (0.06)
	AUC	0.83 (0.09)	0.96 (0.05)	0.91 (0.08)	0.94 (0.06)	0.96 (0.04)
Chirp	Acurácia	0.75 (0.11)	0.87 (0.08)	0.82 (0.09)	0.88 (0.08)	0.92 (0.07)
	Sensibilidade	0.58 (0.19)	0.82 (0.16)	0.78 (0.18)	0.81 (0.17)	0.88 (0.13)
	Especificidade	0.91 (0.06)	0.92 (0.06)	0.86 (0.08)	0.95 (0.04)	0.95 (0.04)
	AUC	0.82 (0.10)	0.94 (0.06)	0.88 (0.08)	0.94 (0.05)	0.95 (0.05)
Pseudoaleatório binário	Acurácia	0.82 (0.09)	0.89 (0.06)	0.89 (0.07)	0.90 (0.06)	0.88 (0.05)
	Sensibilidade	0.74 (0.18)	0.84 (0.11)	0.86 (0.13)	0.86 (0.11)	0.85 (0.11)
	Especificidade	0.89 (0.07)	0.94 (0.05)	0.92 (0.06)	0.95 (0.05)	0.92 (0.06)
	AUC	0.90 (0.06)	0.96 (0.04)	0.94 (0.06)	0.95 (0.06)	0.94 (0.06)

Cabe destacar os resultados dos ajustes do classificador RNA (vide Tabelas 24 a 29) que demonstram evidências importantes sobre as características do modelo estudado. Os resultados do ajuste deste classificador, em especial, demonstram um desempenho similar entre 2 (dois) ou mais neurônios na camada escondida.

Tabela 24 – Ajuste do classificador RNA para o critério *base line*.

Número de neurônios	Partições	Repetições	Acurácia	AUC
1	10	3	0,87 (0,07)	0,80 (0,10)
2	10	3	0,94 (0,03)	0,93 (0,05)
3	10	3	0,97 (0,02)	0,96 (0,04)
4	10	3	0,96 (0,03)	0,96 (0,03)
5	10	3	0,97 (0,03)	0,97 (0,03)

Tabela 25 – Ajuste do classificador RNA para o critério “dano à direita”.

Número de neurônios	Partições	Repetições	Acurácia	AUC
1	10	3	0,83 (0,09)	0,93 (0,06)
2	10	3	0,86 (0,09)	0,93 (0,06)
3	10	3	0,88 (0,08)	0,94 (0,09)
4	10	3	0,87 (0,09)	0,94 (0,06)
5	10	3	0,89 (0,08)	0,95 (0,06)

Tabela 26 – Ajuste do classificador RNA para o critério “dano à esquerda”.

Número de neurônios	Partições	Repetições	Acurácia	AUC
1	10	3	0,87 (0,10)	0,94 (0,06)
2	10	3	0,86 (0,08)	0,94 (0,05)
3	10	3	0,84 (0,09)	0,92 (0,07)
4	10	3	0,88 (0,08)	0,93 (0,06)
5	10	3	0,85 (0,10)	0,91 (0,09)

Tabela 27 – Ajuste do classificador RNA para o critério “dano longe”.

Número de neurônios	Partições	Repetições	Acurácia	AUC
1	10	3	0,83 (0,10)	0,89 (0,12)
2	10	3	0,84 (0,13)	0,87 (0,13)
3	10	3	0,84 (0,14)	0,89 (0,15)
4	10	3	0,86 (0,12)	0,90 (0,11)
5	10	3	0,81 (0,10)	0,89 (0,11)

Tabela 28 – Ajuste do classificador RNA para o critério “dano perto”.

Número de neurônios	Partições	Repetições	Acurácia	AUC
1	10	3	0,85 (0,10)	0,91 (0,10)
2	10	3	0,88 (0,08)	0,92 (0,09)
3	10	3	0,85 (0,10)	0,90 (0,14)
4	10	3	0,88 (0,11)	0,92 (0,10)
5	10	3	0,91 (0,10)	0,95 (0,10)

Tabela 29 – Ajuste do classificador RNA para o critério “dano severo”.

Número de neurônios	Partições	Repetições	Acurácia	AUC
1	10	3	0,75 (0,10)	0,83 (0,08)
2	10	3	0,80 (0,08)	0,86 (0,08)
3	10	3	0,78 (0,10)	0,85 (0,08)
4	10	3	0,79 (0,11)	0,87 (0,07)
5	10	3	0,78 (0,09)	0,86 (0,07)

Com base nos resultados apresentados pelo classificador SVM linear e pelo baixo número de neurônios na camada escondida, sugere-se que, para esta estrutura, o problema de classificação possui uma fronteira de decisão quase linear. Para os experimentos com 32 pontos novamente o classificador SVM radial se destacou com os melhores resultados, sendo que o classificador KNN também obteve um desempenho muito próximo. O classificador linear definido para esses experimentos, no caso o SVM linear, apresentou um desempenho pior, porém tendo em alguns casos um desempenho bastante competitivo.

Em geral, os resultados dos classificadores com o sinal de excitação *chirp* demonstraram um resultado pior em comparação aos outros classificadores. Isso evidencia que neste modelo de banda cheia os atributos extraídos das frequências maiores podem ter influenciado negativamente nos resultados, visto que esse sinal de excitação não possui bom desempenho em altas frequências para este sistema proposto. Isso reforça a necessidade de uma avaliação de um modelo em sub-bandas.

Os resultados dos classificadores para exemplos na condição “dano longe” apresentaram um índice de dispersão elevado, evidenciando a dificuldade do sistema de aquisição em monitorar as partes mais distantes do transdutor (limitação do alcance mencionado no item 5.2.3), ou seja, danos nas posições 1 e/ou 10, por exemplo, tem pouco efeito na impedância do transdutor PZT.

O classificador KNN apresentou melhor desempenho quando executado tendo em seu principal parâmetro 1 (um) vizinho ou, no máximo, 3 (três) vizinhos. Isso sugere que o conjunto de dados não é ruidoso e uma fronteira de decisão suave já é alcançada com poucos vizinhos.

As curvas ROC, vide Figuras 35 a 40, ilustram ainda uma comparação efetiva dos classificadores quanto ao desempenho nesse indicador. Um falso negativo é considerado um aspecto muito crítico na manutenção aeronáutica, pois tal avaliação compromete diretamente a segurança de voo. Se for observada a composição das taxas de sensibilidade e especificidade, que compõem as curvas ROC, tem-se que

- $sensibilidade = \frac{positivos\ reais}{(positivos\ reais + falsos\ negativos)}$
- $especificidade = \frac{negativos\ reais}{(falsos\ positivos + negativos\ reais)}$.

Isto posto, tem-se a sensibilidade como um indicador crítico para este sistema. Se considerar-se uma taxa mínima adequada de até 20% para o indicador $(1 - especificidade)$, então a região das curvas ROC delimitada por este parâmetro se torna relevante para a análise. Para esta última análise, a Figura 41 ilustra a delimitação da área.




Figura 35 – Curva ROC para sinal de excitação pseudoaleatório, condição da barra *base line* e curva de impedância com 32 pontos.

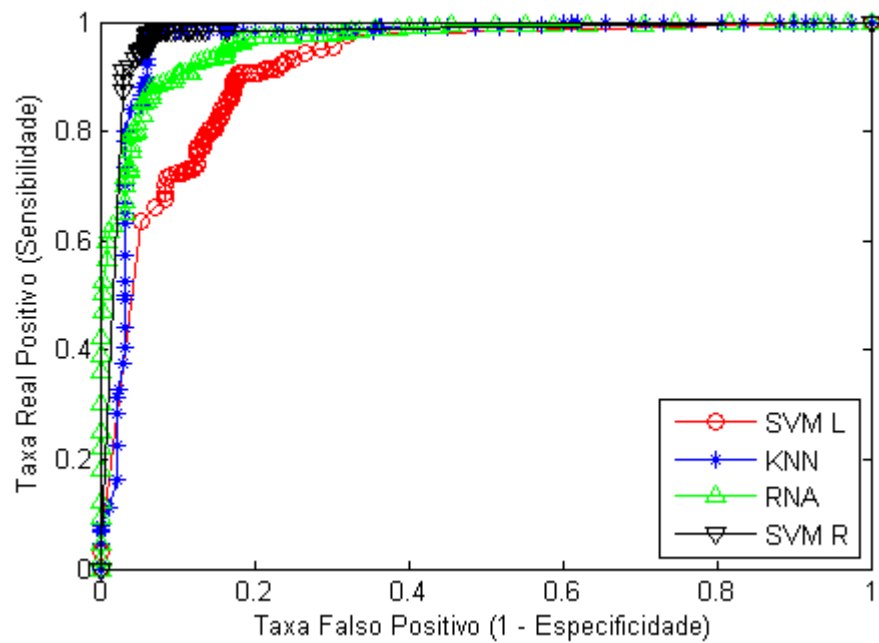


Figura 36 – Curva ROC para sinal de excitação pseudoaleatório, condição da barra “dano à direita” e curva de impedância com 32 pontos.




Figura 37 – Curva ROC para sinal de excitação pseudoaleatório, condição da barra “dano à esquerda” e curva de impedância com 32 pontos.




Figura 38 – Curva ROC para sinal de excitação pseudoaleatório, condição da barra “dano longe” e curva de impedância com 32 pontos.




Figura 39 – Curva ROC para sinal de excitação pseudoaleatório, condição da barra “dano perto” e curva de impedância com 32 pontos.




Figura 40 – Curva ROC para sinal de excitação pseudoaleatório, condição da barra “dano severo” e curva de impedância com 32 pontos.




Figura 41– Curva ROC para sinal de excitação pseudoaleatório, condição da barra *base line* e curva de impedância com 32 pontos com limitação de área (zoom da Figura 35).

Com base na avaliação anterior, considerando a região da curva ROC delimitada pela faixa entre zero e 20% do indicador (1 – especificidade), então se pode observar que, apesar dos valores absolutos de AUC estarem próximos entre os diferentes classificadores avaliados, a referida região ressalta uma diferença de desempenho entre os mesmos classificadores. Em quase todos os casos o classificador SVM linear apresentou um desempenho muito abaixo dos outros classificadores para esta região. Por outro lado, os classificadores SVM radial e KNN apresentam desempenhos muito próximos, da mesma forma como já fora observado nos valores de AUC pelas respectivas Tabelas de resultados.

5.2.5. Avaliação do sistema para sub-bandas

A análise em sub-bandas é mencionada ao longo deste trabalho e sua importância foi observada em algumas oportunidades, como por exemplo durante a observação dos resultados dos classificadores para o sinal de excitação *chirp*. Esta análise está inserida dentro do desenvolvimento de sistemas de monitoramento e passa pela avaliação de um novo pré-processamento que permita realizar a classificação dentro de uma análise em sub-bandas.

A necessidade de buscar uma faixa ótima de frequência para o monitoramento de estruturas é mencionado em outros trabalhos (Baptista, 2010), (Giurgiutiu, 2005), (Junior, 2000), (Palomino, 2008) e (Park e Inman, 2005). Em geral, esta busca é feita por tentativa e erro ou por meio de uma avaliação visual da própria curva de impedância na tentativa de identificar os picos de impedância.

Na seção 4.3.4 foi descrito o modelo para o processamento e extração da curva de impedância dentro da análise em sub-bandas, rotulada como modelo 2. A Figura 26 ilustra o modelo 2 e apresenta o método para a aquisição das curvas de impedância dentro da análise de sub-bandas.

Conforme definido na seção 4.3.4, optou-se por utilizar 4 (quatro) decomposições distintas: $L = 2, 4, 8$ e 16 sub-bandas. Também foi definido utilizar 2 fatores de decimação para cada caso: $M = L/2$ e $M = L$. Os resultados para 8 sub-bandas ilustram mais claramente as observações que se seguem até o final desta seção. Na Tabela 30 encontram-se os resultados do classificador KNN com 1 vizinho para a condição “dano à direita”, com $L = 8$ e $M = L/2$. Nestes exemplos, foram extraídas curvas de impedância com 32 pontos. As 8 bandas são especificadas pelas seguintes faixas:

- B1 (entre zero e 15,63kHz);
- B2 (entre 15,63kHz e 31,25kHz);
- B3 (entre 31,25kHz e 46,88kHz);
- B4 (entre 46,88kHz e 62,50kHz);
- B5 (entre 62,50kHz e 78,13kHz);
- B6 (entre 78,13kHz e 93,75kHz);
- B7 (93,75kHz e 109,38kHz); e
- B8 (entre 109,38kHz e 125kHz).

Analisando os resultados das classificações para o modelo 2 (em sub-bandas), é possível observar que a busca por uma faixa ótima de frequência tem importância, pois as taxas de acerto do classificador modificam-se sensivelmente em cada banda avaliada. Em que pese ainda não ter sido possível desenvolver um método mais preciso para a busca ótima, é possível fazer algumas considerações.

O sinal *chirp* demonstrou, conforme previsto anteriormente, que possui resultados válidos apenas para frequências intermediárias, mais especificamente entre 30kHz e 80kHz (B3, B4 e B5). Este aspecto está relacionado à característica do sinal *chirp* que procura construir um sinal linear contendo todas as frequências definidas em seus parâmetros de

entrada. Ressalta-se ainda que o sinal chirp foi programado no MATLAB[®] para esses experimentos com uma faixa entre zero e 60kHz.

Tabela 30 – Resultados do classificador KNN para sub-bandas critério “dano à direita”.

Sinais de excitação		L = 8 e M = 4							
		B1	B2	B3	B4	B5	B6	B7	B8
Pseudoaleat.	Acurácia	0,95 (0,05)	0,95 (0,05)	0,94 (0,05)	0,92 (0,07)	0,91 (0,07)	0,91 (0,06)	0,91 (0,07)	0,91 (0,05)
	Sensib.	0,95 (0,06)	0,95 (0,08)	0,95 (0,06)	0,92 (0,09)	0,91 (0,10)	0,90 (0,11)	0,91 (0,09)	0,93 (0,07)
	Especif.	0,96 (0,07)	0,94 (0,08)	0,93 (0,10)	0,92 (0,11)	0,92 (0,11)	0,92 (0,08)	0,92 (0,10)	0,89 (0,11)
	AUC	0,98(0,04)	0,97 (0,04)	0,97 (0,05)	0,94 (0,08)	0,95 (0,06)	0,96 (0,05)	0,94 (0,07)	0,94 (0,06)
chirp	Acurácia	0,88 (0,08)	0,88 (0,06)	0,90 (0,07)	0,91 (0,06)	0,91 (0,08)	0,84 (0,09)	0,75 (0,12)	0,84 (0,09)
	Sensib.	0,89 (0,09)	0,88 (0,09)	0,94 (0,09)	0,92 (0,09)	0,93 (0,09)	0,85 (0,14)	0,75 (0,12)	0,83 (0,13)
	Especif.	0,86 (0,11)	0,88 (0,10)	0,87 (0,12)	0,89 (0,10)	0,88 (0,12)	0,84 (0,12)	0,76 (0,21)	0,84 (0,13)
	AUC	0,93 (0,06)	0,92 (0,05)	0,95 (0,05)	0,94 (0,06)	0,95 (0,05)	0,93 (0,06)	0,85 (0,12)	0,91 (0,07)
Pseudoaleat. binário	Acurácia	0,93 (0,05)	0,93 (0,07)	0,92 (0,07)	0,92 (0,06)	0,90 (0,09)	0,91 (0,05)	0,90 (0,09)	0,92 (0,07)
	Sensib.	0,94 (0,08)	0,93 (0,08)	0,90 (0,11)	0,92 (0,10)	0,88 (0,13)	0,91 (0,08)	0,91 (0,10)	0,92 (0,07)
	Especif.	0,93 (0,09)	0,93 (0,09)	0,93 (0,08)	0,92 (0,09)	0,92 (0,10)	0,91 (0,09)	0,90 (0,13)	0,92 (0,10)
	AUC	0,96 (0,05)	0,96 (0,05)	0,95 (0,05)	0,96 (0,04)	0,95 (0,08)	0,95 (0,05)	0,94 (0,08)	0,93 (0,08)

Ao contrário do sinal *chirp*, os sinais pseudoaleatório e pseudoaleatório binário são capazes de monitorar com razoáveis taxas de acerto toda a faixa de frequência permitida pela placa de aquisição utilizada. Porém, cabe destacar que os maiores acertos encontram-se nas faixas de frequências menores.

Na Tabela 31, onde é possível visualizar os resultados do classificador KNN para modelo em sub-banda e critério de análise “dano longe”, constata-se novamente que os melhores resultados encontram-se nas sub-bandas de menores frequências, neste caso entre B2 e B4. Especialmente para esse ensaio, o sinal *chirp* apresentou os melhores resultados.

Tabela 31 – Resultados do classificador KNN para sub-bandas critério “dano longe”.

Sinais de excitação		L = 8 e M = 4							
		B1	B2	B3	B4	B5	B6	B7	B8
Pseudoaleat.	Acurácia	0,83 (0,12)	0,83 (0,11)	0,87 (0,10)	0,86 (0,09)	0,86 (0,11)	0,83 (0,12)	0,85 (0,14)	0,86 (0,10)
	Sensib.	0,76 (0,24)	0,74 (0,21)	0,82 (0,19)	0,81 (0,19)	0,80 (0,21)	0,77 (0,23)	0,78 (0,25)	0,81 (0,19)
	Especif.	0,91 (0,12)	0,92 (0,10)	0,93 (0,11)	0,92 (0,10)	0,92 (0,10)	0,89 (0,13)	0,92 (0,12)	0,92 (0,10)
	AUC	0,88 (0,14)	0,90 (0,10)	0,93 (0,11)	0,93 (0,08)	0,91 (0,10)	0,92 (0,09)	0,90 (0,11)	0,91 (0,08)
chirp	Acurácia	0,87 (0,10)	0,91 (0,08)	0,92 (0,09)	0,90 (0,10)	0,82 (0,14)	0,85 (0,12)	0,81 (0,12)	0,81 (0,15)
	Sensib.	0,86 (0,17)	0,90 (0,15)	0,91 (0,15)	0,87 (0,21)	0,77 (0,23)	0,79 (0,18)	0,74 (0,26)	0,70 (0,29)
	Especif.	0,89 (0,11)	0,92 (0,11)	0,93 (0,10)	0,93 (0,10)	0,87 (0,14)	0,92 (0,13)	0,88 (0,10)	0,92 (0,10)
	AUC	0,92 (0,08)	0,94 (0,10)	0,94 (0,09)	0,95 (0,07)	0,92 (0,11)	0,92 (0,08)	0,84 (0,12)	0,87 (0,12)
Pseudoaleat. binário	Acurácia	0,88 (0,10)	0,86 (0,14)	0,86 (0,09)	0,84 (0,13)	0,76 (0,16)	0,80 (0,15)	0,83 (0,12)	0,83 (0,12)
	Sensib.	0,82 (0,20)	0,81 (0,23)	0,82 (0,17)	0,79 (0,23)	0,67 (0,30)	0,72 (0,25)	0,75 (0,25)	0,76 (0,23)
	Especif.	0,93 (0,09)	0,92 (0,13)	0,89 (0,13)	0,89 (0,11)	0,86 (0,13)	0,88 (0,15)	0,91 (0,12)	0,91 (0,10)
	AUC	0,93 (0,08)	0,92 (0,11)	0,90 (0,11)	0,88 (0,13)	0,84 (0,15)	0,89 (0,14)	0,87 (0,15)	0,88 (0,13)

Para o critério da análise “dano severo” (ver Tabela 32), o sinal pseudoaleatório apresentou resultados de acurácia melhores do que os experimentos em banda cheia. Estas taxas são identificadas entre as sub-bandas B3 e B6. Apesar desta constatação, em geral os resultados em sub-banda são similares ou ligeiramente piores do que os resultados em banda cheia. Em contrapartida, é possível identificar as melhores faixas de frequência para as análises e classificações dentro deste sistema proposto, ainda que em uma análise preliminar.

Tabela 32 – Resultados do classificador KNN para sub-bandas critério “dano severo”.

Sinais de excitação		L = 8 e M = 4							
		B1	B2	B3	B4	B5	B6	B7	B8
Pseudoaleat.	Acurácia	0,87 (0,07)	0,85 (0,07)	0,90 (0,06)	0,91 (0,07)	0,92 (0,06)	0,90 (0,08)	0,88 (0,09)	0,89 (0,06)
	Sensib.	0,82 (0,14)	0,81 (0,13)	0,87 (0,13)	0,88 (0,12)	0,89 (0,11)	0,86 (0,14)	0,82 (0,17)	0,84 (0,12)
	Especif.	0,91 (0,07)	0,90 (0,06)	0,94 (0,05)	0,94 (0,05)	0,94 (0,05)	0,94 (0,06)	0,94 (0,05)	0,94 (0,05)
	AUC	0,92 (0,05)	0,89 (0,07)	0,93 (0,07)	0,95 (0,05)	0,95 (0,04)	0,93 (0,06)	0,91 (0,08)	0,94 (0,05)
chirp	Acurácia	0,85 (0,08)	0,85 (0,08)	0,87 (0,08)	0,85 (0,08)	0,86 (0,08)	0,83 (0,10)	0,74 (0,08)	0,80 (0,08)
	Sensib.	0,78 (0,15)	0,78 (0,15)	0,80 (0,15)	0,77 (0,17)	0,78 (0,18)	0,74 (0,18)	0,59 (0,16)	0,73 (0,14)
	Especif.	0,91 (0,05)	0,93 (0,05)	0,93 (0,05)	0,92 (0,06)	0,93 (0,05)	0,92 (0,07)	0,89 (0,07)	0,87 (0,07)
	AUC	0,91 (0,05)	0,93 (0,07)	0,92 (0,06)	0,92 (0,06)	0,91 (0,08)	0,92 (0,07)	0,86 (0,06)	0,87 (0,07)
Pseudoaleat. binário	Acurácia	0,85 (0,08)	0,84 (0,08)	0,83 (0,08)	0,85 (0,08)	0,84 (0,06)	0,83 (0,09)	0,85 (0,07)	0,86 (0,08)
	Sensib.	0,80 (0,15)	0,77 (0,13)	0,76 (0,14)	0,78 (0,16)	0,76 (0,11)	0,74 (0,19)	0,78 (0,14)	0,78 (0,16)
	Especif.	0,90 (0,06)	0,92 (0,07)	0,90 (0,08)	0,91 (0,06)	0,91 (0,07)	0,92 (0,07)	0,92 (0,06)	0,94 (0,06)
	AUC	0,91 (0,07)	0,91 (0,07)	0,88 (0,08)	0,90 (0,07)	0,90 (0,07)	0,92 (0,07)	0,93 (0,05)	0,94 (0,07)

6. CONCLUSÃO

Dentro da proposta de desenvolvimento de sistemas inteligentes para monitoramento de estruturas, os resultados foram além das expectativas, visto que foi possível identificar e classificar critérios elencados ao longo do trabalho com taxas de acerto próximas à totalidade dos exemplos.

O primeiro sistema propunha a classificar imagens de ultrassom com vista ao apoio à decisão em reparo estrutural e teve como desafios a definição dos atributos a serem extraídos e classificados. Após a realização de 4 diferentes experimentos, com o ajuste de 4 classificadores (SVM linear, KNN, RNA e SVM radial), foi possível alcançar resultados bastante positivos, com taxas de acurácia de 99%. Este primeiro sistema vislumbra a possibilidade de trabalhos futuros como a investigação de métodos que sejam capazes de extrair características que possam ser utilizadas para a classificação, diretamente a partir da imagem obtida pelo mapeamento realizado pela varredura de ultrassom, com ênfase naquelas que tragam informação espacial das áreas críticas da peça analisada.

O segundo sistema tinha como objetivo o desenvolvimento de um sistema de monitoramento de baixo custo capaz de classificar curvas de impedância de um transdutor PZT quanto a diferentes critérios de dano em uma barra de alumínio. As validações realizadas durante este trabalho mostraram que o sistema de aquisição de impedância desenvolvido atende perfeitamente ao modelo proposto inicialmente. Quanto aos resultados das classificações das curvas de impedância, o sistema proposto apresentou em geral um ótimo resultado, com destaque para o classificador SVM radial. Os resultados foram bastante satisfatórios para as classificações quanto às condições sem dano, “dano à direita” e “dano à esquerda”. Para as classificações “dano longe”, “dano perto” e “dano severo” os resultados foram menos satisfatórios, porém também com taxas altas de acurácia e AUC. O sistema atende muito bem à sua proposta inicial, ou seja, monitorar a estrutura e classificá-la quanto à existência ou não de uma falha. Além disso, é capaz de identificar se existe ou não um dano à direita ou à esquerda do transdutor com uma taxa de acurácia bastante elevada. O sistema apresenta uma dificuldade ligeiramente superior para uma identificação de localização quanto à distância, principalmente na condição “dano longe”. Esta dificuldade está relacionada à limitação do sistema de aquisição de impedância e do método EMI para danos em estruturas localizados em regiões distantes do transdutor PZT. Cabe, neste caso, um estudo de estimativa de alcance do PZT para trabalhos futuros.

Com base nos resultados apresentados pelo classificador SVM linear e pelo baixo número de neurônios na camada escondida, sugere-se que, para esta estrutura, o problema de classificação possui uma fronteira de decisão quase linear. É possível avaliar a possibilidade do desenvolvimento em trabalhos futuros de um sistema para operação em condições reais em face de ser um sistema de aquisição de impedância de baixo custo e de possuir uma estrutura simples, porém eficiente. Para o monitoramento de grandes estruturas, uma solução seria a implementação de vários sistemas de monitoramento em paralelo, o que tornaria a solução mais robusta em comparação com outros sistemas compostos, por vezes, de dezenas de transdutores PZT. É possível ainda uma análise composta entre as diferentes métricas dos classificadores como, por exemplo, uma análise entre as avaliações dos classificadores dano à direita e dano severo.

Quanto ao modelo em sub-bandas, foi possível identificar a importância da busca de uma faixa ótima de frequência como, por exemplo, as sub-bandas existentes entre as frequências 20kHz e 80kHz observadas com os melhores resultados. Em que pese os resultados nesta avaliação terem sido preliminares, a continuidade no desenvolvimento de modelos em sub-bandas para obter um procedimento sistemático para a escolha da faixa de frequência adequada é válido. Sugere-se ainda como trabalhos futuros a implementação de um Algoritmo Genético para a realização de uma busca otimizada da faixa de frequência ótima em face da infinidade de combinações de faixas dentro de todo um espectro de monitoramento.

REFERÊNCIAS

AMARAL, J. L. M. ; LOPES, L. A. R. Sistema Classificador para Apoio a Decisão em Reparo Estrutural de Componentes Aeronáutico. In: X SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE, 2011, São João del-Rei, **Anais do X Simpósio Brasileiro de Automação Inteligente**, 2011. p. 510-515.

AMARAL, J. L. M. ; LOPES, A. J. ; JANSEN J. M. ; MELO P. L. Machine Learning Algorithms and forced oscillation measurements applied to the automatic identification of chronic obstructive pulmonary disease. **Journal of Computer Methods and Programs in Biomedicine**, 2012, vol. 105 Issue 3. p. 183-193.

BAPTISTA, F. G. **Uma Contribuição aos Sistemas de Monitoramento de Integridade Estrutural Baseados na Impedância Eletromecânica**. 2010. 91f. Tese (Doutorado). Departamento de Engenharia Elétrica, Faculdade de Engenharia de Ilha Solteira, São Paulo, 2010.

BAPTISTA, F. G. ; FILHO, J. V. Optimal Frequency Range Selection for PZT Transducers in Impedance-Based SHM Systems. **IEEE Sensors Journal**, 2010, vol. 10, Nº 8.

BAPTISTA, F. G. ; FILHO, J. V. ; INMAN, D. J. Real-time multi-sensors measurement system with temperature effects compensation for impedance-based structural health monitoring. **Journal of Structural Health Monitoring**. 2011. Disponível em <http://shm.sagepub.com/content/11/2/173>.

BAPTISTA, F. G. ; FILHO, J. V. ; INMAN, D. J. Influence of Excitation Signal on Impedance-based Structural Health Monitoring. **Journal of Intelligent Material Systems and Structures**, 2010, disponível em <http://jim.sagepub.com/content/21/14/1409>.

BATALHEIRO, P. B. **Desenvolvimento de filtros protótipos para filtragem adaptativa em sub-bandas**. 2000. 97f. Tese (Mestrado). Engenharia Elétrica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2000.

BHALLA, S. *et al.* Ultra Low-cost Adaptations of Electro-mechanical Impedance Technique for Structural Health Monitoring. **Journal of Intelligent Material Systems and Structures**, 2009, disponível em <http://jim.sagepub.com/content/20/8/991>.

BITENCOURT, C. ; TSURUTA, K. M. ; RADE, R. S. L. Avaliação de falhas em ensaio de fadiga em corpo de prova de alumínio através do método de impedância. In: XVII SIMPÓSIO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA. 2007, Uberlândia, **Anais do XVII simpósio do programa de pós-graduação em engenharia mecânica**, 2007.

BITENCOURT, T. F. *et al.* Desenvolvimento de um Sistema de Medição de Sinais de Impedância para Monitoramento de Integridade Estrutural Baseado em Impedância Eletromecânica. In: VI CONGRESSO NACIONAL DE ENGENHARIA MECÂNICA, 2010, Campina Grande, **Anais do VI**

Congresso Nacional de Engenharia Mecânica, 2010.

BITENCOURT, T. F. ; JÚNIOR, V. S. **Monitoramento de Integridade Estrutural de Aeronaves.** 2009. 18f. Trabalho de Conclusão de Curso (Especialização) – Faculdade de Engenharia Mecânica, Universidade Federal de Uberlândia, Uberlândia, 2009.

BOEING, **Aircraft Structural Repair for Engineers - Training Manual**, Curso de Reparo Estrutural da Boeing, 2003.

BOEING, cap 57-wing. In: **Service Repair Maintenance - SRM N° D6-2962**, Technical Manual, 1988.

BRAY, D. E. ; McBRIDE, D. **Nondestructive Testing Techniques.** N.Y.: AWiley-Interscience Publication, 1992. 765 p.

CATELLÓ, J. ; GARCIA-GIL, R., ESPÍ, J. M. A PC-based low cost impedance and gain-phase analyzer. **International Journal of Elsevier.** 2007. Disponível em www.elsevier.com/locate/measurement.

CHAUDHRY, Z. *et al.* Monitoring the Integrity of Composite Patch Structural Repair Via Piezoelectric Actuators/Sensors. In: 36th STRUCTURES, STRUCTURAL DYNAMICS AND MATERIALS CONFERENCE, ADAPTIVE STRUCTURES FORUM, 1995, **AIAA Publishing pp. 2243–2248.**

CORTEZ, N. E. ; FILHO, J. V. ; BAPTISTA, F. G. A New Microcontrolled Structural Health Monitoring System Based on the Electromechanical Impedance Principle. **Journal of Structural Health Monitoring.** 2012. Disponível em <http://shm.sagepub.com/content/early/2012/09/16/1475921712461163>.

DOSCH, J. J. ; INMAN, D. J. ; GARCIA, E. A Self sensing piezoelectric actuator for collocated control. **Journal of Intelligent Material Systems and Structures**, 1992, p 166-185.

DUDA, R. O. ; HART, P. E. ; STORK, D. G. **Pattern Classification**, Wiley-Interscience. 2000.

DUIN, R. P. W. *et al.* **PRTools4.1, A Matlab Toolbox for Pattern Recognition**, Delft University of Technology. 2007.

FARRAR, C. R. ; LIEVEN, N. A. J. ; BENENT, M. T. An Introduction to Damage Prognosis. In: **Damage Prognosis for Aerospace, Civil and Mechanical System**; Wyle, Inglaterra, 2005, p. 449.

FAWCETT, TOM. An introduction to ROC analysis. **International Journal of Elsevier.** 2005. Disponível em www.elsevier.com/locate/patrec.

FILHO, J. V. ; BAPTISTA, F. A. New impedance measurement system for PZT based structural health monitoring. **IEEE Trans Instrum Meas** 2008; 58(10): 3602–3608.

FILHO, J. V. ; BAPTISTA, F. G. ; INMAN, D. J. Time-domain analysis of piezoelectric impedance-based structural health monitoring using multilevel wavelet. **Journal of Mechanical Systems and Signal Processing**. 2011. p. 1550-1558.

FINZI NETO, R. M. *et al.* A Low-cost electromechanical impedance-based SHM architecture for multiplexed piezoceramic actuators. **Journal of Structural Health Monitoring**. 2010. Disponível em <http://shm.sagepub.com/content/early/2010/08/05/1475921710379518>.

FRANCO, V. R. **Monitoramento da Integridade em Estruturas Aeronáuticas**. 2009. 202f. Dissertação (Mestrado). Departamento de Engenharia Mecânica, Faculdade de Engenharia de Ilha Solteira, São Paulo, 2009.

FURTADO, R. M. **Identificação de Falhas Estruturais Usando Sensores e Atuadores Piezoelétricos e Redes Neurais Artificiais**. 2004. 152 f. Dissertação (Mestrado). Departamento de Engenharia Elétrica, Faculdade de Engenharia de Ilha Solteira, São Paulo, 2004.

GIURGIUTIU, V. ; ZAGRAI, A. N. Damage detection in thin plates and aerospace structures with the electro-mechanical impedance method. **Journal of Structural Health Monitoring** 2005; 4: 99–118.

GIURGIUTIU, V. *et al.* Active Sensors for Health Monitoring of Aging Aerospace Structures. **International Journal of the Condition Monitoring and Diagnostic Engineering Management**, 2003, 6(1). 3–21.

GIURGIUTIU, V. ; ZAGRAI, A. ; BAO, J. J. Piezoelectric Wafer Embedded Active Sensors for Aging Aircraft Structural Health Monitoring. **Journal of Structural Health Monitoring**, 2002, 1. 41–61.

GIURGIUTIU, V. ; REYNOLDS, A. ; ROGERS, C. A. Experimental investigation of E/M impedance health monitoring of spot-welded structural joints. **Journal of Intelligent Material Systems and Structures** 1999; 10, 802-812.

GIURGIUTIU, V. ; ROGERS, C. A. Recent advancements in the electro-mechanical (E/M) impedance method for structural health monitoring and NDE. In: ANNUAL INTERNATIONAL SYMPOSIUM ON SMART STRUCTURES AND MATERIALS, 5., 1998, San Diego. **Anais do Annual International Symposium on Smart Structures and Materials**, 1998. v. 3329. p. 536-547.

GLOTSOS, DIMITRIS *et al.* A multi-classifier system for the characterization of normal, infectious, and cancerous prostate tissues employing transrectal ultrasound images. **International Journal of Elsevier**. 2009. Disponível em www.intl.elsevierhealth.com/journals/cmpb.

HALL, S.R. ; CONQUEST, T. J. The total data integrity initiative structural health monitoring, the next generation. In: **USAF ASIP Conference**. Melbourne. 1999.

HAYKIN, S. S. **Redes Neurais: Princípios e Prática**. Prentice Hall, 1999.

HEIJDEN, F. *et al.* **Classification, parameter estimation and state estimation: an engineering approach using MATLAB**, Wiley & Sons, 2004.

HSU, C. W. ; CHANG, C. C. ; LIN, C. J. **A Practical Guide to Support Vector Classification**, 2010. Disponível em www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.

JÚNIOR, V. L. ; SILVA, S. Structural Health Monitoring Algorithms for Smart Structures. In: **Damage Prognosis for Aerospace, Civil and Mechanical System**; Wyle, Inglaterra, 2005, 449 p.

JÚNIOR, V. L. et al. Impedance-Based Structural Health Monitoring with Artificial Neural Networks. **Journal of Intelligent Material Systems and Structures**, 2000, vol. 11 no.3 p. 206-214.

KIM, J. ; GRISSO, B. L. ; HA, D. S. ; INMAN, D. J. A system-on-board approach for impedance-based structural health monitoring. In: **Sensors and smart structures technologies for civil, mechanical and aerospace systems**; San Diego, 2007, v. 6529.

KOO, K-Y. *et al.* Automated Impedance-based Structural Health Monitoring Incorporating Effective Frequency Shift for Compensating Temperature Effects. **Journal of Intelligent Material Systems and Structures**, 2008. Disponível em <http://jim.sagepub.com/content/20/4/367>.

KUNCHEVA, L. I. **Combining Pattern Classifiers: Methods and Algorithms**. Wiley-Interscience, 2004.

LALANDE, F. *et al.* High-Frequency Impedance Analysis for NDE of Complex Precision Parts Monitoring the Integrity of Composite Patch Structural Repair Via Piezoelectric Actuators/Sensors. In: **PROCEEDINGS OF SPIE CONFERENCE ON SMART STRUCTURES AND MATERIALS**. 1996, **SPIE Publishing, Vol. 2717, pp. 237–245**.

LIANG, C. ; SUN F. P. ; ROGERS, C. A. Coupled electromechanical analysis of adaptive material system – determination of actuator power consumption and system energy transfer. **Journal of Intelligent Material Systems and Structures**, 1994, p. 21-20.

MARQUI, C. R. *et al.* External disturbance effect in damage detection using electrical impedance. In: **INTERNATIONAL MODAL ANALYSIS CONFERENCE**, 26., 2008, Orlando. **Anais do International Modal Analysis Conference**, 2008. (Artigo, 286).

MARQUI, C. R.. **Modelagem de Estruturas Piezoelétricas para Aplicação em Localização de**

Falhas. 2007. 237f. Dissertação (Mestrado). Departamento de Engenharia Mecânica, Faculdade de Engenharia de Ilha Solteira, São Paulo, 2007.

MARTINS, L. G. A. et al. Architecture of a Remote Impedance-based Structural Health Monitoring System Used in Aircrafts. **DEStech Publications, Inc.**, 2011, Disponível em www.destechpub.com.

MITRA, S. K. **Digital Signal Processing: A Computer-Based Approach**. The McGraw-Hill Companies, Inc., 1998.

MOURA JR., J. R. V. ; STEFFEN JR., V. Impedance-based health monitoring for aeronautic structures using statistical meta-modeling, **Journal of Intelligent Material Systems and Structures** 2006; 17(11): 1023–1036.

MOURA JR., J. R. V. ; STEFFEN JR., V. ; INMAN, D. J. Strength and damage characterization in an aircraft rib structure. In: **IMAC-XXIV: A Conference & Exposition on Structural Dynamics**, 2006, Saint Louis - MO. IMAC-XXIV – Conference Proceedings (CD). Bethel, CT - USA: Society for Experimental Mechanics.

OPPENHEIM, A. V. ; SCHAFFER, R. W. **Processamento em Tempo Discreto de Sinais**. 3. ed. São Paulo: Pearson Education do Brasil, 2012, 665 p. Tradução: Vieira, D.

OPPENHEIM, A. V. ; WILLSKY, A. S. **Sinais e Sistemas**. 2. ed. São Paulo: Pearson Prentice Hall, 2010, 568 p. Tradução: Vieira, D. ; Bettoni, R.

OVERLY, T. G. ; PARK, G. ; FARRAR, C. R. Development of impedance-based wireless active-sensor node for structural health monitoring. In: **International workshop on structural health monitoring**, Stanford, DEStech Publications, 2007. p. 1660.

PALOMINO, LIZETH V. **Análise das Métricas de Dano Associadas à Técnica de Impedância Eletromecânica para o Monitoramento de Integridade Estrutural**. 2008. 117f. Dissertação (mestrado). Programa de Pós-graduação em Engenharia Mecânica, Universidade Federal de Uberlândia, Minas Gerais, 2008.

PARK, G. *et al.* Electro-Mechanical Impedance-Based Wireless Structural Health Monitoring Using PCA-Data Compression and k-means Clustering Algorithms Monitoring and Path Forward. **Journal of Intelligent Material Systems and Structures**, vol. 19, 2008.

PARK, G. *et al.* **Overview of Piezoelectric Impedance-Based Health Monitoring and Path Forward**. The Shock and Vibration Digest, vol. 35 N° 6, 2003, p. 451-463.

PARK, G. ; INMAN, D. J. Impadance-Based Structural Health Monitoring. In: **Damage Prognosis for Aerospace, Civil and Mechanical System**; Wyle, Inglaterra, 2005, 449 p.

PARK, G. ; CUDNEY, H. ; INMAN, D. J. Impedance-based health monitoring of civil structural components. **ASCE Journal of Infrastructure Systems**. 2000; 6, 153-160.

PARK, S. et al. MFC-Based Structural Health Monitoring Using a Miniaturized impedance Measuring Chip for Corrosion Detection. **American Society for Nondestructive Testing**. Pesquisa em Nondestructive Evaluation, 18: 139-150, 2007.

PAWAR, P. M. ; REDDY, K. V. ; GANGULI, R. Damage Detection in Beams using Spatial Fourier Analysis and Neural Networks. **Journal of Intelligent Material Systems and Structures**. 2007. Disponível em <http://jim.sagepub.com/content/18/4/347>.

PEAIRS, D. ; PARK, G. ; INMAN, D. J. Improving Accessibility of the Impedancebased Structural Health Monitoring Method. **Journal of Intelligent Material Systems and Structures**, 2004, vol.15, 129-139.

POLIKAR, ROBI. **Pattern Recognition**. Wiley Encyclopedia of Biomedical Engineering. Glassboro, New Jersey, 2006.

SILVA, SAMUEL ; JÚNIOR, MILTON ; LOPES JUNIOR, VICENTE. Structural Health Monitoring in Smart Structures Through Time Series Analysis, **Journal of Structural Health Monitoring**, 2008, vol. 7 231-244.

SOH, C. K. *et al.* Performance of smart piezoceramic patches in health monitoring of a RC Bridge. **Smart Materials and Structures**. 2000; 9, 533-542.

SUN, F. *et al.* Truss structure integrity identification using PZT sensor-actuator, **Journal of Intelligent Material Systems and Structures** 1995; 6: 134–139.

TAN, P. N. ; STEINBACH, M. ; KUMAR, V. **Introduction to Data Mining**. University of Minnesota Publisher, Addison-Wesley Copyright, 2006.

TEBALDI, A. **Detecção de Falhas Estruturais Usando Sensores e Atuadores Piezoelétricos e Algoritmos Genéticos**, Dissertação de mestrado; Universidade Estadual Paulista, Ilha Solteira, Brasil, 2003, 105 f.

VAPNIK, V. N. **The Nature of Statistical Learning Theory**. 2nd ed. New York: Springer, 2000.

WITTEN, I. H. ; FRANK, E. **Data Mining: Practical Machine Learning Tools and Techniques**, Morgan Kaufmann; second edition, 2005.

XU, B. ; GIURGIUTIU, V. A low-cost and field portable electromechanical (E/M) impedance analyzer for active structural health monitoring. In: **Proceedings of 5th International Workshop on Structural Health Monitoring**, Stanford University, Stanford, CA, 15–17 September 2005.

YANG, Y. ; SOH, CK. Practical issues related to the application of the electromechanical impedance technique in the structural health monitoring of civil structures: I. Experiment. **Smart Mater Struct** 2008; 17035008 (14pp).