

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL - UFRGS

Escola de Engenharia

Programa de Pós-Graduação em Engenharia de Minas, Metalúrgica e de Materiais - PPGE3M

EVANDRO BERTOLDI

**MÉTODO DE DETECÇÃO E
QUANTIFICAÇÃO DE DANO POR
CORROSÃO EM TANQUES DE FPSO
COM DADOS COLETADOS DE UM
SISTEMA DE SHM BASEADO EM
ONDAS GUIADAS**

Porto Alegre
2022

EVANDRO BERTOLDI

**MÉTODO DE DETECÇÃO E
QUANTIFICAÇÃO DE DANO POR
CORROSÃO EM TANQUES DE FPSO
COM DADOS COLETADOS DE UM
SISTEMA DE SHM BASEADO EM
ONDAS GUIADAS**

Tese de doutorado apresentada ao Programa de Pós-Graduação em Engenharia de Minas, Metalúrgica e de Materiais - PPGE3M da Universidade Federal do Rio Grande do Sul - UFRGS como parte dos requisitos para a obtenção do título de Doutor em Engenharia.

Área de concentração: Ciência e Tecnologia dos Materiais

ORIENTADOR: Prof. Dr. Thomas Gabriel Rosauro Clarke

Porto Alegre
2022

EVANDRO BERTOLDI

**MÉTODO DE DETECÇÃO E
QUANTIFICAÇÃO DE DANO POR
CORROSÃO EM TANQUES DE FPSO
COM DADOS COLETADOS DE UM
SISTEMA DE SHM BASEADO EM
ONDAS GUIADAS**

Esta tese foi analisada e julgada adequada para a obtenção do título de Doutor em Engenharia, área de concentração em Ciência e Tecnologia dos Materiais, e aprovada em sua forma final pelo Orientador e pela Banca Examinadora designada pelo Programa de Pós-Graduação em Engenharia de Minas, Metalúrgica e de Materiais da Universidade Federal do Rio Grande do Sul.

Orientador: _____
Prof. Dr. Thomas Gabriel Rosauo Clarke, UFRGS
Professor do Programa de Pós-Graduação em Engenharia de Minas, Metalúrgica e de Materiais - PPGE3M

Banca Examinadora:

Dr. Eng. Lúcio de Abreu Corrêa,
Fundação de Apoio da Universidade Federal do Rio Grande do Sul - FAURGS, Porto Alegre, Brasil

Dr. Eng. Ricardo Baiotto,
Centre Technologique en Aérospatiale - CTA, Longueuil, Québec, Canadá

Dr. Marlon de Matos de Oliveira,
Departamento de Metalurgia da Escola de Engenharia da Universidade Federal do Rio Grande do Sul - DEMET, Porto Alegre, Brasil

Coordenador do PPGE3M: _____
Prof. Dr. Afonso Reguly

Porto Alegre, dezembro de 2022.

DEDICATÓRIA

À minha família, em especial aos meus pais Adilson José Bertoldi e Zeli Rosalia Bertoldi, meu irmão Everton Bertoldi e à minha noiva Nara Liege Barbieri, pela compreensão dos momentos ausentes e pelo apoio e incentivo constante ao longo desta caminhada, dedico-lhes esta conquista como gratidão.

AGRADECIMENTOS

A Deus, pela vida e por me fortalecer nos momentos difíceis, não me deixando desistir dos meus objetivos.

A toda a minha família, noiva e amigos, pelo apoio e incentivo nos momentos de dificuldades ao longo desta trajetória.

Ao meu orientador, Prof. Dr. Thomas Gabriel Rosauo Clarke, pela oportunidade e confiança depositada, e fundamental participação para a realização deste trabalho.

Ao LAMEF e a PETROBRAS, pela disponibilização de todos os recursos necessários para o desenvolvimento deste projeto de pesquisa e apoio financeiro.

A UFRGS pelo ensino gratuito e de qualidade, e aos professores, pelo suporte técnico e teórico que sempre colocaram a minha disposição para o aprendizado.

Aos colegas e amigos do GEND e demais grupos do LAMEF, pelo companheirismo e por toda a ajuda prestada durante o desenvolvimento deste trabalho, em especial ao Dr. Eng. Lúcio de Abreu Corrêa, Dr. Marlon de Matos de Oliveira e Dr. Eng. Paulo Dambros Menin.

Enfim, a todos que de alguma forma participaram e tornaram possível a concretização deste trabalho.

RESUMO

Neste trabalho foi proposto um método de processamento de dados providos de um sistema de Monitoramento de Saúde Estrutural (SHM) baseado em ondas guiadas visando à detecção e quantificação de danos por corrosão em tanques de armazenamento em unidades Flutuantes de Produção, Armazenamento e Transferência (FPSO). Para isso, foram utilizados dados de um painel simulando um trecho da estrutura de um tanque de FPSO, que foi instrumentado com um conjunto de sensores operados com eletrônica e software desenvolvidos em um trabalho prévio. Primeiramente foram obtidos sinais a partir da estrutura na condição íntegra para criar um banco de dados de sinais base (*baselines*). Posteriormente, foram introduzidos diferentes níveis de dano no painel, e novas coletas de dados foram realizadas para cada nível de dano. O método proposto consiste em realizar uma redução de dimensão nos dados do teste de ondas guiadas usando Análise de Componentes Independentes (ICA). A partir dos dados reduzidos, é utilizado uma abordagem baseada na detecção de *outliers* para identificar a componente referente ao dano de forma automática. Para isso, primeiramente é montado um conjunto de dados a partir do banco de dados de *baseline*, onde os dados são selecionados de forma aleatória e sem reposição, formando o primeiro conjunto de dados. Em seguida é montado o segundo conjunto de dados, o qual é formado pelo primeiro conjunto e um sinal adicionado (sinal de *baseline* ou dano) em uma posição aleatória entre os demais sinais de *baseline*. Após a redução dimensional dos dados, foram utilizados os vetores de pesos do ICA para identificar se um determinado sinal tem origem de uma condição intacta ou danificada por meio de um procedimento envolvendo correlação cruzada. Nesse procedimento, as componentes dos dois conjuntos de dados são relacionadas entre si através do valor máximo da correlação cruzada. Assim, a componente relacionada ao dano do segundo conjunto tenderá a não estar vinculada, pois deverá ter menos similaridade com as componentes do primeiro conjunto. Por último, foi repetido este processo várias vezes para calcular a acurácia e os erros da detecção de danos e para calcular a relação sinal-ruído (SNR) das componentes *outliers* para quantificar o dano. Foram obtidas taxas médias de acurácia acima de 80% para detecção de danos, com taxas médias de erro Tipo I abaixo de 20% e taxas médias de erro Tipo II abaixo de 40%. Além disso, foi possível estimar a severidade dos danos, principalmente, em seus estágios iniciais de profundidade.

Palavras-chave: Orientado a Dados, SHM, Estruturas Complexas, Ondas Guiadas.

ABSTRACT

In this study, it was proposed a method for processing data from a guided wave-based Structural Health Monitoring (SHM) aiming to detect and quantify corrosion damage on storage tanks Floating Production, Storage and Offloading (FPSO) units. For this, data from a panel simulating a section of an FPSO tank structure were used, which were instrumented with a set of sensors operated with electronics and software developed in a previous study. First, signals were obtained from the intact structure to create a baseline signal database. Subsequently, different damage levels were introduced into the panel and new data collection was performed for each damage level. The proposed method consists in performing a dimension reduction on guided wave test data using Independent Component Analysis (ICA). From the reduced data, an approach based on outlier detection is used to automatically identify the damage component. For this purpose, a data set is first assembled from the baseline database, where the data is selected randomly and without replacement, forming the first data set. Then the second data set is assembled, which is made of the first set and one added signal (baseline signal or damage) at a random position among the other baseline signals. After the dimensional reduction of the data, ICA weight vectors were used to identify if a specific signal originated from an intact or damaged condition through a procedure involving cross-correlation. In this procedure, the components of the two data sets are related to each other through the maximum cross-correlation value. So, the damage-related components of the second set will tend to be unrelated, because it should have less similarity to the components of the first set. Finally, this process was repeated several times to calculate the accuracy and errors of the damage detection and to calculate the signal-to-noise ratio (SNR) of the outlier components to quantify the damage. Average accuracy above 80% was obtained for damage detection, with average Type I error rates below 20% and Type II error rates below 40%. Additionally, it was possible to estimate damage severity, especially in its early stages of depths.

Keywords: Data Driven, SHM, Complex Structures, Guided Waves.

LISTA DE FIGURAS

1	FPSO na cidade de Paraty operando no campo de Tupi no nordeste da Bacia de Santos.	25
2	Imagem comparativa de diferentes tipos de plataformas.	31
3	Representação de um navio FPSO e sistema submarino.	32
4	Estrutura típica de tanque de carga e lastro.	33
5	Imagem de uma estrutura típica de um tanque de carga de um navio petroleiro sendo inspecionado por um inspetor utilizando meios de acesso. . . .	36
6	Tecnologia RAS para drones.	37
7	Tecnologia RAS para robôs.	37
8	Desenho esquemático de um arranjo de transdutores de ondas guiadas. . . .	39
9	Reflexão de uma onda transversal em uma superfície livre.	41
10	Formato dos modos de propagação.	42
11	Curvas de dispersão para uma chapa de aço carbono com 20 mm de espessura.	43
12	Diagrama do campo de abrangência da inteligência artificial.	46
13	Representação em duas dimensões da esparsidade dos dados.	48
14	Representação em três dimensões da esparsidade dos dados.	49
15	<i>Cocktails party</i> e o ICA.	51
16	Processo de mistura e separação através do ICA.	53
17	Distribuição de probabilidade gaussiana.	54
18	Função densidade de probabilidade conjunta de x_1 e x_2	58
19	Função densidade de probabilidade conjunta das variáveis branqueadas. . .	58
20	Configuração experimental do painel.	66
21	Desenho esquemático do perfil bulbo tipo HP 400x12 com a especificação das dimensões em mm.	66
22	Configuração e instalação do transdutor.	67
23	Projeto e fabricação do invólucro do transdutor.	68
24	Configuração experimental dos transdutores.	69
25	Instalação dos transdutores piezoelétricos e sensor de temperatura no painel.	70

26	Fluxograma do processo de aquisição de dados da estrutura íntegra e danificada.	71
27	Equipamentos utilizados para aquisição dos sinais experimentais no painel.	72
28	Configuração experimental dos danos.	73
29	Defeitos introduzidos no painel.	74
30	Fluxograma do processo de aplicação do algoritmo orientado a dados para detecção e quantificação de danos.	76
31	Distância e temperatura medida <i>versus</i> sinais de <i>baseline</i>	78
32	Componentes dos pesos do par de sensores e1r2.	79
33	Correlação cruzada entre a componente do primeiro conjunto de componentes com a componente do segundo conjunto de componentes.	80
34	Influência do número de realizações aleatórias na acurácia e erros tipo I e II no par de sensores e2r3 para o caso 3, frequência central de 45 kHz, 25 componentes independentes e 100 sinais aleatórios de <i>baseline</i>	82
35	Influência do número de componentes do ICA e do número de sinais aleatórios de <i>baseline</i> para o par de sensores e2r3, dano I e frequência central de 45 kHz.	84
36	Influência do número de componentes do ICA e do número de sinais aleatórios de <i>baseline</i> para o par de sensores e2r3, dano II e frequência central de 45 kHz.	85
37	Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs <i>versus</i> danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 50 sinais aleatórios de <i>baseline</i> e 15 componentes independentes.	88
38	Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs <i>versus</i> danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 100 sinais aleatórios de <i>baseline</i> e 20 componentes independentes.	89
39	Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs <i>versus</i> danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 150 sinais aleatórios de <i>baseline</i> e 25 componentes independentes.	90
40	Influência do número de realizações aleatórias nos SNRs da estrutura não danificada e danificada em todos os estágios de profundidade para o par de sensores e2r3 para os casos 1, 2 e 3 com 200 amostras, dano I, frequência central de 45 kHz, 150 sinais aleatórios de <i>baseline</i> e 25 componentes independentes.	91

41	Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II nos pares de sensores e1r2, e1r3, e1r4, e1r5, e1r6, e1r7, e1r8, e1r9 e e1r10 para o caso 3, dano I, frequência central de 45 kHz e 70 sinais aleatórios de <i>baseline</i>	96
42	Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II nos pares de sensores e3r1, e3r2, e3r4, e3r5, e3r6, e3r7, e3r8, e3r9 e e3r10 para o caso 3, dano I, frequência central de 45 kHz e 150 sinais aleatórios de <i>baseline</i>	97
43	Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II em todas as combinações de pares de sensores para o caso 3, dano I e frequência central de 45 kHz.	99
44	Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II nos pares de sensores e1r2, e1r3, e1r4, e1r5, e1r6, e1r7, e1r8, e1r9 e e1r10 para o caso 3, dano II, frequência central de 45 kHz e 70 sinais aleatórios de <i>baseline</i>	101
45	Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II nos pares de sensores e3r1, e3r2, e3r4, e3r5, e3r6, e3r7, e3r8, e3r9 e e3r10 para o caso 3, dano II, frequência central de 45 kHz e 150 sinais aleatórios de <i>baseline</i>	102
46	Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II em todas as combinações de pares de sensores para o caso 3, dano II e frequência central de 45 kHz.	103
47	SNRs <i>versus</i> danos nos pares de sensores e2r3 e e2r5 para o caso 3 com 200 amostras, dano I e frequência central de 45 kHz.	105
48	SNRs <i>versus</i> danos nos pares de sensores e3r1 e e3r2 para o caso 3 com 200 amostras, dano I e frequência central de 45 kHz.	106
49	SNRs <i>versus</i> danos nos pares de sensores e3r5 e e3r6 para o caso 3 com 200 amostras, dano I e frequência central de 45 kHz.	106
50	SNRs <i>versus</i> danos nos pares de sensores e4r3 e e4r6 para o caso 3 com 200 amostras, dano I e frequência central de 45 kHz.	107
51	SNRs <i>versus</i> danos nos pares de sensores e5r2 e e5r3 para o caso 3 com 200 amostras, dano I e frequência central de 45 kHz.	107
52	SNRs <i>versus</i> danos nos pares de sensores e6r3 e e6r7 para o caso 3 com 200 amostras, dano I e frequência central de 45 kHz.	108
53	SNRs <i>versus</i> danos nos pares de sensores e1r6 e e1r10 para o caso 3 com 200 amostras, dano II e frequência central de 45 kHz.	110
54	SNRs <i>versus</i> danos nos pares de sensores e2r8 e e4r8 para o caso 3 com 200 amostras, dano II e frequência central de 45 kHz.	110

55	SNRs <i>versus</i> danos nos pares de sensores e6r4 e e7r1 para o caso 3 com 200 amostras, dano II e frequência central de 45 kHz.	111
56	SNRs <i>versus</i> danos nos pares de sensores e7r5 e e9r2 para o caso 3 com 200 amostras, dano II e frequência central de 45 kHz.	111
57	SNRs <i>versus</i> danos nos pares de sensores e9r3 e e9r4 para o caso 3 com 200 amostras, dano II e frequência central de 45 kHz.	112
58	SNRs <i>versus</i> danos nos pares de sensores e9r6 e e10r6 para o caso 3 com 200 amostras, dano II e frequência central de 45 kHz.	112
59	Influência do número de componentes do ICA e do número de sinais aleatórios de <i>baseline</i> para o par de sensores e2r3, dano I e frequência central de 30 kHz.	130
60	Influência do número de componentes do ICA e do número de sinais aleatórios de <i>baseline</i> para o par de sensores e2r3, dano I e frequência central de 35 kHz.	130
61	Influência do número de componentes do ICA e do número de sinais aleatórios de <i>baseline</i> para o par de sensores e2r3, dano I e frequência central de 40 kHz.	131
62	Influência do número de componentes do ICA e do número de sinais aleatórios de <i>baseline</i> para o par de sensores e2r3, dano I e frequência central de 50 kHz.	131
63	Influência do número de componentes do ICA e do número de sinais aleatórios de <i>baseline</i> para o par de sensores e2r3, dano I e frequência central de 55 kHz.	132
64	Influência do número de componentes do ICA e do número de sinais aleatórios de <i>baseline</i> para o par de sensores e2r3, dano I e frequência central de 60 kHz.	132
65	Influência do número de componentes do ICA e do número de sinais aleatórios de <i>baseline</i> para o par de sensores e2r3, dano I e frequência central de 65 kHz.	133
66	Influência do número de componentes do ICA e do número de sinais aleatórios de <i>baseline</i> para o par de sensores e2r3, dano I e frequência central de 70 kHz.	133
67	Influência do número de componentes do ICA e do número de sinais aleatórios de <i>baseline</i> para o par de sensores e2r3, dano I e frequência central de 75 kHz.	134
68	Influência do número de componentes do ICA e do número de sinais aleatórios de <i>baseline</i> para o par de sensores e2r3, dano I e frequência central de 80 kHz.	134

69	Influência do número de componentes do ICA e do número de sinais aleatórios de <i>baseline</i> para o par de sensores e2r3, dano II e frequência central de 30 kHz.	135
70	Influência do número de componentes do ICA e do número de sinais aleatórios de <i>baseline</i> para o par de sensores e2r3, dano II e frequência central de 35 kHz.	135
71	Influência do número de componentes do ICA e do número de sinais aleatórios de <i>baseline</i> para o par de sensores e2r3, dano II e frequência central de 40 kHz.	136
72	Influência do número de componentes do ICA e do número de sinais aleatórios de <i>baseline</i> para o par de sensores e2r3, dano II e frequência central de 50 kHz.	136
73	Influência do número de componentes do ICA e do número de sinais aleatórios de <i>baseline</i> para o par de sensores e2r3, dano II e frequência central de 55 kHz.	137
74	Influência do número de componentes do ICA e do número de sinais aleatórios de <i>baseline</i> para o par de sensores e2r3, dano II e frequência central de 60 kHz.	137
75	Influência do número de componentes do ICA e do número de sinais aleatórios de <i>baseline</i> para o par de sensores e2r3, dano II e frequência central de 65 kHz.	138
76	Influência do número de componentes do ICA e do número de sinais aleatórios de <i>baseline</i> para o par de sensores e2r3, dano II e frequência central de 70 kHz.	138
77	Influência do número de componentes do ICA e do número de sinais aleatórios de <i>baseline</i> para o par de sensores e2r3, dano II e frequência central de 75 kHz.	139
78	Influência do número de componentes do ICA e do número de sinais aleatórios de <i>baseline</i> para o par de sensores e2r3, dano II e frequência central de 80 kHz.	139
79	Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs <i>versus</i> danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 50 sinais aleatórios de <i>baseline</i> e 5 componentes independentes.	141
80	Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs <i>versus</i> danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 50 sinais aleatórios de <i>baseline</i> e 10 componentes independentes.	142

81	Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs <i>versus</i> danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 50 sinais aleatórios de <i>baseline</i> e 20 componentes independentes.	143
82	Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs <i>versus</i> danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 50 sinais aleatórios de <i>baseline</i> e 25 componentes independentes.	144
83	Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs <i>versus</i> danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 50 sinais aleatórios de <i>baseline</i> e 30 componentes independentes.	145
84	Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs <i>versus</i> danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 50 sinais aleatórios de <i>baseline</i> e 35 componentes independentes.	146
85	Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs <i>versus</i> danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 100 sinais aleatórios de <i>baseline</i> e 5 componentes independentes.	147
86	Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs <i>versus</i> danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 100 sinais aleatórios de <i>baseline</i> e 10 componentes independentes.	148
87	Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs <i>versus</i> danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 100 sinais aleatórios de <i>baseline</i> e 15 componentes independentes.	149
88	Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs <i>versus</i> danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 100 sinais aleatórios de <i>baseline</i> e 25 componentes independentes.	150
89	Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs <i>versus</i> danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 100 sinais aleatórios de <i>baseline</i> e 30 componentes independentes.	151

90	Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs <i>versus</i> danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 100 sinais aleatórios de <i>baseline</i> e 35 componentes independentes.	152
91	Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs <i>versus</i> danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 150 sinais aleatórios de <i>baseline</i> e 5 componentes independentes.	153
92	Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs <i>versus</i> danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 150 sinais aleatórios de <i>baseline</i> e 10 componentes independentes.	154
93	Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs <i>versus</i> danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 150 sinais aleatórios de <i>baseline</i> e 15 componentes independentes.	155
94	Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs <i>versus</i> danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 150 sinais aleatórios de <i>baseline</i> e 20 componentes independentes.	156
95	Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs <i>versus</i> danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 150 sinais aleatórios de <i>baseline</i> e 30 componentes independentes.	157
96	Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs <i>versus</i> danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 150 sinais aleatórios de <i>baseline</i> e 35 componentes independentes.	158

LISTA DE TABELAS

1	Número de ciclos do sinal <i>toneburst</i> para cada frequência de emissão.	72
2	Dimensões do dano I para cada etapa de profundidade.	74
3	Dimensões do dano II para cada etapa de profundidade.	74
4	Tipo de erros.	77
5	Valores obtidos na regressão usando a função sigmóide nos <i>outliers</i> do par de sensores e2r3 para o caso 3 com 200 realizações aleatórias, dano I, frequência central de 45 kHz, 50 sinais aleatórios de <i>baseline</i> e 15 componentes independentes.	88
6	Valores obtidos na regressão usando a função sigmóide nos <i>outliers</i> do par de sensores e2r3 para o caso 3 com 200 realizações aleatórias, dano I, frequência central de 45 kHz, 100 sinais aleatórios de <i>baseline</i> e 20 componentes independentes.	89
7	Valores obtidos na regressão usando a função sigmóide nos <i>outliers</i> do par de sensores e2r3 para o caso 3 com 200 realizações aleatórias, dano I, frequência central de 45 kHz, 150 sinais aleatórios de <i>baseline</i> e 25 componentes independentes.	90
8	Valores obtidos na regressão usando a função sigmóide nos <i>outliers</i> do par de sensores e2r3 para o caso 1 com 200 realizações aleatórias, dano I, frequência central de 45 kHz, 150 sinais aleatórios de <i>baseline</i> e 25 componentes independentes.	92
9	Valores obtidos na regressão usando a função sigmóide nos <i>outliers</i> do par de sensores e2r3 para o caso 2 com 200 realizações aleatórias, dano I, frequência central de 45 kHz, 150 sinais aleatórios de <i>baseline</i> e 25 componentes independentes.	92
10	Valores obtidos na regressão usando a função sigmóide nos <i>outliers</i> do par de sensores e2r3 para o caso 3 com 200 realizações aleatórias, dano I, frequência central de 45 kHz, 150 sinais aleatórios de <i>baseline</i> e 25 componentes independentes.	92
11	Número de componentes selecionados em cada par de sensores para o dano I.	93

12	Número de componentes selecionados em cada par de sensores para o dano I.	93
13	Número de componentes selecionados em cada par de sensores para o dano II.	94
14	Número de componentes selecionados em cada par de sensores para o dano II.	94
15	Valores obtidos na regressão usando a função sigmóide nos <i>outliers</i> para o caso 3 com 200 realizações aleatórias, dano I e frequência central de 45 kHz.	105
16	Valores obtidos na regressão usando a função sigmóide nos <i>outliers</i> para o caso 3 com 200 realizações aleatórias, dano I e frequência central de 45 kHz.	105
17	Valores obtidos na regressão usando a função sigmóide nos <i>outliers</i> para o caso 3 com 200 realizações aleatórias, dano II e frequência central de 45 kHz.	109
18	Valores obtidos na regressão usando a função sigmóide nos <i>outliers</i> para o caso 3 com 200 realizações aleatórias, dano II e frequência central de 45 kHz.	109
19	Valores obtidos na regressão usando a função sigmóide nos <i>outliers</i> do par de sensores e^{2r3} para o caso 3 com 200 realizações aleatórias, dano I, frequência central de 45 kHz, 50 sinais aleatórios de <i>baseline</i> e 5, 10, 20, 25, 30 e 35 componentes independentes.	141
20	Valores obtidos na regressão usando a função sigmóide nos <i>outliers</i> do par de sensores e^{2r3} para o caso 3 com 200 realizações aleatórias, dano I, frequência central de 45 kHz, 100 sinais aleatórios de <i>baseline</i> e 5, 10, 15, 25, 30 e 35 componentes independentes.	147
21	Valores obtidos na regressão usando a função sigmóide nos <i>outliers</i> do par de sensores e^{2r3} para o caso 3 com 200 realizações aleatórias, dano I, frequência central de 45 kHz, 150 sinais aleatórios de <i>baseline</i> e 5, 10, 15, 20, 30 e 35 componentes independentes.	153

LISTA DE ABREVIATURAS

SHM	<i>Structural Health Monitoring</i> (Monitoramento de Saúde Estrutural)
FPSO	<i>Floating, Production, Storage and Offloading unit</i> (unidade Flutuante de Produção, Armazenamento e Transferência)
ICA	<i>Independent Component Analysis</i> (Análise de Componentes Independentes)
NDT	<i>Non-Destructive Testing</i> (Ensaio Não-Destrutivo)
IA	Inteligência Artificial (<i>Artificial Intelligence</i>)
PCA	<i>Principal Component Analysis</i>
LDA	<i>Linear Discriminant Analysis</i>
SVD	<i>Singular Value Decomposition</i>
LLE	<i>Locally Linear Embedding</i>
t-SNE	<i>t-Distributed Stochastic Neighbor Embedding</i>
ML	<i>Machine Learning</i> (Aprendizado de Máquina)
IACS	<i>International Association of Classification Societies</i>
RAS	<i>Robotics and Autonomous Systems</i>
GPS	<i>Global Positioning System</i> (Sistema Global de Posicionamento)
SH	Modo <i>Shear Horizontal</i>
S	Modo Simétrico
A	Modo Antissimétrico
SH ₀	Modo <i>Shear Horizontal 0</i>
S ₀	Modo Simétrico 0
A ₀	Modo Antissimétrico 0
PZT	<i>Lead zirconate and titanate</i> (Zirconato-titanato de chumbo)

ASTM	<i>American Society for Testing and Materials</i>
PCB	<i>Printed Circuit Board</i> (Placa de Circuito Impresso)
DL	<i>Deep Learning</i> (Aprendizado Profundo)
SVM	<i>Support Vector Machine</i>
ESD	<i>Ensemble Subspace Discriminant</i>
kNN	<i>k-Nearest Neighbors</i>
LSVM	<i>Linear Support Vector Machine</i>
DT	<i>Decision Trees</i>
NB	<i>Naive Bayes</i>
SVC	<i>Support Vector Classification</i>
LVQ	<i>Linear Vector Quantization</i>
MLP	<i>Multilayer Perceptron</i>
LSTM	<i>Long Short-Term Memory</i>
BSS	<i>Blind Source Separation</i> (Separação Cega de Fontes)
SNR	<i>Signal-to-Noise Ratio</i> (Relação Sinal-Ruído)
NBR	Borracha Nitrílica
BNC	<i>Bayonet Neil Concelman</i>

LISTA DE SÍMBOLOS

c_1	Celeridade das ondas primárias
c_2	Celeridade das ondas secundárias
λ_L	Primeira constante de Lamé
μ_L	Segunda constante de Lamé
ρ	Massa específica
θ_i	Ângulo de incidência
θ_{rt}	Ângulo de reflexão da onda transversal
θ_{rl}	Ângulo de reflexão da onda longitudinal
e	Espessura da placa
K	Número de onda na direção de propagação da onda guiada
K_{ts}	Componente do número de onda relativo à onda transversal
K_{tl}	Componente do número de onda relativo à onda longitudinal
ω	Frequência angular
N	Número da ordem do modo de propagação da onda guiada
c_p	Velocidade de fase do modo de propagação
c_g	Velocidade de grupo do modo de propagação
n	Número de variáveis aleatórias
x_1	Primeira variável aleatória da mistura de sinais
x_n	n -ésima variável aleatória da mistura de sinais
x_i	i -ésima mistura
s_1	Primeiro sinal original
s_n	n -ésimo sinal original

a_{i1}	Coeficiente da i -ésima mistura referente à variável s_1
a_{i2}	Coeficiente da i -ésima mistura referente à variável s_2
s_2	Segundo sinal original
a_{in}	Coeficientes da i -ésima mistura referente à n -ésima variável
i	Número de misturas
j	Número de sinais originais
a_{ij}	Coeficientes da i -ésima mistura referente à j -ésima variável
s_j	j -ésimo sinal original
x	Vetor de misturas
A	Matriz de mistura
s	Vetor de sinais originais
a_{11}	Coeficiente da matriz de mistura da posição $i = 1$ e $j = 1$
a_{12}	Coeficiente da matriz de mistura da posição $i = 1$ e $j = 2$
x_2	Segunda variável aleatória da mistura de sinais
a_{21}	Coeficiente da matriz de mistura da posição $i = 2$ e $j = 1$
a_{22}	Coeficiente da matriz de mistura da posição $i = 2$ e $j = 2$
s_i	i -ésimo sinal original
W	Matriz de separação
w_i	Vetor linha da matriz de separação W
W^*	Aproximação da matriz de separação W
y	Vetor de componentes independentes
$\ \cdot\ $	Norma de um vetor
$p(y_1, y_2)$	Função densidade de probabilidade conjunta das variáveis aleatórias y_1 e y_2
$p_i(y_i)$	Função densidade de probabilidade marginal de y_i
$E[\cdot]$	Valor esperado de uma variável aleatória
h_1	Primeira função
h_2	Segunda função
α	Valor escalar
a_i	Vetor coluna da matriz de mistura A

P	Matriz de permutação
P^{-1}	Inversa da matriz de permutação P
x_c	Vetor de misturas centralizadas
A^{-1}	Inversa da matriz de mistura A
cov	Função de covariância
y_1	Variável aleatória
y_2	Variável aleatória
C_r	Matriz de covariância do vetor r
r	Vetor de variáveis aleatórias
r^t	Transposto do vetor de variáveis aleatórias r
I	Matriz identidade
X	Variável aleatória
z	Vetor de variáveis aleatórias brancas
V	Matriz de branqueamento
C_x	Matriz de covariância do vetor de misturas x
x^t	Transposto do vetor de misturas x
M	Matriz ortogonal dos auto-vetores associados aos auto-valores da matriz de covariância C_x
D	Matriz diagonal dos auto-valores da matriz de covariância C_x
A'	Matriz de mistura ortogonal
A'^{-1}	Inversa da matriz de mistura ortogonal A'
exp	Função exponencial
π	Pi
k	Número de misturas e de componentes independentes
b	Vetor linha
q	Vetor resultante do produto bA
q_i	i -ésimo termo do vetor q
$kurt$	Função curtose
H	Função entropia

Y	Variável aleatória
$\int[\cdot]$	Integral
$p_Y(\eta)$	Função densidade de probabilidade da variável aleatória Y
\log	Função logarítmica
J	Função negentropia
Y_{gauss}	Variável aleatória gaussiana com a mesma matriz de correlação (covariância) que a variável Y
G_1	Função não-quadrática
G_2	Função não-quadrática
k_1	Constante positiva
k_2	Constante positiva
v	Variável aleatória gaussiana com média zero e variância unitária
a_1	Constante, tal que $1 \leq a_1 \leq 2$
\cosh	Função cosseno hiperbólico
w	Vetor de coeficientes de separação
w^*	Estimativa do vetor w pelo algoritmo FastICA
g	Função não-quadrática
w^t	Transposto do vetor de coeficientes de separação w
g'	Derivada da função não-quadrática g
g_1	Função não-quadrática
\tanh	Função tangente hiperbólica
g_2	Função não-quadrática
g_3	Função não-quadrática
g'_1	Derivada da função não-quadrática g_1
g'_2	Derivada da função não-quadrática g_2
g'_3	Derivada da função não-quadrática g_3
A'^t	Transposta da matriz de mistura ortogonal A'
A_{ecd}	Taxa de acurácia da estrutura com dano
N_{ra}	Número de realizações aleatórias

$N_{n\ddot{d}d}$	Número de vezes que não detectou a presença de dano existente
E_I	Taxa de erro do tipo I
A_{esd}	Taxa de acurácia da estrutura sem dano
$N_{\ddot{d}d}$	Número de vezes que detectou a presença de dano que não existe
E_{II}	Taxa de erro do tipo II
SNR	Relação sinal-ruído
v_{max}	Valor máximo do vetor da componente
v_{med}	Valor médio do vetor da componente
p_d	Profundidade do dano em % de perda de espessura
k_{cs1}	Primeira constante para ajuste da curva sigmoidal
k_{cs2}	Segunda constante para ajuste da curva sigmoidal
k_{cs3}	Terceira constante para ajuste da curva sigmoidal
k_{cs4}	Quarta constante para ajuste da curva sigmoidal
k_{cs5}	Quinta constante para ajuste da curva sigmoidal

SUMÁRIO

1	INTRODUÇÃO	25
2	OBJETIVOS	29
3	REVISÃO BIBLIOGRÁFICA	30
3.1	Unidade Flutuante de Produção, Armazenamento e Transferência	30
3.1.1	Sistema FPSO de Exploração de Petróleo	30
3.1.2	Tanques de Armazenamento de FPSOs	32
3.1.3	Mecanismos e Modos de Falha em FPSOs	33
	3.1.3.1 Mecanismos e Modos de Falha	34
	3.1.3.2 Processos Corrosivos	34
3.1.4	Inspeção e Monitoramento de Tanques de Armazenamento de FPSOs	35
3.2	Monitoramento de Integridade Estrutural	38
3.3	Fundamentos das Ondas Guiadas	40
3.4	Transdutores Piezoelétricos	44
3.5	Inteligência Artificial	45
3.5.1	Conceitos de Inteligência Artificial	45
3.5.2	Redução de Dimensionalidade	48
3.6	Análise de Componentes Independentes	50
3.6.1	Definição do ICA	51
3.6.2	Restrições do ICA	53
3.6.3	Ambiguidades do ICA	54
3.6.4	Pré-Processamento para ICA	55
	3.6.4.1 Centralização	55
	3.6.4.2 Branqueamento	56
3.6.5	Não-Gaussianidade e Independência	59
3.6.6	Medidas de Não-Gaussianidade	60
	3.6.6.1 Curtose	60
	3.6.6.2 Negentropia	61

3.6.7	Algoritmo FastICA	62
4	MATERIAIS E MÉTODOS	65
4.1	Ensaio Experimental	65
4.1.1	Projeto e Construção do Painel de Testes e Transdutores Piezoelétricos	65
4.1.2	Instalação do Arranjo de Transdutores Piezoelétricos	68
4.1.3	Aquisição dos Sinais Experimentais	70
4.1.4	Inserção dos Danos no Painel	73
4.2	Metodologia para Detecção e Quantificação de Danos	75
5	RESULTADOS E DISCUSSÕES	83
5.1	Influência do Número de Componentes do ICA, do Número de Sinais Aleatórios de <i>Baseline</i> e da Frequência de Operação na Detecção e Quantificação dos Danos	83
5.2	Resultados da Detecção dos Danos	94
5.2.1	Dano I	94
5.2.2	Dano II	99
5.3	Resultados da Quantificação dos Danos	104
5.3.1	Dano I	104
5.3.2	Dano II	108
6	CONCLUSÕES	114
7	SUGESTÕES PARA TRABALHOS FUTUROS	116
	REFERÊNCIAS	117
	APÊNDICE A INFLUÊNCIA DO NÚMERO DE COMPONENTES DO ICA, DO NÚMERO DE SINAIS ALEATÓRIOS DE <i>BASELINE</i> E DA FREQUÊNCIA DE OPERAÇÃO NOS VALORES DE AMPLITUDES DE PICO	129
A.1	Dano I	130
A.2	Dano II	135
	APÊNDICE B INFLUÊNCIA DO NÚMERO DE COMPONENTES DO ICA E DO NÚMERO DE SINAIS ALEATÓRIOS DE <i>BASELINE</i> NA DETECÇÃO E QUANTIFICAÇÃO DO DANO I	140
B.1	50 sinais aleatórios de <i>baseline</i>	141
B.2	100 sinais aleatórios de <i>baseline</i>	147
B.3	150 sinais aleatórios de <i>baseline</i>	153

1 INTRODUÇÃO

As unidades Flutuantes de Produção, Armazenamento e Transferência (FPSO), mostrado na Figura 1, são instalações marítimas que normalmente constituem-se de navios tanques equipados para a produção e armazenagem de petróleo extraído de poços submarinos. Eles permitem grande flexibilidade de operação em regiões remotas [1], pois podem atuar como uma instalação intermediária de pré-processamento e armazenamento [2]. O óleo armazenado em seus tanques, localizados no interior do casco mostrado na Figura 1, é descarregado periodicamente em navios petroleiros para transporte e distribuição.

Devido à sua exposição a misturas agressivas de água do mar e óleo, os tanques de armazenamento e de lastro dos FPSOs geralmente enfrentam problemas relacionados a danos por corrosão [3; 4]. A integridade estrutural é garantida por meio de inspeções periódicas e rotinas de manutenção que são caras e demoradas [5]. Além disso, o pessoal envolvido nesses procedimentos está exposto a riscos de trabalho em espaços confinados com atmosferas tóxicas [6]. Um sistema capaz de detectar corrosão de forma remota eliminaria a necessidade dessas intervenções e seria altamente desejável do ponto de vista operacional e econômico.

Figura 1: FPSO na cidade de Paraty operando no campo de Tupi no nordeste da Bacia de Santos.



Fonte: Adaptado de Petrobras [7].

Técnicas alternativas de inspeção ou monitoramento estão sempre sendo estudadas para desenvolver formas mais seguras e eficientes de gerenciar a integridade do casco de um navio [5]. As sociedades classificadoras estão explorando o uso de *Robotics and Autonomous Systems* (RAS) para realizar inspeções remotas como drones aéreos para inspeções visuais e robôs escaladores de esteiras magnéticas com ferramentas de Ensaio Não-Destrutivo (NDT) [8; 9; 10]. No entanto, para a aplicação dessas técnicas, ainda é necessário que o tanque esteja vazio e limpo para permitir a operação [5]. Uma alternativa a estes métodos seriam sistemas baseados em ondas guiadas elásticas, o qual é utilizada para detecção de corrosão e trincas [11].

A técnica de onda guiada tem a característica de monitorar extensas regiões de uma estrutura a partir de um único ponto de acesso, permitindo a inspeção de partes remotas e de difícil acesso [12; 13; 14]. Conforme demonstrado na literatura, sistemas baseados em ondas guiadas elásticas têm grande potencial para aplicação no Monitoramento de Saúde Estrutural (SHM) de estruturas complexas [15; 16] em áreas de difícil acesso [17], como tanques de armazenamento de FPSOs, o qual trata-se da estrutura estudada nesse trabalho. Esses sistemas são geralmente compostos por um conjunto de transdutores piezoelétricos permanentemente acoplados, cada um atuando sequencialmente como emissor e receptor das ondas guiadas [18; 19]. Nesta configuração, a presença de um defeito irá de alguma forma modificar a propagação das ondas em comparação com a estrutura em estado sem dano, porém vale ressaltar que as ondas guiadas são muito sensíveis a um grande número de parâmetros, e, portanto, torna-se difícil separar a influência de defeitos nos sinais medidos da influência de outros parâmetros, como por exemplo a variação de temperatura [20; 21].

A finalidade de um sistema SHM é monitorar continuamente a integridade de uma estrutura de forma não destrutiva [15; 21] através da observação da estrutura por meio de amostragens periódicas de sua resposta mediante um conjunto de sensores, e a análise estatística dos atributos dessas medições com o objetivo de determinar a condição atual da estrutura [22], ou seja, através das informações fornecidas pelo sistema SHM, é possível verificar se a estrutura possui algum tipo de dano, localizá-lo, avaliar a sua severidade e realizar o prognóstico da estrutura. Dessa forma, é possível tomar decisões sobre a manutenção e possível reparo da estrutura [23], melhorando a sua segurança e confiabilidade, e reduzindo os custos de manutenção [24; 25; 26].

A interpretação dos dados de sistemas baseados em ondas guiadas é comumente realizada diretamente por operadores técnicos treinados em um procedimento clássico de inspeção de NDT, e é sua responsabilidade gerenciar a integridade estrutural e alertar quando houver uma anormalidade. No entanto, os dados de um sistema SHM são gerados em intervalos muito mais curtos devido a possuírem sensores instalados permanentemente operados com eletrônica que normalmente é dedicada. Além disso, à medida que o número de locais de monitoramento em uma estrutura aumenta, o fluxo de dados pode se tornar excessivo para interpretação humana [27]. Assim, muitas medições são obtidas, mas apenas uma parte é útil para tarefas de tomada de decisão [28; 29].

Atualmente, a alta dimensão é uma característica comum em dados [30]. Normalmente,

dados com alta dimensionalidade são muito esparsos, altamente correlacionados e, portanto, bastante redundantes, causando a maldição da dimensionalidade [31]. O termo maldição da dimensionalidade significa que à medida que aumenta as dimensões dos dados, a quantidade de dados necessários para treinar um modelo e evitar o *overfitting* cresce exponencialmente [32; 33].

Técnicas de Inteligência Artificial (IA) [34] são uma opção para resolver o problema de lidar com um grande volume de dados gerados [27]. Embora os algoritmos de IA possam processar *big data* [28; 29], sua acurácia é prejudicada à medida que a dimensionalidade aumenta [35]. Entre várias técnicas de IA, os algoritmos de redução de dimensionalidade visam resolver a maldição da dimensionalidade, com o objetivo de melhorar a qualidade dos dados, reduzindo a complexidade dos mesmos [35; 36]. Esses algoritmos podem lidar com problemas comuns adicionais em conjuntos de dados como ruído, complexidade e esparsidade [35].

Alguns algoritmos mais representativos e bem-sucedidos e que possuem aplicações em dados de ondas guiadas são [35; 37]: *Principal Component Analysis* (PCA) [38; 39; 40; 41], *AutoEncoder* [38], *Linear Discriminant Analysis* (LDA) [40; 42], *Singular Value Decomposition* (SVD) [41; 43], *Locally Linear Embedding* (LLE) [44], *t-Distributed Stochastic Neighbor Embedding* (t-SNE) [39] e *Independent Component Analysis* (ICA) [38; 43; 45; 46].

Pesquisas realizadas nos últimos anos mostram que a aplicação de algoritmos de redução de dimensionalidade em sistemas SHM de ondas guiadas tem um grande potencial [46]. Métodos utilizando esses algoritmos têm sido desenvolvidos para diferentes propósitos, estruturas e materiais. Em alguns métodos desenvolvidos, essas técnicas foram combinadas com outras técnicas de *Machine Learning* (ML) [38; 40; 44; 47; 48; 49; 50; 51]. Em outras abordagens, diferentes técnicas de redução de dimensionalidade foram combinadas [39; 52]. Por último, outros métodos foram desenvolvidos usando apenas uma técnica de redução de dimensionalidade [41; 42; 43; 45; 46; 53; 54].

Desta forma, tem-se como objetivo nesta tese o desenvolvimento de um método para detecção e quantificação de danos utilizando dados de dimensão reduzida de um SHM de ondas guiadas. Para alcançar esse objetivo, seguiu-se um fluxo de atividades o qual iniciou-se pela realização de uma revisão bibliográfica sobre os temas abordados a fim de obter uma melhor compreensão sobre os sistemas FPSO de exploração de petróleo, seus tanques de armazenamento, os mecanismos e modos de falha mais comuns, e os métodos de inspeção e monitoramento normalmente usados nesses tanques. Além disso, realizou-se a revisão bibliográfica sobre o uso de sistemas SHM para garantir a integridade estrutural, fundamentos das ondas guiadas, e os conceitos de transdutores piezoelétricos. Por último, realizou-se a revisão bibliográfica sobre os conceitos de IA, redução de dimensionalidade e técnica ICA.

Em seguida, realizou-se o desenvolvimento do projeto e construção de um painel para reproduzir uma região do tanque de armazenamento de um FPSO. Realizou-se o desenvolvimento do projeto do invólucro para proteção do transdutor contra condições climáticas adversas e, posteriormente, realizou-se a construção e instalação permanente de um conjunto de transdutores

piezoelétricos no painel. Após a instrumentação do painel com os transdutores piezoelétricos, realizou-se a aquisição de sinais em uma determinada faixa de temperaturas através de pares de sensores, emissor e receptor, para formar um conjunto de dados da estrutura íntegra que serão usados como sinais de *baseline*.

Na sequência, reproduziu-se os danos no painel com diferentes níveis de profundidade para representar danos por corrosão e realizou-se a aquisição do sinal de onda guiada para cada nível de dano através de pares de sensores, emissor e receptor. Posteriormente, desenvolveu-se o método para detecção e quantificação de danos usando o banco de dados adquiridos nos ensaios experimentais do painel. Por último, realizou-se as discussões dos resultados da detecção e quantificação dos danos, as conclusões, e foi sugerido algumas atividades para trabalhos futuros.

2 OBJETIVOS

Esta tese tem como objetivo geral o desenvolvimento de um método para a detecção e quantificação de danos relacionados a redução de espessura em estruturas complexas e de difícil acesso como tanques de armazenamento de FPSOs por meio de dados de dimensão reduzida de um sistema SHM de ondas guiadas permanentemente instalado em uma estrutura que reproduz uma parte da divisória que separa os tanques de armazenamento e de lastro. O método deverá ser capaz de lidar com variações ambientais como ruído ambiente e variações de temperatura sem a necessidade do uso de técnicas de pré-processamento complexas.

Além disso, a tese também possui os seguintes objetivos específicos:

- Analisar e comparar os dados reduzidos, através do algoritmo ICA, de dois conjuntos de dados, o primeiro composto por dados de *baseline* e o segundo composto pelos mesmos dados mais um dado (*baseline* ou defeito), para verificar e identificar a nova informação estatística relacionada ao dano;
- Automatizar a identificação da componente relacionada ao dano, utilizando os dados reduzidos, através da detecção de *outliers*, relacionando entre si as componentes dos dois conjuntos de dados através do valor máximo da correlação cruzada;
- Avaliar a influência do número de componentes do ICA, do número de sinais de *baseline* para formar o conjunto de dados, da frequência de operação e do intervalo de amostragem de *lag* na busca pelo valor máximo de cada correlação cruzada na detecção (acurácia e erros) e quantificação (relação sinal-ruído (SNR) das componentes *outliers*) dos danos;
- Analisar a influência do caminho percorrido pela onda, se houver interação direta ou indireta com o dano ou elementos estruturais, na detecção e quantificação dos danos em todas as combinações de pares de sensores.

3 REVISÃO BIBLIOGRÁFICA

Com o intuito de melhor planejar o desenvolvimento deste estudo e alcançar os objetivos apresentados anteriormente, realizou-se uma pesquisa bibliográfica sobre os temas abordados nesta tese. Neste capítulo são apresentados alguns conceitos sobre unidades FPSO, uso de sistemas SHM para garantir a integridade estrutural, fundamentos das ondas guiadas, e conceitos sobre transdutores piezoelétricos, sobre IA e sobre o algoritmo ICA com a finalidade de obter uma melhor compreensão sobre esses temas.

3.1 Unidade Flutuante de Produção, Armazenamento e Transferência

Nesta seção são apresentados os sistemas FPSOs de exploração de petróleo, seus tanques de armazenamento, os mecanismos e modos de falha mais comuns e as técnicas normalmente empregadas na inspeção e monitoramento dos tanques.


3.1.1 Sistema FPSO de Exploração de Petróleo

Atividades operacionais marítimas são sempre acompanhadas de alto risco devido ao ambiente hostil e a processos de trabalho complexos [55] que podem levar a desastres humanos e ambientais. Nos últimos tempos, houve um aumento significativo das atividades de exploração e desenvolvimento de reservatórios de petróleo e gás em águas profundas, e isso foi acompanhado pelo aumento da demanda por FPSOs. Entre todos os tipos de estruturas marítimas, as estruturas FPSOs se tornaram cada vez mais populares devido à sua mobilidade e capacidade de carga com ampla área de convés [56; 57]. Um FPSO contém todos os equipamentos de uma plataforma fixa quanto ao processamento primário de óleo e gás, e possui semelhança a um petroleiro na aparência, porém com uma estrutura consideravelmente mais complexa. Além disso, um FPSO geralmente é projetado para produção marítima ininterrupta em longo prazo, normalmente não possui manutenção programada de docas secas, e é impossível realizar atividades de manutenção frequentes enquanto estiver em serviço [1; 6; 58].

Para demonstrar a complexidade de um FPSO, pode-se dizer que se trata de um grande navio com uma refinaria. Evidentemente, isso é uma simplificação do que é um FPSO, mas por outro lado, pode-se ter uma ideia do número de equipamentos que precisam ser inspecionados [2].

Na Figura 2 é mostrado uma imagem comparativa entre as plataformas fixa, autoelevatória, semissubmersível e FPSO, o qual verifica-se que as plantas FPSOs possuem a vantagem de poderem ser utilizadas em regiões que não possuem infraestrutura capaz de suportar oleodutos e em campos de petróleo de águas profundas e ultraprofundas. Outra vantagem das unidades FPSOs em relação aos oleodutos se deve ao fato de não ser uma estrutura fixa, sendo assim, os FPSOs podem ser deslocadas para outro poço caso a produção não seja mais viável ou rentável [57; 59; 60; 61].

Figura 2: Imagem comparativa de diferentes tipos de plataformas.




Fonte: Adaptado de Moraes [62].

Normalmente os FPSOs possuem forma de navios onde a sua construção é a partir de navios-tanque convertidos, mas a sua fabricação também pode ser através de projetos específicos por meio de novas construções [63]. Uma nova construção é uma embarcação totalmente projetada para ser um FPSO, ou seja, o casco é construído a partir de um novo projeto. Já os de conversão são normalmente construídos a partir de cascos de navios-tanque. Nesse caso, o casco pode sofrer pequenas alterações quando os requisitos de armazenamento não são atendidos, ou pode ser aumentado quando necessário. Adaptações na estrutura são necessárias para atender aos requisitos de operação do FPSO, que são mais rigorosos que os navios-tanque comerciais mais comuns [64]. O FPSO é constituído por duas partes principais que são o casco e o *topside*. O casco possui grandes dimensões para poder armazenar o máximo de carga possível. Grandes tanques de carga para o armazenamento de óleo estão localizados dentro do casco e divididos em várias seções. Já o *topside* é localizado no convés, onde são colocados todos os equipamentos necessários à produção a partir de módulos [57; 64].

O navio FPSO deve ser ancorado e conectado aos sistemas de produção submarinos por meio de linhas flexíveis. Assim, o óleo é extraído dos poços de produção, através de *flowlines* e *risers*, e processado pelos sistemas *topside* através de unidades de processamento de hidrocarbonetos que processam e separam o petróleo bruto extraído em óleo refinado, gás e água. O óleo extraído e processado é então armazenado a bordo em tanques de carga e posteriormente transferido para a terra por meio de navios-tanque [3; 11; 61]. Além disso, os tanques de carga são considerados um sistema marítimo, pois afetam diretamente a estabilidade e a resistência estrutural da embarcação [64], e estão sujeitos a diversos mecanismos de degradação onde a sua integridade estrutural é assegurada através de inspeções e manutenções [6]. Uma visão geral de uma típica solução FPSO pode ser vista na Figura 3.

Figura 3: Representação de um navio FPSO e sistema submarino.



Fonte: [11].


3.1.2 Tanques de Armazenamento de FPSOs

Além dos tanques de armazenamento de óleo, a embarcação é equipada com tanques de lastro que também interessam à inspeção. Esses tanques transportam água para dar estabilidade à embarcação. Sua inspeção é relevante para a integridade geral da estrutura, devido ao efeito altamente corrosivo da água salgada do mar. Ao mesmo tempo, os tanques vazios também são afetados pelo ar úmido, o que também aumenta o impacto da corrosão na superfície do tanque. Ao contrário dos tanques de armazenamento de óleo, os tanques de lastro geralmente são apresentados como ambientes desordenados com muitos obstáculos [11].

Os componentes do casco têm basicamente as funções de garantir que o navio tenha integridade estrutural suficiente para conter vazamentos e suportar carga e lastro sob cargas estáticas e dinâmicas. Tanto a estrutura do casco do navio quanto a estrutura dos tanques de carga e de lastro são constituídos de placas e reforços conectados por juntas soldadas. Devido à interconexão desses componentes, a perda de integridade ou danos nesses componentes podem, eventualmente, levar a falhas na estrutura, resultando em grandes consequências econômicas e ambientais, dada à forma como os componentes estão interconectados [11; 65].

Na Figura 4, uma estrutura típica de tanque de carga juntamente com a estrutura do tanque de lastro (tanques laterais) é apresentada em uma vista em corte transversal e em perspectiva [66], mostrando fileiras de reforços nos tanques de carga e de lastro soldados no piso e nas paredes laterais, além das anteparas longitudinais que separam os dois tanques. O petróleo bruto é armazenado no tanque central enquanto os tanques de lastro possuem água do mar. Esses tanques de armazenamento de alto volume possuem uma área ampla com alturas significativas de até 30 m [11].

Figura 4: Estrutura típica de tanque de carga e lastro.



Fonte: [66].

3.1.3 Mecanismos e Modos de Falha em FPSOs

No interior do tanque de um FPSO, diferentes tipos de falhas podem surgir dependendo da localização e do método de proteção contra corrosão utilizado [5]. Nesta seção são apresentados os mecanismos e modos de falha mais comuns em FPSOs com enfoque nos processos corrosivos.

3.1.3.1 *Mecanismos e Modos de Falha*

Nos diversos modos de operação aos quais as estruturas de engenharia estão expostas, existem vários tipos de possíveis mecanismos de falha [67]. Mecanismos de degradação ou mecanismos de falha são os processos de evolução de danos estruturais que eventualmente precipitam um ou mais modos de falha. Para identificar esses mecanismos é necessário conhecer os processos de envelhecimento da estrutura e observar os resultados da inspeção para identificar se eles estão presentes. Os principais mecanismos de degradação podem atuar isolados ou combinados e a intensidade de seus efeitos pode antecipar a ocorrência de danos estruturais. Os mecanismos de degradação mais comuns em FPSOs são a corrosão substancial, corrosão severa, corrosão por pites, desgaste, erosão, trincas e flambagem [11; 65]. Dentre esses mecanismos de falha, a degradação por corrosão possui a maior incidência [65].

A relação entre o mecanismo e os modos de falha e sua observação, pode tornar-se decisiva para decidir qual tipo de manutenção deve ser empregada. Diferentes mecanismos de falha podem se manifestar da mesma forma, ou seja, podem apresentar o mesmo modo de falha. Essa complexidade fica mais evidente quando os itens estão associados. O modo de falha caracteriza a falha ou perda de função de um sistema ou estrutura. O colapso, por exemplo, é a manifestação final de um modo de falha. Além disso, cada elemento estrutural pode ter diferentes modos de falha [65].

A identificação do modo de falha é feita por uma atuante observação e análise cuidadosa dos dados. Os principais modos de falha podem ocorrer isolados ou combinados e podem levar ao comprometimento local da estrutura ou mesmo ao colapso global da estrutura. Os modos de falha mais significativos em FPSOs são a inundação do compartimento, perda de flutuabilidade, explosão ou incêndio, vazamento para o meio ambiente ou entre tanques e perda de integridade estrutural [11; 65]. Dentre os modos de falha apresentados, o vazamento para o meio ambiente ou entre tanques e a perda de integridade estrutural são consequências da corrosão [65].

Quando os mecanismos de degradação e os modos de falha associados são conhecidos, é importante identificar meios de intervenção. Os meios de intervenção visam reduzir ou bloquear a ação do mecanismo de degradação, prevenindo ou retardando danos nos componentes. Alguns meios de intervenção para unidades FPSOs são: pintura e revestimento, ânodos de sacrifício, tratamento de agentes corrosivos, tratamento e limpeza de gases inertes, desumidificação do tanque e alterações nos detalhes estruturais [65].

3.1.3.2 *Processos Corrosivos*

Devido aos remotos locais de operação dos FPSOs, é improvável que evitem condições climáticas adversas durante a sua vida útil [68]. A deterioração progressiva das estruturas dos navios como consequência da operação normal e das influências ambientais pode ser atribuída como definição de envelhecimento estrutural. Esta deterioração pode aparecer a partir de vários mecanismos de falha, porém a corrosão é um dos mais relatados [2; 68; 69].

A corrosão é um conjunto de fenômenos de deterioração dos materiais, principalmente me-

tálicos, devido a reações químicas ou eletroquímicas entre o material e o meio ambiente [2]. Dependendo do ambiente, os processos de corrosão podem se referir a reações químicas ou eletroquímicas, sendo que esta última ocorre em uma grande variedade de aplicações industriais. Um exemplo distintivo disso é o enferrujamento do aço devido à exposição à água ou ao ar úmido, levando à formação de óxidos de ferro e, eventualmente, a danos materiais. O processo de corrosão inicia-se com a diminuição da espessura do material, variações em suas propriedades mecânicas e por fim uma redução na capacidade de resistência [69].

Muitas vezes o óleo produzido contém uma pequena quantidade de água que se separa durante o tempo de armazenamento e se acumula no fundo do tanque. Esta água, de formações geológicas, possui características corrosivas bastante severas, muitas vezes mais agressivas que a água do mar, destacando essa região como uma das mais suscetíveis à degradação por corrosão. Outra região do tanque de carga do FPSO suscetível à corrosão é a estrutura da anteparo (divisória) que é composta por placas e enrijecedores (reforços) e separa os tanques de carga e de lastro. Vale salientar que qualquer falha no sistema de proteção favorece um rápido ataque da corrosão [65].

Os FPSOs operam em locais cada vez mais remotos e permanecem na estação durante toda a sua vida útil. Dessa forma, as inspeções para identificar a presença de corrosão precisam ser realizadas no local e muitas vezes podem se tornar desafiadoras e potencialmente arriscadas [69].

3.1.4 Inspeção e Monitoramento de Tanques de Armazenamento de FPSOs

Historicamente, as inspeções de navios são realizadas em docas secas em intervalos regulares de cinco anos. Normalmente, as estruturas marítimas flutuantes permanentemente ancoradas não possuem manutenção programada de docas secas. Portanto, a inspeção dessas estruturas deve ser realizada no local durante a operação, tornando a inspeção mais desafiadora [6]. Além disso, mesmo que sejam tomadas precauções significativas, o pessoal envolvido na inspeção está exposto a riscos devido ao trabalho em espaços confinados, trabalho em altura, caminhada em superfícies escorregadias e acesso a áreas quase inacessíveis [6; 8].

O gerenciamento da integridade estrutural da maior parte da estrutura do casco do FPSO é baseado em risco, com a inspeção sendo conduzida por regulamentos das sociedades classificadoras [9]. Atualmente as inspeções em navios são realizadas normalmente através de inspetores. Esses especialistas inspecionam todas as partes do navio, incluindo áreas muito perigosas e potencialmente letais. As sociedades classificadoras de navios, como a *International Association of Classification Societies* (IACS), tem emitido uma série de documentos contendo recomendações e diretrizes para minimizar riscos aos inspetores, porém ainda existem muitos riscos, além do tempo e custos de inspeção serem altos. Esses documentos evidenciam a complexidade das inspeções a bordo dos navios, sugerindo que cada inspeção deve ser antecipada por uma série de operações preventivas como limpeza, ventilação, iluminação e montagem temporária de estruturas como escadas [10]. Na Figura 5 é mostrada uma estrutura típica de um tanque de carga de um navio petroleiro sendo inspecionado por um inspetor utilizando meios de acesso como

uma escada. Nesses casos, a inspeção realizada normalmente é visual e através de medições de pontos de espessura utilizando ultrassom. Técnicas de inspeção como líquidos penetrantes e partículas magnéticas também são utilizadas em casos onde é necessário investigar localmente defeitos como trincas que foram identificados [70].

Figura 5: Imagem de uma estrutura típica de um tanque de carga de um navio petroleiro sendo inspecionado por um inspetor utilizando meios de acesso.



Fonte: [10].

Técnicas alternativas de inspeção ou monitoramento estão sempre sendo estudadas para desenvolver formas mais seguras e eficientes de gerenciar a integridade do casco de um navio. Entre as questões que ainda podem ser melhoradas está a minimização da entrada tripulada em tanques de lastro e armazenamento de óleo [5]. Para evitar esses procedimentos, as sociedades classificadoras estão explorando o uso de RAS para realizar inspeções remotas como drones aéreos para inspeções visuais e robôs escaldadores de esteiras magnéticas com ferramentas de NDT [8; 9; 10].

Na Figura 6 é apresentado dois modelos de drones aéreos que se diferem em tamanho e habilidades. O primeiro, mostrado na Figura 6a, é projetado para voar em amplos espaços abertos para inspeção em áreas de segurança comprometida, de difícil acesso e com grandes espaços como os tanques de carga. Já o segundo, mostrado na Figura 6b, é tolerante a colisões e especialmente dedicado a realizar inspeções em espaços estreitos com alta densidade de obstáculos como os tanques de lastro [10].

Os robôs escaldadores, mostrados na Figura 7, são uma das soluções para a realização de inspeções, o qual permitem a montagem de suportes para a fixação de ferramentas de NDT. Como a estrutura do navio é feita de aço, a adesão magnética é normalmente usada para gerar a força de contato necessária para fornecer adesão e propulsão. Para isso, os robôs se deslocam sobre rodas magnéticas, conforme Figuras 7a, ou esteiras magnéticas, conforme Figuras 7b, inspecionando estruturas verticais ou suspensas [8; 10].

Figura 6: Tecnologia RAS para drones.

(a) Drone para amplos espaços abertos.



(b) Drone para espaços estreitos com proteção contra colisão.




Fonte: [10].

Figura 7: Tecnologia RAS para robôs.

(a) Robô escalador com rodas magnéticas.



(b) Robô escalador com esteiras magnéticas.



Fonte: [8; 10].

No entanto, para a aplicação dessas técnicas, ainda é necessário que o tanque esteja vazio e limpo para permitir a operação [5]. Além disso, essas técnicas ainda possuem muitas limitações em inspeções de tanques de navios. No caso dos drones, voar em espaços confinados envolve muitos desafios como distúrbios de campo eletromagnético entre o RAS e sistemas eletrônicos a bordo, impossibilidade de uso dos sinais do Sistema Global de Posicionamento (GPS) para a localização do RAS devido o ambiente circundante ser de aço, problemas relacionados à detecção de obstáculos ou manutenção de posição em uma referência visual onde as câmeras geralmente são afetadas por desfoque de movimento, dificuldades na detecção de distâncias entre os obstáculos através dos lasers e câmeras devido às superfícies refletoras das placas metálicas, instabilidade devido as turbulências do ar causadas pelas próprias hélices, imagens pouco nítidas devido a poeira levantada pelas hélices, desempenho dos motores elétricos de propulsão prejudicados pela poeira e impossibilidade de monitorar o drone através

de um campo de visão direto devido o voo ser realizado fora do campo de visão do operador. Da mesma forma, o principal problema dos robôs escaldadores é representado pela sua capacidade limitada de ultrapassar os obstáculos presentes nesse tipo de estrutura, que é composta por enrijecedores soldados e geometrias complexas como a transição entre duas superfícies com inclinações diferentes [10].

Uma alternativa aos métodos anteriormente apresentados seriam sistemas baseados em ondas guiadas elásticas, o qual é utilizada para detecção de corrosão e trincas [11], e, atualmente, estão sendo estudadas em aplicações de SHM para o monitoramento de estruturas complexas como os tanques de armazenamento de FPSOs [5] através do uso de transdutores instalados permanentemente na estrutura [71]. Um sistema de ondas guiadas baseia-se na emissão de ondas elásticas que se propagam ao longo da estrutura, inspecionando, assim, uma determinada área. Para estruturas do tipo placa, esses sistemas podem ser aplicados através de uma matriz esparsa de sensores para obter a cobertura de grandes áreas da estrutura [19].

3.2 Monitoramento de Integridade Estrutural

Atualmente as empresas têm utilizado a manutenção preditiva como um processo efetivo em suas atividades para a prevenção do surgimento de possíveis falhas em componentes. As falhas podem surgir devido ao uso contínuo do material ou aos esforços dinâmicos que estes são submetidos [72]. Com o objetivo de evitar acidentes que podem ocasionar perdas de vidas humanas e grandes perdas financeiras, e reduzir os custos de manutenção, pesquisadores vêm se dedicando ao estudo do monitoramento em estruturas [24; 72]. A ideia central desse procedimento é fazer um acompanhamento contínuo nos equipamentos com o intuito de conhecer a atual condição estrutural destes [72].

Há um interesse crescente em mudar da inspeção periódica através de NDT para o monitoramento contínuo usando sistemas SHM [27]. A tecnologia SHM possibilita o monitoramento com menos interferência humana e resultados mais precisos no gerenciamento de falhas [73]. O SHM é um tipo de manutenção preditiva que vem sendo amplamente estudada na engenharia com o intuito de detectar o momento inicial das variações nas propriedades do material ou da geometria do sistema, as quais podem estar relacionadas a algum tipo de dano [18; 22; 72]. Isso é possível através da observação do sistema por meio de amostragens periódicas de sua resposta mediante um conjunto de sensores e a análise estatística dos atributos dessas medições [22], facilitando, assim, a tomada de decisões sobre a manutenção e possível reparo da estrutura [23]. Além disso, dependendo da estrutura e da técnica de NDT utilizada, estas variações poderão ser detectadas somente quando o dano já estiver em estágio avançado [72].

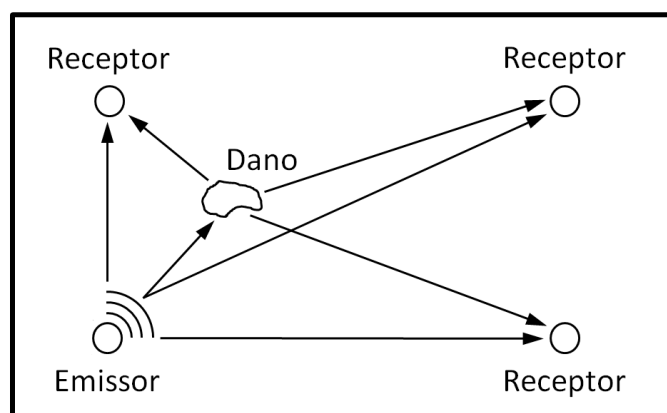
A técnica SHM, em geral, pode ser classificada em níveis que se baseiam na capacidade de abrangência [74]. Esses níveis explicam como, do início ao fim, um sistema SHM pode fornecer informações úteis [67]. Atualmente, pode-se classificar o SHM nos cinco níveis funcionais apresentados a seguir [75; 76]:

- Nível 1: Detecta a existência do dano (identificação);
- Nível 2: Detecta e localiza o dano (localização);
- Nível 3: Detecta, localiza e classifica o tipo do dano (classificação);
- Nível 4: Detecta, localiza, classifica e quantifica o dano (avaliação);
- Nível 5: Detecta, localiza, classifica e quantifica o dano e então estima a vida útil remanescente do equipamento (prognóstico).

Vários tipos de sistemas SHM foram propostos e implementados nos últimos anos, porém as técnicas de SHM baseadas em ondas guiadas tem atraído grande atenção, além de demonstrarem serem sensíveis a pequenos danos [24; 77; 78]. Nos últimos anos houve um movimento em direção à instalação permanente do sensor que permitiu leituras altamente repetíveis, permitindo melhorias na detecção e classificação de danos [46]. Ao interrogar frequentemente a estrutura por um longo período de tempo, esses sistemas têm o potencial de detectar danos com maior antecedência do que com a inspeção pontual convencional, além de reduzir o tempo e os custos de operação [13; 26; 43; 79].

Nesses sistemas, um conjunto esparsos de transdutores instalados permanentemente, cada um sondando alguns metros quadrados, é usualmente adotado em estruturas do tipo placa, como tanques de armazenamento e vasos de pressão, a fim de obter cobertura total de grandes áreas da estrutura [80; 81]. Na Figura 8 é apresentado um desenho esquemático de um arranjo de transdutores, onde cada transdutor opera sequencialmente como emissor, enquanto os demais operam como receptores, o qual recebem a onda contendo informações da presença de um possível dano.

Figura 8: Desenho esquemático de um arranjo de transdutores de ondas guiadas.



Fonte: Próprio Autor.

Nesses casos, as medições são registradas a partir da rede de transdutores, onde cada medição registrada está ao longo de um caminho entre um par de transdutores [82]. Um sistema

SHM típico consiste em transdutores para emissão e recepção, conforme apresentado na Figura 8, em que o emissor é normalmente conectado a um gerador de sinal enquanto os receptores são conduzidos a um sistema de aquisição de dados [77]. Nesses sistemas, o diagnóstico pode ser feito comparando os sinais adquiridos, onde qualquer alteração no sinal recebido pode ser interpretada como uma possível variação estrutural ou alteração das condições operacionais ou ambientais [72].

3.3 Fundamentos das Ondas Guiadas

A onda guiada, no contexto do SHM, é uma onda mecânica ultrassônica que se propaga através de meios estruturais finitos. A configuração finita do guia de ondas geralmente resulta em propagação de ondas multimodal, dispersiva e atenuante, tornando, assim, a análise e a implementação mais desafiadoras [77]. Por outro lado, a onda mecânica emitida por uma perturbação a partir de um determinado ponto de acesso propaga-se ao longo da geometria da estrutura, podendo percorrer grandes distâncias, e, assim, permitindo a inspeção de forma rápida de partes remotas e de difícil acesso de uma determinada área [79; 83].

Em meios sólidos infinitos, a propagação de ondas ocorre através de ondas primárias (longitudinal) ou secundárias (transversal) [84]. Estas formas de propagação possuem celeridades definidas pelas propriedades do meio material pelo qual se propagam e podem ser obtidas através da solução da equação de movimento para um corpo elástico, linear e isotrópico com uma força externa aplicada [85]. Assim, a partir das Equações (1) e (2), são apresentadas as celeridades c_1 e c_2 referentes às ondas primárias e secundárias.


$$c_1 = \sqrt{\frac{\lambda_L + 2\mu_L}{\rho}} \quad (1)$$

$$c_2 = \sqrt{\frac{\mu_L}{\rho}} \quad (2)$$

onde λ_L e μ_L são as constantes de Lamé e ρ é a massa específica do material do corpo.

Ondas que se propagam em estruturas finitas irão interagir com os limites físicos da estrutura do material, refletindo nas fronteiras do mesmo. Esta reflexão é regida pela Lei de Snell, onde uma onda transversal incidente sobre uma superfície livre irá refletir uma onda transversal e uma onda longitudinal [85], refletidas respectivamente em ângulos θ_{rt} , o qual é igual a θ_i , e θ_{rl} conforme ilustrado na Figura 9 [79].

Figura 9: Reflexão de uma onda transversal em uma superfície livre.



Fonte: [79].

A mudança de comportamento da onda ao interagir com superfícies de uma estrutura física leva à geração de modos característicos de propagação. Em estruturas com superfícies que sirvam como um guia de ondas, os quais possuem uma ou mais de suas dimensões comparáveis ao comprimento da onda emitida, os modos irão se propagar com celeridades diferentes, que dependem das propriedades mecânicas e da geometria do meio e da frequência com a qual a perturbação se propaga. Estes modos podem ser representados por meio das curvas de dispersão, os quais apresentam a relação entre a frequência e a celeridade de cada modo para uma dada geometria e material [86]. A dispersão trata-se do fenômeno em que a velocidade de fase de um modo de onda guiada varia com a frequência, o que resultará na distorção de um pacote de ondas e na redução da amplitude da onda durante a propagação. A redução da amplitude limitará a distância de inspeção e a distorção do pacote de ondas dificultará a identificação do sinal [87].

As curvas de dispersão para uma placa infinita foi obtida por Lamb através da resolução das equações de Rayleigh-Lamb e são descritas pelas Equações (3) e (4), que representam os modos simétricos e assimétricos, respectivamente [88].

$$\frac{\tan\left(K_{ts}\frac{e}{2}\right)}{\tan\left(K_{tl}\frac{e}{2}\right)} = -\frac{4\beta^2 K_{tl}K_{ts}}{(K_{ts}^2 - K^2)^2} \quad (3)$$

$$\frac{\tan\left(K_{ts}\frac{e}{2}\right)}{\tan\left(K_{tl}\frac{e}{2}\right)} = -\frac{(K_{ts}^2 - K^2)^2}{4\beta^2 K_{tl}K_{ts}} \quad (4)$$


onde a variável e representa a espessura da placa, K o número de onda na direção de propagação, K_{ts} e K_{tl} representam, respectivamente, os componentes do número de onda referentes à ondas transversais e longitudinais propagando no guia de ondas. Os números de onda K_{tl} e K_{ts} são representados pelas Equações (5) e (6) [88].

$$K_{tl}^2 = \left(\frac{\omega}{c_1}\right)^2 - K^2 \quad (5)$$

$$K_{ts}^2 = \left(\frac{\omega}{c_2}\right)^2 - K^2 \quad (6)$$

onde ω representa a frequência angular da onda e as constantes c_1 e c_2 representam as celeridades das ondas longitudinais e transversais, respectivamente. Os valores K e ω são apresentados através das curvas de dispersão como modos simétricos (S) e antissimétricos (A) [88]. Os modos S possuem simetria em relação à linha central do guia de ondas e os modos A possuem anti-simetria em relação à mesma linha, conforme mostrado nas Figuras 10a e 10b, respectivamente.

Figura 10: Formato dos modos de propagação.



Fonte: Adaptado de GuidedWave [89].

Em placas, além dos modos S e A, existem também os modos *Shear Horizontal* (SH), que possuem movimento cisalhante perpendicular ao plano. As curvas de dispersão referentes aos modos SH podem ser representadas através da relação apresentada na Equação (7) [83].

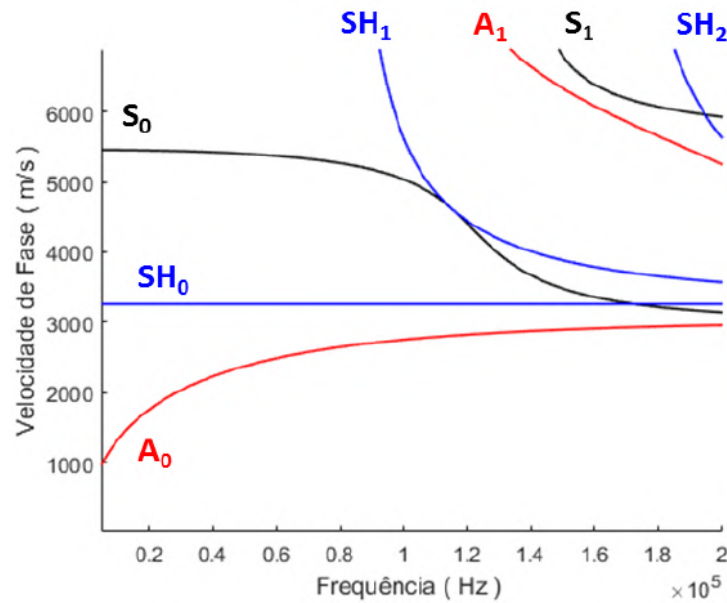
$$\frac{\omega^2}{c_2^2} - \frac{\omega^2}{c_p^2} = \left(\frac{N\pi}{e}\right)^2 \quad (7)$$

onde N é um número inteiro referente ao modo representado e c_p é a velocidade de fase do modo de propagação. Na Figura 10c pode ser visualizado o movimento perpendicular à superfície gerado por esse modo.

A presença de múltiplos modos de ordem superior em valores de frequência mais altos aumenta a complexidade dos sinais recebidos devido à ocorrência de múltiplas reflexões para cada perfil estrutural [71]. Por essa razão, a operação em valores de frequência baixas é geralmente preferida, pois dessa forma apenas os modos fundamentais de propagação podem ser excitados. Em estruturas com formato de chapas existem três modos fundamentais, ou seja, os modos de onda de Lamb simétrico (S_0) e antissimétrico (A_0) e o modo *Shear Horizontal* (SH_0) [84; 88; 90]. A ausência de um elevado número de modos facilita o tratamento de dados e diminui o ruído gerado por modos de propagação emitidos de forma indesejada [91].

Na Figura 11 são apresentadas as curvas de dispersão existentes até a frequência de 200 kHz para uma chapa de aço carbono de 20 mm de espessura através da relação entre velocidade de fase e frequência. Por meio das curvas de dispersão, verifica-se que para frequências abaixo de aproximadamente 90 kHz apenas os modos fundamentais podem ser propagados.

Figura 11: Curvas de dispersão para uma chapa de aço carbono com 20 mm de espessura.



Fonte: [91].

Os modos de propagação também podem ser representados através da velocidade de grupo (c_g). A velocidade de grupo refere-se à velocidade com que um pacote de ondas com frequências similares propaga-se através de uma estrutura, e pode ser obtida através da derivada presente na Equação (8) [83].

$$c_g = \frac{d\omega}{dK} \quad (8)$$

Dentre os modos de propagação fundamentais presentes em uma estrutura do tipo placas, o SH_0 tem a vantagem de não ser dispersivo, o que pode simplificar significativamente a interpretação dos sinais [25; 78; 92]. O modo não dispersivo possui velocidade de fase constante para todas as frequências, conforme mostrado na Figura 11, o que ajuda a evitar etapas adicionais de processamento de sinal e permite uma melhor resolução na detecção de falhas em uma estrutura, visto que o efeito da dispersão, presente nos modos de propagação S_0 e A_0 , aumenta a duração do sinal e diminui sua amplitude [25; 71; 92]. De acordo com a Figura 11, nota-se que o modo A_0 apresenta variações na velocidade de fase para toda a faixa de frequência analisada, enquanto que o modo S_0 inicia a apresentar variações mais acentuadas a partir de 65 kHz.

O modo SH_0 também sofre menores atenuações ao se propagar em superfícies em contato com fluidos [93], pois o mesmo apresenta seus maiores deslocamentos dentro do plano da estrutura que serve como guia de ondas, interagindo menos com algum fluido que esteja em contato com a estrutura [25; 79]. Dessa forma, a utilização do modo SH_0 pode ser considerada uma alternativa para a detecção de corrosão, perda de espessura ou trincas em estruturas como tanques ou cascos de navios, onde as mesmas geralmente estão em contato com algum tipo de fluido [79].

As ondas guiadas podem ser emitidas em uma estrutura através de transdutores projetados para excitar determinado modo de propagação. Um transdutor de ondas guiadas omnidirecional permite a emissão e recepção de ondas de forma uniforme em todas as direções. A possibilidade de gerar de forma uniforme apenas um modo de propagação permite a diminuição de sinais gerados por outros modos, que podem interferir na detecção de um dano na estrutura e aumentar a complexidade na interpretação dos resultados de uma inspeção [94].

3.4 Transdutores Piezoelétricos

Os transdutores, tanto para emissão quanto para recepção, são uma parte importante de um sistema SHM [18; 77], e é necessário que estes transdutores sejam confiáveis e sensíveis o suficiente para detectar pequenas mudanças na estrutura, permitindo que seja possível realizar um eficiente monitoramento da integridade estrutural [95]. Os transdutores eletromecânicos convertem energia elétrica em mecânica, e vice-versa, transformando, assim, deformações em sinais elétricos, o qual, entre os diferentes princípios físicos utilizados nesses transdutores, destaca-se a piezoelectricidade [79].

Materiais piezoelétricos possuem a propriedade de se deformarem quando submetidos a um campo elétrico e, da mesma forma, se tornam eletricamente polarizados quando submetidos a uma deformação mecânica. Estes materiais podem ser encontrados na forma de cristais, ou então fabricados na forma de cerâmicas ou polímeros. Em comparação a cristais piezoelétricos, algumas cerâmicas piezoelétricas possuem alta sensibilidade à deformações mecânicas. Esta característica, além da possibilidade de fabricação em diversos formatos e tamanhos, faz das cerâmicas piezoelétricas um material normalmente utilizado na construção de transdutores de NDT [96].

O efeito piezoelétrico acontece em materiais que não possuem um centro de simetria na sua estrutura cristalina. Conforme o material é deformado elasticamente, o centro de gravidade das cargas positivas e negativas é deslocado, e a falta de simetria da estrutura impossibilita que as cargas elétricas se cancelem umas com as outras. As cerâmicas piezoelétricas em sua forma natural são materiais dielétricos, pois não possuem partículas livres que conduzem corrente elétrica. Esses materiais podem ser formados por moléculas polares, que apresentam dipolos elétricos, porém, devido à distribuição aleatória destas moléculas, macroscopicamente o material se mostra neutro. À medida que essas cerâmicas são submetidas a um forte campo elétrico, as moléculas polares do material se alinharão na direção do campo e o material se tornará, então, polarizado [91; 97].

Determinados materiais piezoelétricos são também ferroelétricos, onde cada célula unitária da rede cristalina possui um momento de dipolo elétrico permanente. Esses materiais podem ser polarizados através da aplicação de um forte campo elétrico e de altas temperaturas, apresentando, assim, efeito piezoelétrico permanente na direção da polarização. A polarização somente será desfeita caso o material seja submetido a temperaturas superiores a temperatura de Curie.

Neste caso, as direções do dipolo se tornariam aleatórias novamente [98]. Atualmente, os transdutores mais usados em sistemas SHM são os baseados em material cerâmico ferroelétrico como o zirconato-titanato de chumbo (PZT) [18; 77].

Para a construção de um transdutor através da utilização de um material piezoelétrico, deve-se observar algumas características como as suas dimensões físicas, posição do campo elétrico ao qual foi submetido e tipo do material utilizado. De acordo com estas características, a resposta a estímulos elétricos pode variar. A resposta em frequência da cerâmica piezoelétrica é um fator importante, o qual relaciona a amplitude da resposta mecânica do sistema para uma determinada excitação em função da frequência de excitação. Através da análise da resposta em frequência, pode-se visualizar qual a faixa de operação mais apropriada para determinadas dimensões de uma cerâmica, onde a resposta apresenta maior uniformidade, além de determinar quais frequências apresentam ressonância [79]. Em ensaios de ondas guiadas, é interessante que os transdutores piezoelétricos sejam operados em uma faixa de frequências que não esteja próxima a grandes ressonâncias em sua resposta, pois a presença de pequenas variações ambientais poderá apresentar alterações consideráveis nas medidas próximas destas ressonâncias, podendo dificultar uma posterior etapa de processamento de dados [91].

O comportamento mecânico de cerâmicas piezoelétricas é descrito através de relações constitutivas que relacionam deformações mecânicas e elétricas devido à aplicação de carregamentos mecânicos ou elétricos. As propriedades mecânicas e elétricas presentes nas relações constitutivas variam de acordo com o tipo de cerâmica utilizada. Dependendo do carregamento ao qual a cerâmica será submetida, pode-se escolher um material que apresente propriedades vantajosas para essa finalidade. Altos coeficientes piezoelétricos são desejáveis em materiais utilizados como transdutores, devido à maior resposta elétrica ou mecânica obtida [79].

3.5 Inteligência Artificial


Nesta seção são apresentados conceitos sobre IA e redução de dimensionalidade, e alguns exemplos do uso de algoritmos de redução de dimensionalidade em dados de ondas guiadas.

3.5.1 Conceitos de Inteligência Artificial

A IA trata-se de uma ampla área do conhecimento relacionada aos campos da ciência e engenharia, e, ainda que os conceitos referentes a essa área convirjam para a possibilidade de uma máquina realizar alguma tarefa de forma autônoma e com o mínimo de intervenção humana, não existe um consenso em relação ao que seja exatamente a IA [99]. No entanto, alguns pesquisadores definem a IA como um método ou procedimento realizado por uma máquina em uma tomada de decisão, que reflete as características de hábitos ou atitudes desempenhadas por um agente portador de inteligência [72]. Dessa forma, pode-se dizer que o intuito da IA é o desenvolvimento de sistemas computacionais capazes de realizar tarefas complexas, que normalmente requerem inteligência humana, com um grau de confiabilidade que é equivalente ou

superior ao de um humano [100; 101], agilizando, assim, o processo de tomada de decisão e diminuição das taxas de erros, além de aumentar a eficiência computacional [102]. De acordo com o diagrama mostrado na Figura 12, a IA abrange tanto o ML quanto o *Deep Learning* (DL), onde o ML é um subcampo da IA e o DL é um subcampo do ML [103].

Figura 12: Diagrama do campo de abrangência da inteligência artificial.



Fonte: [104].

As técnicas de ML são métodos orientados a dados que combinam conceitos fundamentais em computação com ideias oriundas das áreas de estatística, probabilidade e otimização [105], o qual pode ser categorizado basicamente como aprendizado supervisionado, não supervisionado e por reforço [104].

No aprendizado supervisionado, também chamado de aprendizado com instrutor, é disponibilizado um conjunto de dados rotulados nos quais para cada observação há uma resposta ou saída associada, onde o objetivo é encontrar um modelo que relacione as entradas às saídas para que seja possível prever os resultados de futuras observações (previsão) ou melhor entender as relações entre as respostas e as entradas (inferência) [106]. Nesse tipo de aprendizado, se o vetor de saída for uma variável categórica (variável discreta), a tarefa aprendida visa resolver um problema de classificação. Por outro lado, se o vetor de saída for uma variável numérica (variável contínua), então a tarefa aprendida tem por objetivo solucionar um problema de regressão [99].

Já no aprendizado não supervisionado, ou aprendizado sem instrutor, não são disponibilizadas ao algoritmo as respostas associadas às observações realizadas, ou seja, apenas as entradas são fornecidas, e o que se busca é compreender as relações entre as variáveis ou entre as observações em si [106]. Nesse caso, os dados de treinamento consistem em vetores de entrada sem nenhum vetor de valores alvo correspondentes [99]. O aprendizado não supervisionado é comumente usado para encontrar grupos ou conjuntos de elementos similares nos dados, o que é chamado de agrupamento ou *clustering*, onde após o agrupamento, geralmente, é necessária

uma avaliação para definir o que cada agrupamento significa, e para projetar os dados de um hiperespaço de dimensão n em outro de dimensão k (em que $k < n$), reduzindo a dimensionalidade dos dados para diminuir seu tempo de processamento ou para que possam ser representados em duas ou três dimensões, permitindo a sua visualização [104; 107].

No aprendizado por reforço, o algoritmo deve buscar tomar ações em determinadas situações com o intuito de maximizar algum tipo de recompensa. Nesse caso, não são disponibilizadas para o algoritmo as respostas ótimas para o problema, ou seja, nenhuma informação é fornecida sobre a categoria desejada ou objetivos explícitos, então, o algoritmo deve explorar o espaço de entradas interagindo com o ambiente através de uma sequência de estados, ações, recompensas e penalidades por um processo de tentativa e erro [107]. Os algoritmos de aprendizado por reforço são treinados continuamente, levando em consideração o *feedback* sobre a qualidade da decisão [108].

Inserido no subcampo do ML encontra-se o DL, o qual trata-se de uma técnica inspirada na maneira como o cérebro humano filtra informações, auxiliando, assim, um modelo a filtrar os dados de entrada por meio de camadas para prever e classificar informações [104]. Normalmente os métodos de DL usam arquiteturas de redes neurais, por isso são frequentemente chamadas de redes neurais profundas, onde a sua estrutura inclui uma camada de entrada, outra de saída e, entre essas, várias camadas ocultas. Por sua vez, essas camadas são conectadas através de nós, formando uma rede [104; 109]. O neurônio artificial tenta imitar o comportamento biológico através de funções matemáticas, onde recebe vários sinais (entradas) e calcula, de maneira ponderada, o somatório entre eles, então são aplicadas funções e, em seguida, o resultado é transmitido adiante. Os dados recebidos de outros neurônios representam os impulsos nervosos responsáveis por transmitir informação para treinar o algoritmo. O neurônio receptor será mais ou menos excitado com o sinal recebido devido à soma ponderada realizada, onde esta operação é comandada pelos pesos sinápticos [109].

Dentre as várias aplicações da IA na engenharia, destaca-se o seu uso em processos de identificação de anormalidades estruturais e detecção de danos mediante os sistemas de SHM [100]. A combinação de IA e SHM tem se mostrado uma solução atrativa, onde um dos mais recentes esquemas de SHM compreende em um sistema de rede de sensores para coletar as respostas estruturais e IA como um processo de extração de conhecimento para identificar a condição da integridade estrutural [23; 110]. A partir das características do sinal captado pelos sensores do SHM, é possível utilizar sistemas de IA para o processamento de sinais, o qual, por meio das informações geradas pelos desvios dos sinais, podem permitir a verificação da existência ou não de danos, a sua localização e a severidade [111].

Dos métodos de aprendizado apresentados, o não supervisionado permite uma abordagem baseada na detecção de *outliers*, ao invés de aprender os modelos e treinar com base nos dados. Nesses casos, uma *baseline* inicial do modelo é criada assumindo as condições operacionais normais. Posteriormente, ao receber novos dados dos sistemas de detecção durante a operação, o algoritmo detecta qualquer *outlier* dentro do *threshold* definido pelo sistema [75]. Além


disso, alguns algoritmos de redução de dimensionalidade são comumente utilizados para auxiliar o aprendizado não supervisionado, visando melhorar a qualidade dos dados, reduzir a complexidade dos mesmos, e, conseqüentemente, melhorar a acurácia do modelo [35].

3.5.2 Redução de Dimensionalidade

Nos últimos anos, um grande volume de dados vem sendo gerado continuamente em diferentes áreas de aplicação devido às modernas ferramentas de coleta de dados, técnicas e capacidades de armazenamento [112]. Dessa forma, é comum que conjuntos de dados possuam alta dimensionalidade. Normalmente, dados com alta dimensionalidade são muito esparsos, altamente correlacionados e, portanto, bastante redundantes, causando a maldição da dimensionalidade [31]. À medida que a dimensionalidade dos dados aumenta, eles se tornam exponencialmente mais esparsos [31]. Nas Figuras 13 e 14 é representado o aumento da distância dos pontos de dados à medida que a dimensionalidade aumenta.


O termo maldição da dimensionalidade significa que à medida que aumenta as dimensões dos dados, a quantidade de dados necessários para treinar um modelo e evitar o *overfitting* cresce exponencialmente [32; 33]. A maldição da dimensionalidade tem sido um problema rotineiro para cientistas que, a fim de compreender e explicar determinados fenômenos, têm se deparado com a necessidade de encontrar estruturas significativas ocultas, de baixa dimensão, dentro de dados de alta dimensão. Esse processo é denominado como redução de dimensionalidade dos dados [113].

Figura 13: Representação em duas dimensões da esparsidade dos dados.



Fonte: [114].

Figura 14: Representação em três dimensões da esparsidade dos dados.



Fonte: [114].

Do ponto de vista computacional, a consequência da redução de dimensionalidade dos dados é uma diminuição do espaço de busca de hipóteses, melhorando o desempenho e simplificando os resultados da modelagem de conhecimento em sistemas de aprendizado [113].

O principal objetivo da redução de dimensionalidade geralmente é uma melhor representação e discriminação dos dados ou uma visualização mais fácil dos mesmos [115]. Além disso, as técnicas de redução de dimensionalidade podem ser aplicadas para reduzir as exigências de espaço de armazenamento [112]. Essa técnica transfere os dados originais do espaço de alta dimensão para um espaço de baixa dimensão por transformação matemática [30], ou seja, visa manter a essência dos dados em poucas variáveis representativas através da remoção da redundância, tornando os dados mais intuitivos para a extração de padrões úteis [31]. Esses algoritmos podem lidar com problemas comuns adicionais em conjuntos de dados como ruído, complexidade e esparsidade [35].

A redução de dimensionalidade se torna mais importante quando são considerados conjuntos de dados do mundo real, que podem conter centenas ou milhares de variáveis [37]. Dentre as vantagens dos algoritmos de redução de dimensionalidade, destacam-se as seguintes: melhoria do desempenho dos algoritmos de ML; simplificação do modelo, além de evitar o *overfitting*; menor tempo de computação e muito menos armazenamento são necessários; e maior facilidade de visualização e interpretação dos dados [35].

Muitas alternativas de técnicas de redução de dimensionalidade têm sido propostas nos últi-

mos anos, onde alguns dos algoritmos mais representativos e bem-sucedidos, e com aplicações em dados de ondas guiadas são [35; 37]: PCA [38; 39; 40; 41], *AutoEncoder* [38], LDA [40; 42], SVD [41; 43], LLE [44], t-SNE [39] e ICA [38; 43; 45; 46]. Pesquisas realizadas nos últimos anos mostram que a aplicação de algoritmos de redução de dimensionalidade em sistemas SHM de ondas guiadas tem um grande potencial [46], onde vários métodos, utilizando esses algoritmos, têm sido desenvolvidos para diferentes propósitos, estruturas e materiais.

Em alguns métodos desenvolvidos, essas técnicas de redução de dimensionalidade foram combinadas com outras técnicas de ML como *Support Vector Machine* (SVM) [38; 44; 47; 48; 49], *Ensemble Subspace Discriminant* (ESD) [40], *k-Nearest Neighbors* (kNN) [40], *Linear Support Vector Machine* (LSVM) [40], *Decision Trees* (DT) [40], *Long Short-Term Memory* (LSTM) [50], *Naive Bayes* (NB) [51], *Support Vector Classification* (SVC) [51], *Linear Vector Quantization* (LVQ) [47] e *Multilayer Perceptron* (MLP) [47]. Em outras abordagens, diferentes técnicas de redução de dimensionalidade foram combinadas como PCA - t-SNE [39] e PCA - ICA [52]. Por último, outros métodos foram desenvolvidos usando apenas uma técnica de redução de dimensionalidade como PCA [41; 53], LDA [42], SVD [43; 54] e ICA [43; 45; 46].

Dentre os algoritmos de redução de dimensionalidade encontrados na literatura, o ICA tem se mostrado promissor para ser usado em sistemas SHM de ondas guiadas [46]. O ICA pode ser utilizado para auxiliar os métodos pertencentes à categoria de aprendizado não supervisionado, o qual não é disponibilizado um conjunto de dados rotulados ao algoritmo, ou seja, apenas as entradas são fornecidas [116], oferecendo, assim, a vantagem de não requerer informações prévias sobre o estado danificado da estrutura, excluindo a necessidade de simular todos os possíveis tipos de danos que se deseja monitorar.

3.6 Análise de Componentes Independentes

O algoritmo ICA abrange várias áreas de pesquisas e aplicações, não sendo a intensão desta tese esgotar a sua análise, mas apresentá-la de forma que seja possível entender os seus fundamentos. O ICA tenta minimizar o grau de dependência estatística das componentes, como informação mútua [117], estimativa de máxima verossimilhança e maximização de não-Gaussianidade (curtose ou negentropia) [118]. Além disso, várias implementações do algoritmo ICA são apresentadas na literatura [119; 120].

O ICA, apesar de eficiente, tinha um alto custo computacional [121]. Por esta razão, vários autores procuraram novas alternativas para melhorar, acelerar ou otimizar este processo [118; 122; 123]. Dentre esses autores, destaca-se Hyvärinen [118] que criou o FastICA, o qual trata-se de um algoritmo baseado no esquema de iteração de ponto-fixa que maximiza a não-gaussianidade como uma medida de impedância estatística. Entre as vantagens do FastICA, pode-se destacar que o método possui desempenho computacional altamente eficiente [124]. A busca rápida dentro da função-objetivo faz com que o FastICA seja mais rápido, como um todo, comparado com o método convencional baseado em declínio de gradiente. O algoritmo

FastICA trata-se do método mais robusto e fácil de implementar, cuja implementação baseia-se em Hyvärinen e Oja [125].

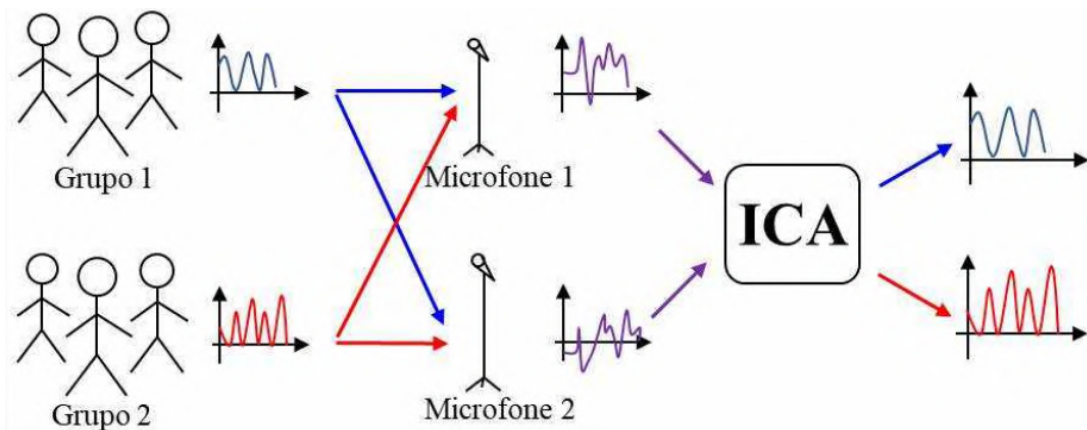
A seguir, baseado em Hyvärinen e Oja [125], é realizada uma breve apresentação sobre o algoritmo ICA, suas restrições e ambiguidades, as etapas de pré-processamento necessárias para estimar as componentes independentes, a relação entre as restrições de não-gaussianidade e independência estatística das componentes independentes e como o modelo ICA utiliza dessas restrições, as medidas da não-gaussianidade utilizadas para estimar o modelo, e, por último, o algoritmo FastICA.

3.6.1 Definição do ICA

O ICA é um dos métodos mais utilizados em *Blind Source Separation* (BSS) destinado a recuperação dos sinais originais (ou fontes) a partir de sinais misturados, sem o conhecimento prévio (ou pouca informação) sobre as fontes e a forma com que os sinais foram misturados [126].

Portanto, pode-se explicitar o tema abordado acima através do exemplo clássico que ilustra o comportamento desta metodologia, conhecido como *Cocktails Party Problem* [121; 127]. Estabelece-se que em uma sala estão dois grupos de pessoas conversando isoladamente entre si, e são colocados dois microfones em posições diferentes e aleatórias para captar os áudios deles, conforme mostrado na Figura 15. Dessa forma, os sinais obtidos pelos microfones são uma mistura das conversas dos dois grupos e a priori nada se sabe a respeito da forma em que foram misturados. Assim, o objetivo central do ICA é separar estes sinais e obter as fontes que os geraram [128].

Figura 15: *Cocktails party* e o ICA.



Fonte: [128].

Sendo assim, para definir o ICA, é utilizado um modelo estatístico de variáveis não observadas diretamente, mas sim inferidas através das propriedades de outras variáveis observadas. Sejam n variáveis aleatórias x_1, \dots, x_n , sendo cada x_i uma combinação linear de n variáveis aleatórias s_1, \dots, s_n , tal que:

$$x_i = a_{i1}s_1 + a_{i2}s_2 + \dots + a_{ij}s_n \quad (9)$$

para todo $i, j = 1, \dots, n$, onde a_{ij} são os coeficientes da i -ésima mistura, referente à j -ésima variável, s_n é o n -ésimo sinal original e x_i é o i -ésimo sinal misturado.

Como uma combinação linear, o modelo também pode ser escrito como:

$$x_i = \sum_{j=1}^n a_{ij}s_j \quad (10)$$

Adotando um modelo matricial e denotando a matriz formada pelos coeficientes de mistura a_{ij} por A , tem-se:

$$x = As \quad (11)$$

O modelo ICA descreve como os dados observados são gerados por meio do processo de mistura das componentes s_i . Para ilustrar o uso do modelo, podem-se considerar duas variáveis aleatórias, x_1 e x_2 , conforme segue:

$$x_1 = a_{11}s_1 + a_{12}s_2 \quad (12)$$

$$x_2 = a_{21}s_1 + a_{22}s_2 \quad (13)$$

Com isso, obtém-se a seguinte forma matricial:

$$\begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{pmatrix} \begin{pmatrix} s_1 \\ s_2 \end{pmatrix} \quad (14)$$

O problema central do ICA é estimar as componentes independentes, partindo do princípio de que os coeficientes de mistura, a_{ij} , não são conhecidos. Diante disso, é preciso estimar uma matriz de separação W , composta por vetores linha w_i , em que $i = 1, \dots, n$, de forma que:

$$s = Wx \quad (15)$$

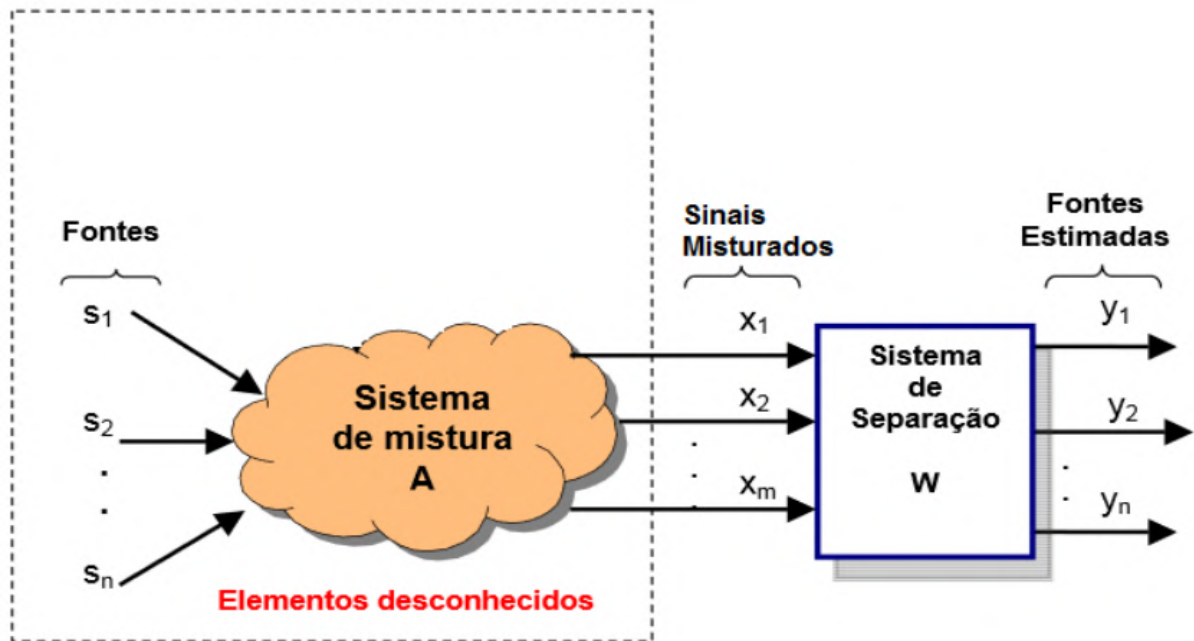
Como a matriz A é desconhecida, não se pode determinar uma matriz W tal que a Equação (15) seja satisfeita, mas pode-se encontrar um W^* tal que:

$$y = W^*x \quad (16)$$

onde $\|s-y\| = \min$.

Na Figura 16 é apresentada uma representação esquemática da aplicação do algoritmo ICA na separação de fontes, conforme as definições descritas anteriormente.

Figura 16: Processo de mistura e separação através do ICA.



Fonte: [129].

3.6.2 Restrições do ICA

Para que o modelo ICA possa ser estimado, é preciso considerar as seguintes restrições:

- É preciso assumir que as componentes independentes sejam estatisticamente independentes. Duas ou mais variáveis aleatórias são ditas estatisticamente independentes se a informação contida nos valores de qualquer uma delas não fornece informação alguma acerca dos valores de qualquer uma das outras. A independência estatística pode ser definida formalmente através das funções densidade de probabilidade das variáveis aleatórias. Sejam $p(y_1, y_2)$ a função densidade de probabilidade conjunta das variáveis aleatórias y_1 e y_2 , e $p_i(y_i)$ a função densidade de probabilidade marginal de y_i , ou seja, a função densidade de probabilidade de y_i quando somente esta é considerada. É dito que y_1 e y_2 são estatisticamente independentes se, e somente se, a função densidade de probabilidade conjunta for favorável da seguinte maneira:


$$p(y_1, y_2) = p_1(y_1)p_2(y_2) \quad (17)$$

Uma propriedade importante da independência de variáveis aleatórias é que, dado duas funções h_1 e h_2 , sempre tem-se:

$$E[h_1(y_1)h_2(y_2)] = E[h_1(y_1)]E[h_2(y_2)] \quad (18)$$

- As componentes independentes precisam ter distribuições de probabilidade não-gaussianas. No modelo ICA, não é assumido que as distribuições de probabilidade das componentes independentes são conhecidas, porém, é preciso assumir que elas sejam não-gaussianas. As distribuições gaussianas são simétricas (Figura 17), logo, não há uma direção de maior concentração de valores que possa ser privilegiada na estimativa do modelo ICA. Isso significa que as distribuições gaussianas possuem cumulantes de alta ordem iguais a zero, mas essas informações de alta ordem são importantes estimativas do modelo ICA. Embora seja assumido que as distribuições das componentes independentes sejam não-gaussianas, certamente as distribuições das misturas observadas serão. Para fins de simplicidade, assume-se que o número de componentes independentes equivale ao número de misturas observadas, ou seja, a matriz de mistura é quadrada e, portanto, pode possuir inversa. Se esse não for o caso, haverão misturas redundantes que poderão ser omitidas no modelo.

Figura 17: Distribuição de probabilidade gaussiana.



Fonte: [125].

3.6.3 Ambiguidades do ICA

Existem algumas ambiguidades decorrentes do modelo ICA básico conforme segue:

- Não é possível determinar as variâncias das componentes independentes. Como tanto A quanto s são desconhecidos, qualquer escalar α multiplicado em alguma das componentes

independentes poderia ser cancelado dividindo a coluna correspondente a_i de A pelo mesmo escalar. Uma solução possível é fixar as energias das variáveis aleatórias, onde um método simples de se fazer isso é considerar que suas variâncias sejam unitárias, isto é, $E[s_i^2] = 1$. Assumir que as componentes independentes possuem variâncias unitárias, é uma das consequências de um dos pré-processamentos realizados antes de estimar o modelo, conforme subseção 3.6.4. É importante notar que mesmo assumindo variância unitária para as fontes, ainda permanece a ambiguidade do sinal que significa multiplicar uma componente por -1, porém, esta ambiguidade é considerada insignificante na maioria dos casos.

- Não se pode determinar a ordem das componentes independentes. Isso novamente se dá por A e s serem desconhecidos. Uma solução para essa ambiguidade é adicionar uma matriz de permutação P e sua inversa no modelo, tal que:

$$x = AP^{-1}Ps \quad (19)$$

de forma que as componentes independentes Ps serão as componentes originais s_i em outra ordem. A matriz AP^{-1} será a nova matriz de mistura a ser estimada.

3.6.4 Pré-Processamento para ICA

Antes de aplicar o algoritmo ICA para a estimativa das componentes independentes, é recomendável realizar algumas etapas de pré-processamento no conjunto de misturas observadas para melhor condicionar as mesmas, tornando a estimativa do modelo mais simples.

3.6.4.1 Centralização

A centralização trata-se do pré-processamento mais básico, embora tenha uma boa contribuição em simplificar a teoria envolvida no modelo ICA e os algoritmos para estimar o modelo. Sem perda de generalidade, pode-se assumir que as componentes independentes e as misturas observadas possuem média zero. Para que isso seja verdade, as misturas observadas passam pela fase de centralização, que significa subtrair das misturas a sua média. Denotando as misturas observadas originais por x , as misturas centralizadas x_c são tais que:

$$x_c = x - E[x] \quad (20)$$

Dessa forma, as componentes independentes também terão média zero já que:

$$E[s] = A^{-1}E[x_c] \quad (21)$$

O modelo continua sendo estimado da mesma forma, pois não há alteração alguma na matriz de mistura. Além disso, após a matriz de mistura ser estimada (considerando que as misturas

observadas passaram pela fase de centralização), a média subtraída pode ser reconstruída adicionando $W^*E[x]$ (lembrando que $W=A^{-1}$ e W^* é uma aproximação ótima de W) às componentes independentes de média zero, ou seja, as componentes independentes que foram estimadas no modelo.

3.6.4.2 Branqueamento

A fase de branqueamento, apesar de ser um pouco mais difícil de ser calculada do que a centralização, ainda é um procedimento simples de ser implementado, além de ajudar a diminuir significativamente a complexidade do problema. Esse pré-processamento é aplicado nas misturas centralizadas e trata-se de uma propriedade mais poderosa, em relação à decorrelação. Duas variáveis aleatórias y_1 e y_2 são decorrelacionadas se sua covariância for igual a zero, ou seja:

$$cov(y_1, y_2) = E[y_1y_2] - E[y_1]E[y_2] = 0 \quad (22)$$

Se duas variáveis aleatórias forem independentes, necessariamente elas serão decorrelacionadas. Essa afirmação pode ser verificada considerando $h_1=y_1$ e $h_2=y_2$ na Equação (18), obtendo:

$$E[y_1y_2] = E[y_1]E[y_2] = 0 \quad (23)$$

que implica em decorrelação das variáveis aleatórias.

Por outro lado, decorrelação não implica independência. Por exemplo, se considerarmos duas variáveis aleatórias discretas com uma distribuição tal que o par possui probabilidade 1/4 para os seguintes pares de valores (0,1), (0,-1), (1,0) e (-1,0), percebe-se que as duas variáveis são decorrelacionadas, porém, a condição da Equação (18) é violada como se pode ver na Equação (24), portanto, y_1 e y_2 não são independentes.

$$E[y_1^2y_2^2] = 0 \neq \frac{1}{4} = E[y_1^2]E[y_2^2] \quad (24)$$

A diferença entre o branqueamento e a decorrelação é que variáveis brancas (como são chamadas as variáveis aleatórias que passaram pelo processo de branqueamento), além de serem decorrelacionadas, possuem variância unitária, ou seja, possuem matriz de covariância igual a matriz identidade, conforme:

$$C_r = E[rr^t] = I \quad (25)$$

O processo de branqueamento consiste em aplicar uma determinada transformação linear em uma variável aleatória X , obtendo, assim, uma nova variável aleatória z , a qual é branca:

$$z = VX \quad (26)$$

Um método popular para realizar o branqueamento é a decomposição por auto-valor da matriz de covariância:

$$C_x = E[xx^t] = MDM^t \quad (27)$$

tal que M é a matriz ortogonal dos auto-vetores associados aos auto-valores da matriz de covariância C_x , e D é a matriz diagonal de auto-valores da matriz de covariância. A matriz de transformação utilizada no branqueamento, geralmente chamada por matriz de branqueamento, é definida por:

$$V = MD^{-1/2}M^t \quad (28)$$

Pela definição do modelo ICA básico, tem-se:

$$z = VAs \quad (29)$$

$$z = A' s \quad (30)$$

A utilidade do branqueamento reside no fato de que a nova matriz de mistura A' é ortogonal, então a estimativa da matriz de mistura se restringe ao espaço de matrizes ortogonais. Ao invés de estimar os n^2 parâmetros da matriz de mistura original, somente é preciso estimar os parâmetros da matriz ortogonal A'^{-1} , o que significa $n(n-1)/2$ parâmetros.


Com o intuito de exemplificar essa propriedade, considera-se duas variáveis aleatórias x_1 e x_2 com distribuições uniformes $p(s_i)$ (Equação (31)), tal que:

$$p(s_i) = \begin{cases} \frac{1}{2\sqrt{3}} & \text{se } s_i \leq \sqrt{3} \\ 0, & \text{caso contrário} \end{cases} \quad (31)$$

Conforme mostrado na Figura 18, escolheu-se os valores da distribuição uniforme de tal forma que a função densidade de probabilidade conjunta das duas variáveis aleatórias fossem propositalmente quadrada.


Após o branqueamento, a função densidade de probabilidade conjunta das variáveis branqueadas é uma versão totalmente rotacionada da função das variáveis originais, conforme mostrado na Figura 19. Isso se dá porque em um espaço bidimensional, uma transformação ortogonal ($z = A' s$) é determinada por um único parâmetro, que é o ângulo da rotação, ou seja, ao invés de estimar todos os quatro parâmetros de uma matriz 2×2 , estima-se somente um parâmetro de rotação, caso as variáveis tenham passado pelo processo de branqueamento.

Figura 18: Função densidade de probabilidade conjunta de x_1 e x_2 .



Fonte: [125].

Figura 19: Função densidade de probabilidade conjunta das variáveis branqueadas.



Fonte: [125].

3.6.5 Não-Gaussianidade e Independência

A seguir será apresentada a relação entre as restrições de não-gaussianidade e independência estatística das componentes independentes, assim como a maneira como o ICA se utiliza dessas restrições para estimar o modelo.

Para componentes independentes com distribuições de probabilidade gaussianas, a matriz de mistura não surte efeito algum nas distribuições das misturas, ou seja, as distribuições são idênticas. Logo, não há meios de se estimar a matriz de mistura tendo somente as informações fornecidas pelas misturas observadas. O mesmo ocorre quando as componentes independentes passam pelo processo de branqueamento.

Por outro lado, se for considerado que as componentes independentes são estatisticamente independentes e não-gaussianas, baseado no teorema do limite central, a técnica ICA é capaz de estimar a matriz de mistura, e, conseqüentemente, recuperar as componentes baseando-se somente nas informações fornecidas pelas misturas observadas. Baseado no teorema do limite central, pode-se dizer que a soma de duas variáveis aleatórias estatisticamente independentes e igualmente distribuídas, geralmente tem uma distribuição que é mais próxima de uma gaussiana que qualquer uma das distribuições das variáveis originais. Assim, o teorema do limite central pode ser utilizado para estimar as componentes independentes conforme descrito a seguir.

Por meio do modelo ICA básico, tem-se:

$$s = A^{-1}x \quad (32)$$

Portanto, para estimar uma das componentes independentes, pode-se considerar uma combinação linear das misturas observadas y , tal que $y = bx$, onde b é um vetor linha a ser determinado. Pelo modelo, tem-se também que $y = bAs$, ou seja, y é uma combinação linear das componentes independentes com o vetor bA . Se denotar esse vetor por q , tem-se:

$$y = bx = qs = \sum_i q_i s_i \quad (33)$$

Se observar a Equação (32) e considerar que b corresponde a uma das linhas de A^{-1} , então a combinação linear bx teria como resultado uma das componentes independentes. Conseqüentemente, se considerar $q = bA$ e b como uma linha da inversa de A , q será necessariamente um vetor com somente um elemento igual a 1 e todos os outros iguais a zero. Se considerar que as componentes independentes são estatisticamente independentes, pelo teorema do limite central, pode-se afirmar que qualquer combinação linear das componentes terá distribuição mais próxima da gaussiana do que as distribuições de qualquer uma das componentes. Portanto, $y = qs$, será sempre mais gaussiana do que qualquer s_i , a menos que qs resulte em uma das componentes independentes.

Se os valores de q e s fossem conhecidos, poderia-se variar o valor de q até que y se iguasse a uma das componentes independentes, mas, na prática, somente os valores das misturas

observadas x são conhecidas. Por outro lado, sabe-se, também, que $qs = bx$, então, ao ser calculado um vetor b que maximize a não-gaussianidade de bx , esse vetor será necessariamente igual ao vetor bA , ou seja, $y = bx = qs$ será equivalente a uma das componentes independentes.

Portanto, a combinação linear $y = bx$ pode ser equivalente a uma das componentes independentes, desde que seja calculado um vetor b que maximize a não-gaussianidade de bx . Dessa forma, na subseção 3.6.6 é apresentado como a não-gaussianidade pode ser medida.

3.6.6 Medidas de Não-Gaussianidade

Para utilizar a não-gaussianidade na estimativa do modelo ICA, é necessária ter uma medida quantitativa da não-gaussianidade de uma variável aleatória Y . Apesar de existirem outros métodos relacionados com não-gaussianidade de variáveis aleatórias que podem ser utilizados para estimar o modelo ICA, como a máxima verossimilhança e informação mútua, serão apresentadas a seguir duas importantes medidas de não-gaussianidade que são a curtose e a negentropia.

3.6.6.1 Curtose

Uma medida clássica de não-gaussianidade é a curtose, o qual a função curtose de uma variável aleatória Y é dada da seguinte forma:

$$kurt(Y) = E[Y^4] - 3(E[Y^2])^2 \quad (34)$$

Assumindo-se que Y possui variância unitária (se a variável for branca, por exemplo), então a função é simplificada da seguinte maneira:

$$kurt(Y) = E[Y^4] - 3 \quad (35)$$

onde a função $kurt$ é uma versão normalizada do momento de quarta ordem $E[Y^4]$.

Usando-se o valor absoluto da curtose, chega-se na medida de não-gaussianidade. O quadrado do valor absoluto da curtose também pode ser utilizado. Para o caso de uma variável gaussiana, o resultado da função curtose é, na maioria das vezes, igual a zero. Para variáveis não-gaussianas, o valor absoluto (ou seu quadrado) da curtose é diferente de zero.

O principal motivo que faz com que a curtose seja largamente utilizada para mensurar a não-gaussianidade de uma variável aleatória é a sua simplicidade, porém, ela possui algumas desvantagens. O fato de não ser uma medida robusta é a maior delas, já que somente algumas amostras de uma variável aleatória podem ter uma maior influência no valor absoluto da curtose em relação a todos as outras amostras.

Por exemplo, para uma variável aleatória com 1.000 amostras entre 0 e 1, com média zero e variância unitária, a curtose é igual a 0. Se algum evento fizer com que apenas uma das amostras altere seu valor para 10, o valor da curtose seria, no mínimo, igual a $10^4/1000 - 3 = 7$ [121].

3.6.6.2 Negentropia

Outra medida de não-gaussianidade é a negentropia, que baseia-se na quantidade de informação teórica de uma variável dada pela entropia diferencial, tratada simplesmente por entropia. A entropia de uma variável pode ser interpretada pelo grau de informação que se pode ter ao observar as variáveis, isto é, quanto mais aleatória for uma variável, maior sua entropia. A entropia H de uma variável aleatória Y com função densidade de probabilidade $p_Y(\eta)$ é definida da seguinte forma:

$$H(Y) = - \int p_Y(\eta) \log(p_Y) d\eta \quad (36)$$

Um resultado fundamental da teoria da informação é que uma variável gaussiana possui a maior entropia dentre todas as variáveis aleatórias de igual variância. Isso significa que distribuições gaussianas são as mais aleatórias e desestruturadas dentre todas as distribuições, ou seja, pode-se utilizar a entropia como medida de não-gaussianidade.

A negentropia é uma versão normalizada da entropia, de tal forma que a negentropia é sempre não negativa e zero para uma variável gaussiana. A negentropia J de uma variável aleatória Y é definida da seguinte maneira:

$$J(Y) = H(Y_{gauss}) - H(Y) \quad (37)$$

onde Y_{gauss} é uma variável aleatória com distribuição gaussiana e mesma matriz de correlação (e portanto, covariância) que Y .

A negentropia é uma medida de não-gaussianidade bem justificada pela teoria estatística e é por vezes considerada um estimador ótimo de não-gaussianidade. O problema é que a negentropia é uma medida de difícil implementação computacional, além de ser necessário ter conhecimento (ou ao menos uma estimativa) da função densidade de probabilidade. A seguir são apresentadas algumas aproximações da negentropia que tornam a medida mais praticável.

O primeiro método de aproximação é utilizando cumulantes de alta-ordem. Dessa forma, tem-se a seguinte aproximação:

$$J(Y) \approx \frac{1}{12} E[Y^3]^2 + \frac{1}{48} kurt(Y)^2 \quad (38)$$

Como se pode constatar na Equação (38), a aproximação usando cumulantes de alta-ordem levam ao uso da curtose apresentada na subseção 3.6.6.1. Como consequência disso, essa aproximação da negentropia não é robusta, assim como a curtose.

Um método mais sofisticado é utilizar esperanças de funções não-quadráticas. Nesse caso, pode-se utilizar quaisquer duas funções não-quadráticas G_1 e G_2 , tal que G_1 é ímpar e G_2 é par. Dessa forma chega-se a seguinte aproximação:

$$J(Y) \approx k_1(E[G_1(Y)])^2 + k_2(E[G_2(Y)] - E[G_2(v)])^2 \quad (39)$$

onde k_1 e k_2 são constantes positivas e v é uma variável aleatória gaussiana com média zero e variância unitária.

Caso se utilize somente uma função não-quadrática G , a aproximação se torna a seguinte:

$$J(Y) \propto [E[G(Y)] - E[G(v)]]^2 \quad (40)$$

A questão, então, é centrada na escolha de uma função não-quadrática G . Uma função G que não cresça rapidamente resulta em estimadores mais robustos. As seguintes funções preenchem tal requisito:

$$G_1(Y) = \frac{1}{a_1} \log(\cosh(a_1 Y)) \quad (41)$$

$$G_2(Y) = -\exp\left(-\frac{Y^2}{2}\right) \quad (42)$$

onde a_1 é uma constante, tal que $1 \leq a_1 \leq 2$.

3.6.7 Algoritmo FastICA

O algoritmo FastICA [118] é baseado em iteração de ponto-fixa que maximiza a não-gaussianidade de wz (máximo local), onde z são as misturas observadas centralizadas e brancas, e w é um vetor de coeficientes de separação. É importante notar que o algoritmo encontra somente uma componente independente e para estimar todas as componentes é preciso executar o algoritmo para cada componente.

O algoritmo FastICA pode ser derivado tanto para o caso de maximizar a não-gaussianidade utilizando o método curtose quanto o método negentropia. A diferença básica entre os algoritmos será a iteração que calculará o novo w [121; 125]. Abaixo segue o algoritmo utilizando o método negentropia:

- 1. Escolher um vetor de pesos w inicial (por exemplo, aleatoriamente)
- 2. $w^* \leftarrow E[zg(w^t z)] - E[g'(w^t z)]w$
- 3. $w \leftarrow \frac{w^*}{\|w^*\|}$
- 4. Se não convergiu, voltar ao passo 2.

As derivadas das funções descritas nas Equações (41) e (42) podem ser utilizadas como função g , conforme Equações (43) e (44), já que resultam em boas aproximações de negentropia. Além dessas funções, pode-se utilizar também a derivada do momento de quarta ordem, que resultará no método curtose, conforme Equação (45).

$$g_1(y) = \tanh(a_1 y) \quad (43)$$

$$g_2(y) = y \exp\left(-\frac{y^2}{2}\right) \quad (44)$$

$$g_3(y) = y^3 \quad (45)$$

As derivadas g' são dadas por:

$$g'_1(y) = a_1(1 - \tanh^2(a_1 y)) \quad (46)$$

$$g'_2(y) = (1 - y^2) \exp\left(-\frac{y^2}{2}\right) \quad (47)$$

$$g'_3(y) = 3y^2 \quad (48)$$

Para a iteração utilizando a curtose, o algoritmo é o mesmo que a iteração utilizando a negentropia com uma única modificação no passo 2 que é dada da seguinte forma:

$$w^* \leftarrow E[z(w^t z)^3] - 3w \quad (49)$$

A seguir é apresentada algumas propriedades do algoritmo FastICA:

- A convergência é cúbica (ou pelo menos quadrática), sob a suposição do modelo de dados ICA. Isto contrasta com outros algoritmos ICA baseados em métodos de gradiente descendente, onde a convergência é somente linear. Isto significa uma rápida convergência para o algoritmo FastICA. Diversos experimentos em dados em tempo real comprovam esta propriedade;
- Ao contrário dos algoritmos baseados em gradiente, não há nenhum parâmetro de taxa de aprendizagem para escolher, o que torna o FastICA mais simples;
- O algoritmo encontra diretamente as componentes independentes de praticamente qualquer distribuição não-gaussiana usando qualquer medida de não-linearidade, ao contrário de muitos algoritmos, onde a medida de não-linearidade precisa ser escolhida especificamente;
- O desempenho do algoritmo pode ser melhorado com a escolha adequada de uma medida de não-linearidade;
- As componentes independentes podem ser estimadas uma a uma, o que diminui o custo computacional em casos onde somente algumas das componentes independentes precisam ser estimadas;
- O algoritmo FastICA possui outras vantagens como o paralelismo, é distribuído, é computacionalmente simples e requer pouco espaço de memória.

Como visto anteriormente, o algoritmo FastICA apresentado calcula somente uma componente independente. É possível calcular todas as componentes executando o FastICA um número de vezes igual ao número de componentes independentes, além de variar o vetor w inicial, porém, existe o risco de um mesmo máximo local ser calculado mais de uma vez. Para eliminar este problema, é utilizada a propriedade de que os vetores w_i são ortogonais no espaço branco. Isto se dá devido a ortogonalidade da nova matriz de mistura A' obtida após o branqueamento. Como $A'^{-1} = A'^t$, os vetores w_i são as linhas de A'^{-1} e as colunas de A'^t , portanto, para evitar que um mesmo máximo local seja calculado mais de uma vez, é preciso ortogonalizar os vetores w_i a cada iteração do algoritmo.

4 MATERIAIS E MÉTODOS

Neste capítulo são apresentados detalhes sobre o desenvolvimento do método de processamento de dados de ondas guiadas para a detecção e quantificação de danos e sobre os testes experimentais realizados para avaliar os resultados da aplicação do método. O capítulo é dividido em duas seções principais, onde na primeira são descritos os procedimentos para a realização do ensaio experimental e na segunda é apresentado o método desenvolvido.

4.1 Ensaio Experimental

Nesta seção são apresentados a construção do painel de testes e dos transdutores piezoelétricos, a instalação do arranjo de transdutores no painel, a aquisição dos sinais experimentais e a inserção dos danos no painel.


4.1.1 Projeto e Construção do Painel de Testes e Transdutores Piezoelétricos

Inicialmente, construiu-se um painel com o intuito de reproduzir uma região do tanque de armazenamento de um FPSO chamada de antepara longitudinal, o qual refere-se a região a ser inspecionada. A antepara longitudinal trata-se de uma divisória posicionada perpendicularmente ao fundo do tanque, que separa os tanques de armazenamento e de lastro e é constituída por placas reforçadas com enrijecedores que são soldados entre si.

Na Figura 20a é apresentado o desenho do painel utilizado nos ensaios experimentais com a indicação dos principais componentes, e na Figura 20b é mostrado a imagem do painel após a sua fabricação. Para a fabricação dos componentes, utilizou-se o material aço carbono ASTM A36 e realizou-se a união entre os componentes por meio de cordões contínuos de solda em ambos os lados das espessuras. O painel é constituído por: uma chapa principal com 6 m de comprimento, 2,5 m de largura e 19,05 mm de espessura; seis reforços transversais com dimensões de 2,5 m de comprimento, 0,4 m de altura e 12 mm de espessura, espaçados com 0,9 m de distância entre cada reforço; e um reforço longitudinal de 6 m de comprimento, 0,6 m de altura e 15,88 mm de espessura, posicionado a uma distância de 0,85 m de uma das extremidades da chapa principal.

Figura 20: Configuração experimental do painel.

(a) Desenho do painel com a indicação dos principais componentes.




(b) Imagem do painel após a sua fabricação.



Fonte: Próprio Autor.

As dimensões e geometrias do painel são semelhantes às utilizadas em estruturas reais de tanques de armazenamento de FPSOs. Os reforços transversais foram construídos a partir de uma chapa dobrada, formando um perfil L, com o intuito de reproduzir o perfil bulbo tipo HP 400x12, mostrado na Figura 21, o qual trata-se de um tipo de perfil estrutural utilizado na construção naval. Conforme mostrado na Figura 20b, o painel de testes foi pintado com tinta epóxi e ficou posicionado no pátio do laboratório, exposto a intempéries e permanecendo desprotegido durante todo o ensaio.

Figura 21: Desenho esquemático do perfil bulbo tipo HP 400x12 com a especificação das dimensões em mm.



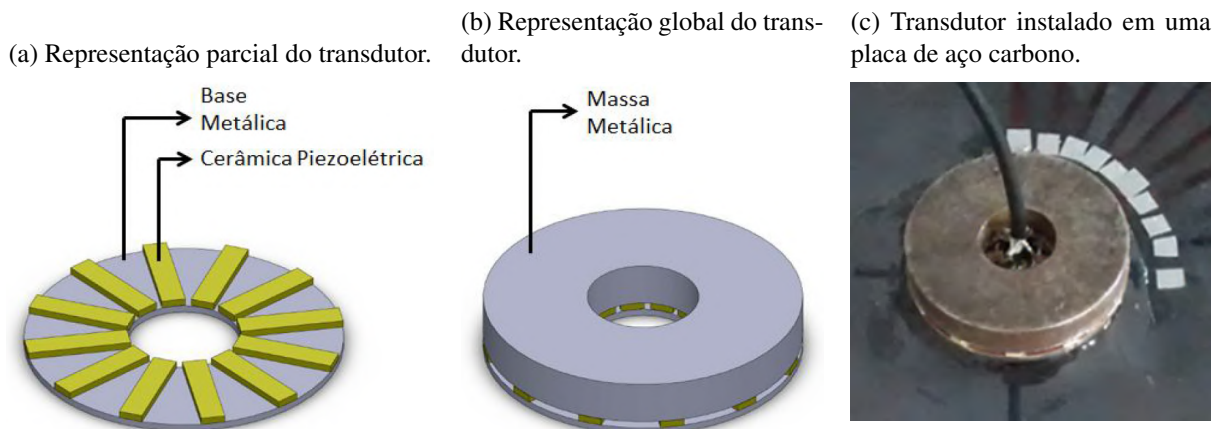
Fonte: Adaptado de British Steel [130].

O transdutor construído e utilizado nesse trabalho trata-se de um transdutor de modo SH_0 omnidirecional o qual foi desenvolvido por Menin e Clarke [71], onde pode ser encontrado maiores detalhes sobre o seu desenvolvimento. O conceito do transdutor baseou-se em um arranjo de elementos cerâmicos piezoelétricos de geometria padronizada. O intuito do desenvolvimento desse transdutor foi de minimizar a emissão dos modos de onda de Lamb durante a excitação

e também maximizar a omnidirecionalidade do modo SH_0 gerado. O transdutor foi planejado para emitir o modo SH_0 omnidirecional para operar em uma faixa de frequências relativamente baixas, entre 20 kHz e 100 kHz. Esse arranjo foi construído posicionando-se as cerâmicas simetricamente em uma base circular com o intuito de gerar um movimento circular através da base para que a mesma transmita tensões torcionais até a estrutura, gerando o modo SH_0 . Quando um campo elétrico é aplicado entre as superfícies maiores desses elementos piezoelétricos, os mesmos mudam de forma, produzindo um movimento de cisalhamento.

Nas Figuras 22a e 22b é mostrado a configuração do transdutor conforme apresentado em Menin [79]. O transdutor consiste em um arranjo circular composto por doze elementos piezoelétricos de cisalhamento com forma retangular prismática e polarizados na direção transversal. O arranjo circular de elementos piezoelétricos igualmente espaçados é posicionado sobre uma base metálica, e sobre o arranjo piezoelétrico é posicionada uma massa metálica. A base metálica influenciará na relação SH_0/A_0 do transdutor em função da frequência de operação. Já a massa metálica influenciará na amplitude da resposta gerada pelo transdutor. Quanto as dimensões geométricas, as cerâmicas piezoelétricas possuem comprimento de 13 mm, largura de 3 mm e espessura de 1 mm. Já a base e a massa metálica possuem espessuras de 2 mm e 6,35 mm respectivamente, e ambas possuem um furo central de diâmetro 14 mm e diâmetro externo de 40 mm. A altura total do transdutor após a união entre os componentes e o material laminado com solda e adesivo epóxi é de aproximadamente 10 mm.

Figura 22: Configuração e instalação do transdutor.




Fonte: [71; 79].

A construção dos transdutores utilizados nesse trabalho baseou-se em Menin e Clarke [71], onde é descrito os componentes e materiais necessários para a obtenção do transdutor mostrado na Figura 22c. O material piezoelétrico considerado foi a cerâmica PZ27. A base e a massa metálica foram construídas em aço carbono ASTM A36 e o acoplamento entre as partes metálicas e o arranjo piezoelétrico foi realizado por meio de um material laminado utilizado na fabricação de placa de circuito impresso (PCB) flexível, o qual trata-se de uma folha de material compósito

composta por uma camada de cobre e outra de compósito de fibra de vidro e resina epóxi. Os elementos piezoelétricos foram fixados através de um processo de solda na face de cobre do material laminado. Já a base e a massa metálica foram fixadas através de adesivo epóxi na face de compósito do material laminado, e para realizar a fixação do transdutor no painel de testes, também considerou-se o adesivo epóxi.

Com o intuito de oferecer proteção contra condições climáticas adversas, adaptou-se o transdutor mostrado na Figura 22 com o invólucro metálico mostrado na Figura 23. Previu-se, neste invólucro, um conector do tipo *Bayonet Neil Concelman* (BNC) para a conexão do equipamento de aquisição, e uma tampa para a sua proteção, mostrado na Figura 23a. Na Figura 23b é indicado os principais componentes do invólucro além do próprio transdutor. A tampa, fabricada em liga de alumínio, é fixada no corpo, também fabricado em liga de alumínio, através de parafusos e para garantir a vedação utilizou-se um anel do tipo O-ring. Na parte inferior do corpo, uniu-se, com cola de contato, um anel fabricado a partir de um lençol de borracha nitrílica (NBR) e uma base fabricada em aço carbono ASTM A36 com 1 mm de espessura. O transdutor localiza-se no interior do corpo e é unido na superfície dessa base metálica através de adesivo epóxi. Por último, na Figura 23c, é mostrado o transdutor encapsulado após a sua fabricação, o qual possui dimensões de 53 mm de altura total e 56 mm de diâmetro.

Figura 23: Projeto e fabricação do invólucro do transdutor.



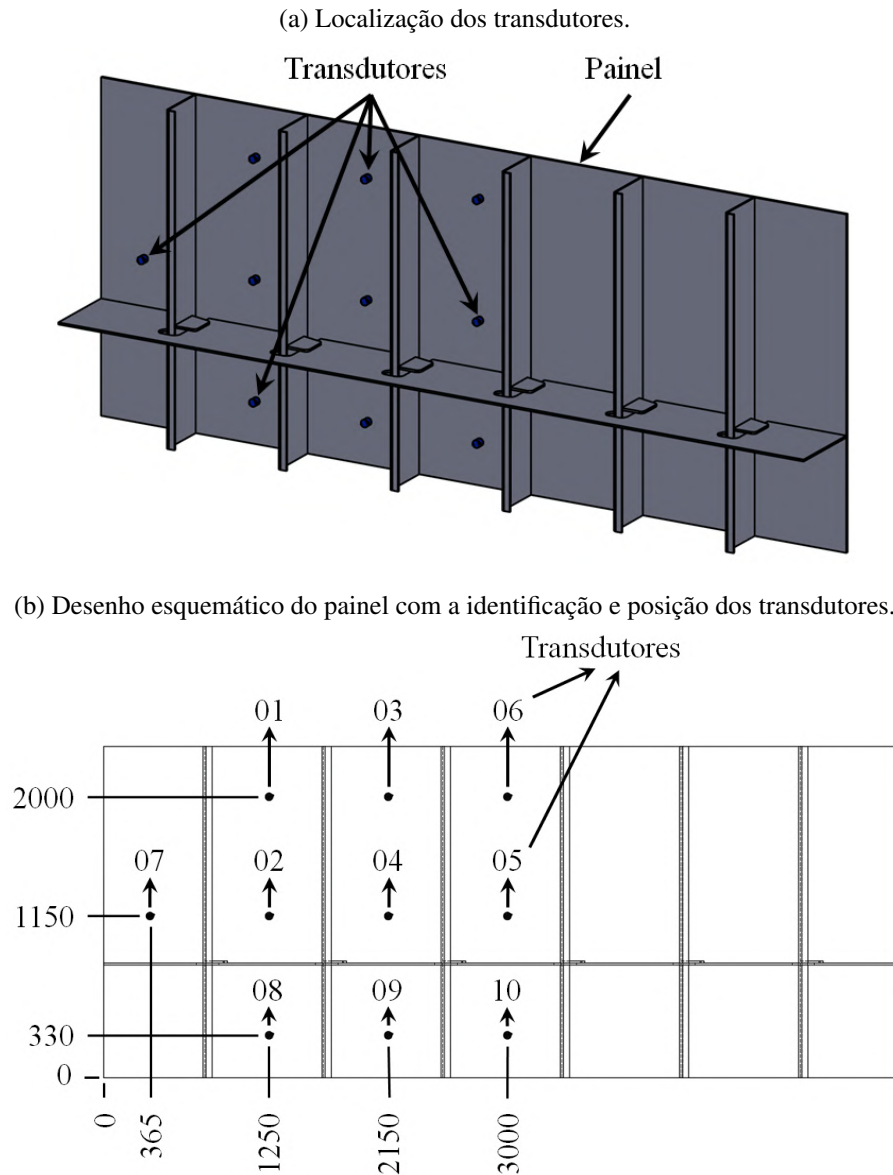
Fonte: Adaptado de Clarke *et al.* [131].

4.1.2 Instalação do Arranjo de Transdutores Piezoelétricos

Posteriormente à construção do painel de testes e dos transdutores piezoelétricos, realizou-se a instalação permanente de um conjunto de transdutores encapsulados no painel. Na Figura 24

é apresentado, através de desenhos esquemáticos, a configuração experimental do painel instrumentado com um arranjo composto por dez transdutores piezoelétricos distribuídos na superfície da chapa principal do painel de testes. Para o posicionamento dos transdutores, considerou-se o alinhamento em ângulos retos tanto na vertical quanto na horizontal, cujas dimensões das posições de cada transdutor estão indicadas no desenho esquemático da Figura 24b. Como pode ser visto na Figura 24, o posicionamento dos transdutores foi planejado para estarem distribuídos entre os perfis estruturais. A posição dos transdutores foi definida de acordo com um estudo de avaliação de atenuação e alcance do sinal emitido pelo transdutor realizado por Menin [91], o qual estimou a distância que o sinal poderia se propagar antes da amplitude do sinal diminuir abaixo de um valor de SNR pré-estabelecido.

Figura 24: Configuração experimental dos transdutores.



Fonte: Próprio Autor.

Para realizar o acoplamento dos transdutores na chapa principal da placa de testes, utilizou-se um adesivo epóxi e um suporte magnético, mostrado na Figura 25a, para garantir o posicionamento do transdutor e a completa cura do adesivo. Na Figura 25b é mostrado o transdutor com a tampa fechada já instalado no painel. Já na Figura 25c é mostrado a instalação e fixação do sensor de temperatura Pt100 para a realização do monitoramento da temperatura durante as medições. Por último, na Figura 25d, é mostrado os transdutores já em operação com os cabos conectados.

Figura 25: Instalação dos transdutores piezoelétricos e sensor de temperatura no painel.

(a) Posicionamento e acoplamento do transdutor no painel.



(b) Transdutor após a sua instalação.



(c) Sensor de temperatura após a sua instalação.



(d) Transdutores piezoelétricos em operação.



Fonte: Próprio Autor.

4.1.3 Aquisição dos Sinais Experimentais

Para interrogar a estrutura, usou-se o modo de onda guiada SH_0 , descrito na seção 3.3, o qual trata-se de um modo não dispersivo que possui velocidade de grupo de 3260 m/s. Inicialmente, realizou-se um conjunto de medidas de *baseline* (0% de perda de espessura) para todas as combinações de emissão-recepção (*pitch-catch*) entre os pares de transdutores instalados,

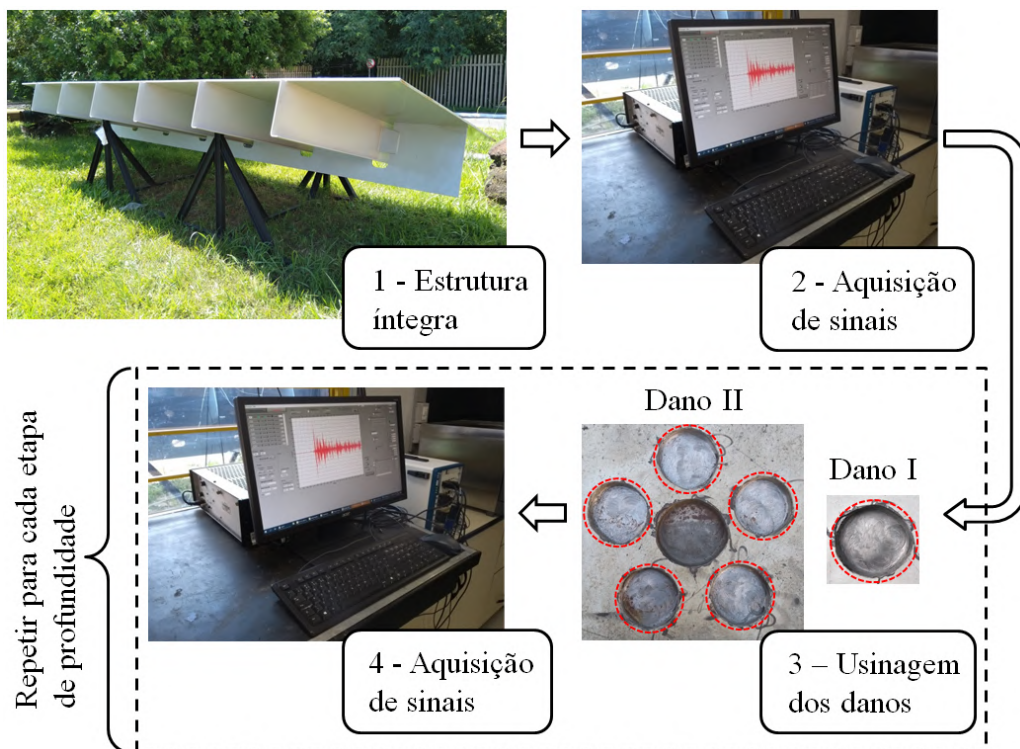
de forma que enquanto um dos transdutores operava como emissor, os demais operavam como receptores simultaneamente, obtendo, assim, um banco de dados de *baseline* formado por um conjunto de dados distinto para cada par de sensores.

Para cada par de sensores, foi adquirido os sinais de *baseline* em uma faixa de temperaturas de 5° C até 39° C. Essa abordagem levou a um número desigual de sinais para cada par de sensores devido às condições climáticas, pois iniciou-se a coleta a partir do transdutor 01 como emissor. A partir do transdutor 01, cada transdutor operou sequencialmente como emissor enquanto os demais operavam como receptores simultaneamente. Dessa forma, a partir das emissões realizadas pelos transdutores de 01 a 10, obteve-se 73, 202, 250, 212, 216, 220, 76, 64, 78 e 88 sinais de *baseline*, respectivamente.

Após a aquisição dos sinais de *baseline*, reproduziu-se os danos I e II no painel, mostrados na Figura 29 na próxima subseção, em seis níveis de profundidade, cujas dimensões e profundidades são apresentadas nas Tabelas 2 e 3 na próxima subseção, com o intuito de representar danos por corrosão. Para cada nível de profundidade de dano, realizou-se um teste de onda guiada dentro da faixa de temperatura dos sinais de *baseline*.

Na Figura 26 é apresentado o fluxo de trabalho esquemático das etapas de aquisição de dados da estrutura sem dano e para cada nível de profundidade dos danos I e II. A realização das medidas de *baseline*, usinagem dos danos, e realização das medidas de cada profundidade dos danos levou aproximadamente 60 dias.

Figura 26: Fluxograma do processo de aquisição de dados da estrutura íntegra e danificada.




Fonte: Próprio Autor.

Todos os transdutores foram excitados usando um gerador de forma de onda arbitrária *National Instruments PXIe-5451* e uma fonte amplificadora *Krohn-Hite 7500*. Os sinais de ondas guiadas foram adquiridos usando um osciloscópio *PXI-5105* da *National Instruments*. Utilizou-se, nos testes, 1 MHz para a frequência de amostragem e realizou-se 50 médias em cada aquisição para reduzir a variação causada pelo ruído branco nos dados registrados. Todos os sinais foram pré-processados com um filtro *Butterworth* passa-banda para uma banda de frequências em um intervalo de 25% a 150% da frequência central do sinal emitido e janelados para remover o *cross-talk*. Os equipamentos utilizados para a geração e aquisição dos sinais são mostrados na Figura 27.

A forma de onda considerada para as medições foi do tipo *toneburst* com frequência central de 30 kHz a 80 kHz em intervalos de 5 kHz, e número de ciclos para cada sinal *toneburst* condicionado de acordo com a frequência central de emissão, conforme mostrado na Tabela 1. Esta variação no número de ciclos é realizada para evitar uma grande diferença na largura da banda do sinal, e, conseqüentemente, na energia do pacote emitido para cada frequência.

Figura 27: Equipamentos utilizados para aquisição dos sinais experimentais no painel.



Fonte: Próprio Autor.

Tabela 1: Número de ciclos do sinal *toneburst* para cada frequência de emissão.

Frequência central da <i>toneburst</i> (kHz)	Número de ciclos do sinal	Frequência central da <i>toneburst</i> (kHz)	Número de ciclos do sinal
30	4	60	7
35	4	65	7
40	5	70	8
45	5	75	8
50	6	80	9
55	6	-	-


Fonte: Próprio Autor.

4.1.4 Inserção dos Danos no Painel

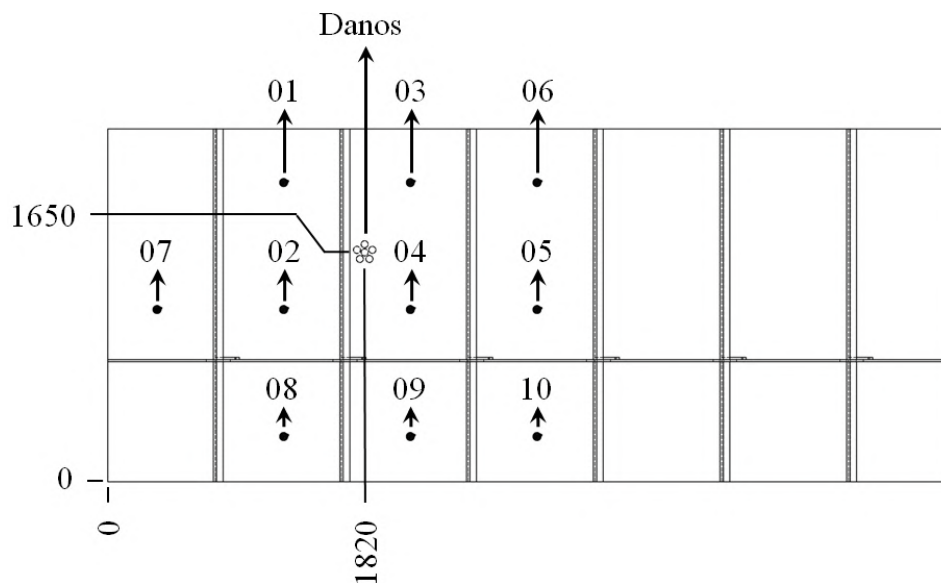
Realizou-se o teste do método para detecção e quantificação de perdas de espessura através da inserção de dois danos distintos. Para garantir o controle do avanço de remoção de material, utilizou-se uma fresa com acoplamento magnético para realizar a usinagem de ambos os danos. A localização e a posição dos danos são mostrados na Figura 28 e suas dimensões em cada estágio de profundidade são mostradas nas Tabelas 2 e 3 para os danos I e II, respectivamente.

Figura 28: Configuração experimental dos danos.

(a) Localização dos danos.



(b) Desenho esquemático do painel com a identificação e posição dos danos.



Fonte: Próprio Autor.

Tabela 2: Dimensões do dano I para cada etapa de profundidade.

	Diâmetro (mm)	Redução de espessura (%)	Profundidade do dano (mm)
Nível 1	50	10	1,9
Nível 2	50	20	3,8
Nível 3	50	30	5,7
Nível 4	50	40	7,6
Nível 5	50	50	9,5
Nível 6	50	60	11,4

Fonte: Próprio Autor.


Tabela 3: Dimensões do dano II para cada etapa de profundidade.

	Diâmetro (mm) Central / Entorno	Redução de espessura (%) Central / Entorno	Profundidade do dano (mm) Central / Entorno
Nível 1	50 / 45	60 / 10	11,4 / 1,9
Nível 2	50 / 45	60 / 20	11,4 / 3,8
Nível 3	50 / 45	60 / 30	11,4 / 5,7
Nível 4	50 / 45	60 / 40	11,4 / 7,6
Nível 5	50 / 45	60 / 50	11,4 / 9,5
Nível 6	50 / 45	60 / 60	11,4 / 11,4

Fonte: Próprio Autor.

Figura 29: Defeitos introduzidos no painel.

(a) Dano I.



(b) Dano II.



Fonte: Próprio Autor.

O dano I, mostrado na Figura 29a, trata-se de um rebaixo circular usinado com diâmetro de 50 mm em seis estágios de profundidade, iniciando com 1,9 mm de profundidade (10% de perda de espessura) até 11,4 mm de profundidade (60% de perda de espessura). Já o dano II,

mostrado na Figura 29b, trata-se de cinco rebaxos circulares usinados no entorno do dano I com diâmetro de 45 mm em seis estágios de profundidade, iniciando com 1,9 mm de profundidade (10% de perda de espessura) até 11,4 mm de profundidade (60% de perda de espessura).

4.2 Metodologia para Detecção e Quantificação de Danos

O método proposto utiliza o algoritmo ICA, apresentado em Bertoldi *et al.* [132], para reduzir a dimensão dos dados do teste de ondas guiadas, o qual é implementado através da biblioteca de código aberto chamada *scikit-learn* [133] usando o algoritmo FastICA. A partir dos dados reduzidos, utilizou-se uma abordagem baseada na detecção de *outliers* para identificar a componente independente referente ao dano de forma automática.

Para isso, primeiramente é montado um conjunto de dados a partir do banco de dados de *baseline*, onde os dados são selecionados de forma aleatória e sem reposição, formando o primeiro conjunto de dados. Em seguida é montado o segundo conjunto de dados, o qual é formado pelo primeiro conjunto de dados e um sinal adicionado em uma posição aleatória entre os demais sinais de *baseline*. A seleção dos dados de forma aleatória e sem reposição fornece exatidão e eficácia à amostragem, onde todos os elementos da população possuem a mesma probabilidade de pertencerem à amostra. Nos testes realizados em laboratório, o sinal adicionado em uma posição aleatória no segundo conjunto de dados trata-se de um sinal conhecido, que pode ser um sinal de *baseline*, diferente dos demais sinais do conjunto de dados, ou um sinal de dano relacionado a um determinado nível de profundidade.

Após a redução dimensional dos dados, as componentes dos dois conjuntos de dados são relacionadas entre si através do valor máximo da correlação cruzada. Assim, a componente relacionada ao dano do segundo conjunto tenderá a não estar vinculada, pois deverá ter menos similaridade com as componentes do primeiro conjunto. Utilizou-se o valor máximo da correlação cruzada como um detector de *outliers* para automatizar a identificação da componente do dano.

Finalmente, repetiu-se esse processo várias vezes com a finalidade de obter uma estimativa do erro. Dessa forma, foi possível calcular a acurácia e os erros (erros tipo I e II, conforme mostrado na Tabela 4) da detecção de danos a partir de cálculos percentuais e calcular o SNR das componentes *outliers* para quantificar o dano. Para calcular as taxas de acurácia e erros considerou-se as Equações (50), (51), (52) e (53) e para calcular o SNR considerou-se a Equação (54). Por último, um fluxograma esquemático do processo é apresentado na Figura 30.

$$A_{ecd} = \frac{(N_{ra} - N_{ndd})}{N_{ra}} 100(\%) \quad (50)$$

$$E_I = 100(\%) - A_{ecd} \quad (51)$$

$$A_{esd} = \frac{(N_{ra} - N_{dd})}{N_{ra}} 100(\%) \quad (52)$$

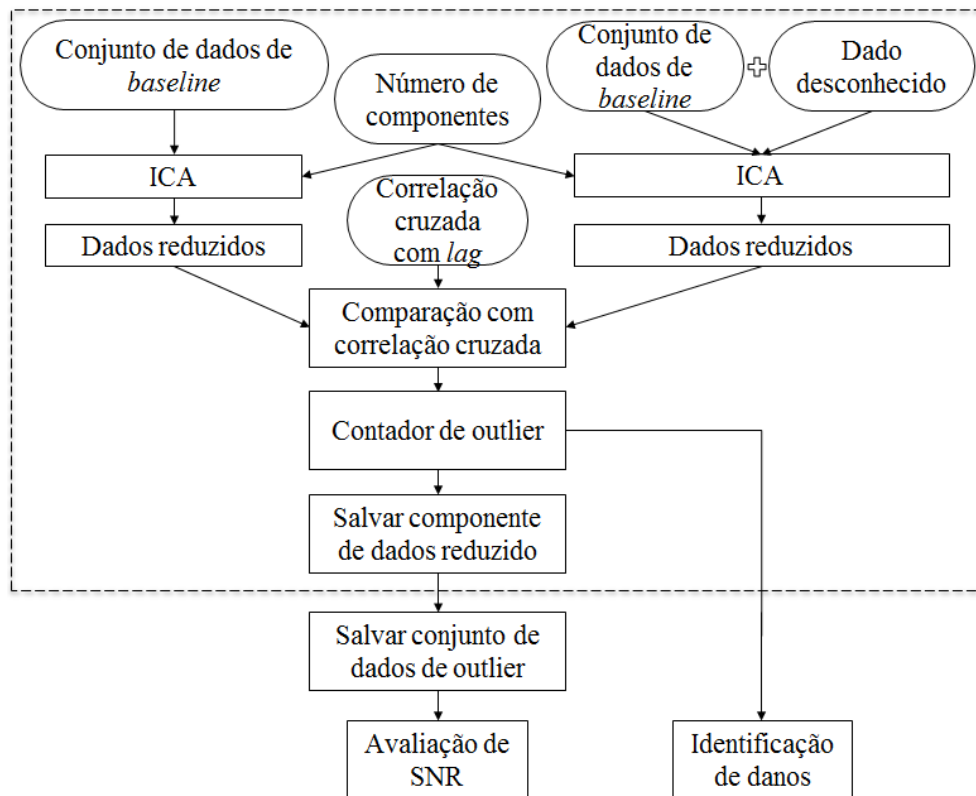
$$E_{II} = 100(\%) - A_{esd} \quad (53)$$

onde A_{ecd} é a taxa de acurácia da estrutura com dano, N_{ra} é o número de realizações aleatórias, N_{ndd} é o número de vezes que não detectou a presença de dano existente, E_I é a taxa de erro do tipo I, A_{esd} é a taxa de acurácia da estrutura sem dano, N_{dd} é o número de vezes que detectou a presença de dano que não existe e E_{II} é a taxa de erro do tipo II.

$$SNR = \frac{v_{max}}{v_{med}} \quad (54)$$

onde SNR é a relação sinal-ruído, v_{max} é o valor máximo do vetor da componente e v_{med} é o valor médio do vetor da componente.

Figura 30: Fluxograma do processo de aplicação do algoritmo orientado a dados para detecção e quantificação de danos.



Fonte: Próprio Autor.

Para quantificar as taxas de erro, a partir dos cálculos dos erros de detecção de danos, seguiu-se a matriz de confusão mostrada na Tabela 4. Considera-se acurácia quando há um defeito e o método o detecta e quando não há defeito e o método não o detecta. Já os falsos positivos são chamados de erro tipo I e são quando o método não conseguiu classificar um defeito existente.

Por último, os verdadeiros negativos são erros do tipo II e ocorrem quando o método classifica um defeito que não existe. Em um caso de aplicação do mundo real, não há informações sobre a integridade da estrutura, ou seja, o sinal adicionado é de uma condição desconhecida, podendo representar algum dano ou não. No entanto, em testes de laboratório é possível identificar se o sinal está relacionado a condição de *baseline* ou não.

Tabela 4: Tipo de erros.

	Negativo	Positivo
Falso	Acurácia	Tipo I
Verdadeiro	Tipo II	Acurácia

Fonte: Próprio Autor.


Definiu-se uma nomenclatura formada por letras e números para cada par de sensores com o intuito de rotular os dados para alimentar o modelo de detector de *outlier*. Por exemplo, o par de sensores designado como e1r2 é composto pelo transdutor 01 como emissor do sinal e o transdutor 02 como receptor do sinal juntamente com os demais transdutores. O arranjo mostrado na Figura 24b, composto por dez transdutores, permite noventa possíveis combinações de pares de sensores emissores e receptores. Conforme mostrado na Figura 24b, dependendo do par de sensores, pode haver um ou dois elementos estruturais soldados entre os sensores e o dano e, em alguns casos, tanto o elemento estrutural quanto o dano não estão localizados entre os sensores. Além disso, dependendo do par de sensores, o dano pode estar mais próximo do sensor emissor ou mais próximo do sensor receptor.

O processo de aplicação do algoritmo orientado a dados é dividido em duas partes: a primeira parte é representada pelas etapas que estão dentro do retângulo de linhas tracejadas do fluxograma mostrado na Figura 30; e a segunda parte é representada pelas etapas que estão fora do retângulo de linhas tracejadas do fluxograma. Para realizar os cálculos da acurácia e dos erros do tipo I e II da detecção de danos e os cálculos do SNR das componentes *outliers* para quantificar o dano, a primeira parte do processo deve ser repetida N vezes antes da avaliação da segunda parte.


A primeira parte do processo visa comparar dois conjuntos de dados diferentes: um composto pela condição da estrutura íntegra; e o outro é a mesma condição da estrutura íntegra mais um sinal desconhecido. Para construir os conjuntos de dados, procedeu-se da seguinte forma: retirou-se amostras aleatórias (usando uma lei uniforme e sem reposição) de um conjunto de dados e empilhou-se as mesmas para construir uma matriz de dados. Para manter a mesma metodologia, os dados desconhecidos (mais um sinal) são adicionados e inseridos aleatoriamente na matriz de dados. O número de sinais de *baseline* usados nos testes baseou-se no número de sinais experimentais coletados para cada transdutor emissor. Na Figura 31 é mostrado um exemplo da matriz de dados do conjunto de dados do par de sensores e1r2 com 70 sinais de *baseline* e frequência central de 45 kHz. A Figura 31 mostra também a variação da temperatura.

Figura 31: Distância e temperatura medida *versus* sinais de *baseline*.

(a) Distância e temperatura medida *versus* sinais de *baseline* para o par de sensores e1r2.



(b) Distância e temperatura medida *versus* sinais de *baseline* e sinal do defeito para o par de sensores e1r2.



Fonte: Próprio Autor.

Espera-se que quando uma "nova informação estatística", ou seja, um defeito for adicionado ao conjunto de dados, novas componentes de pesos do ICA sejam criadas. Por outro lado, se não houver defeito, não haverá "novas informações estatísticas" e não haverá a necessidade de novas componentes de pesos do ICA. Os pesos determinam a contribuição de cada sinal original para uma dada componente independente. A adição de uma "nova informação estatística" pode impactar na estimativa dos pesos e, conseqüentemente, alterar a interpretação através de uma

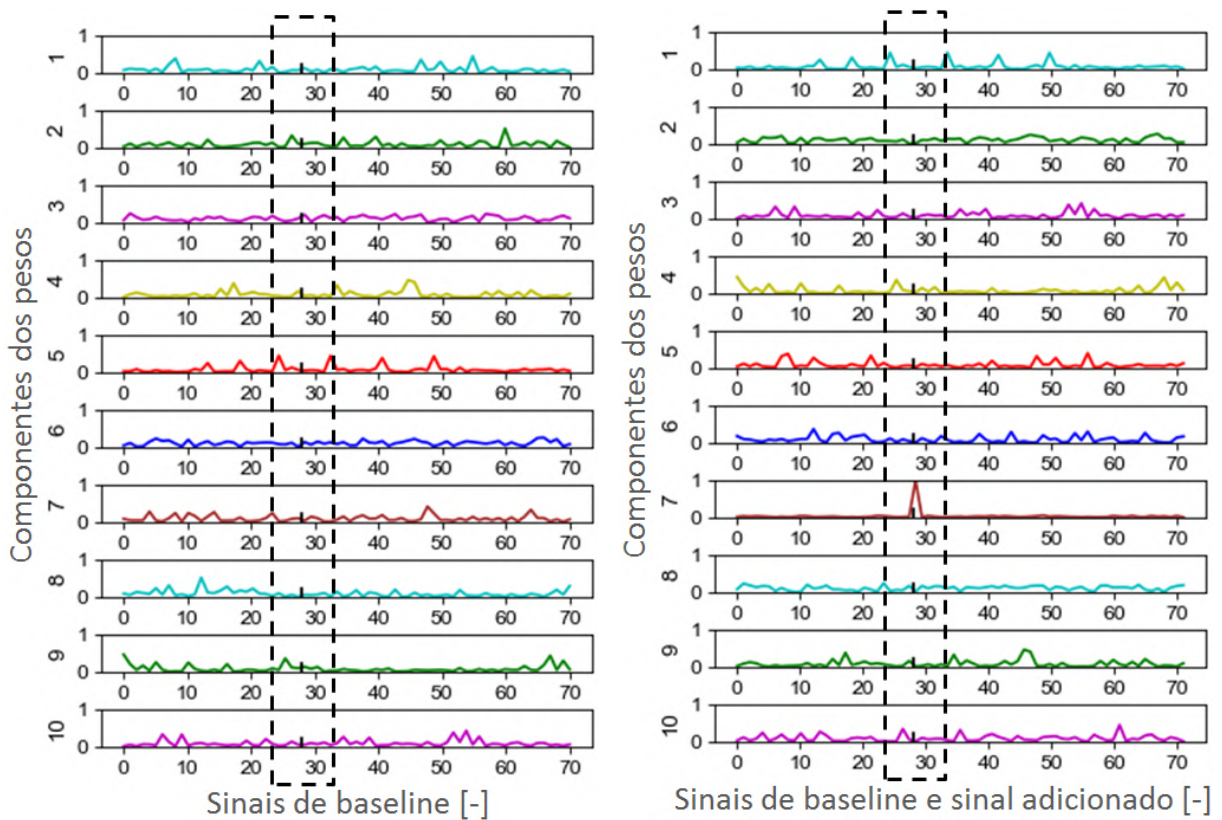
componente independente.

Para melhorar a visualização do método, adicionou-se o sinal correspondente ao nível 6 do dano I entre os demais sinais de *baseline* (representado por uma linha de cor vermelha na posição 52 da Figura 31b). Na Figura 32 é mostrado o resultado da aplicação do algoritmo ICA nestes sinais, considerando 10 componentes independentes. Na Figura 32a, o resultado para o primeiro conjunto de componentes é apresentado. Já na Figura 32b é apresentado o resultado para o segundo conjunto de componentes.

Figura 32: Componentes dos pesos do par de sensores e1r2.

(a) Componentes dos pesos da *baseline* do par de sensores e1r2.

(b) Componentes dos pesos da *baseline* e sinal do defeito do par de sensores e1r2.



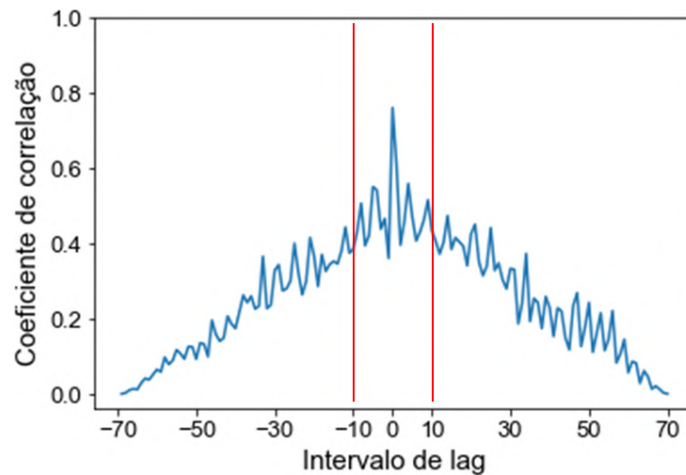
Fonte: Próprio Autor.

Seguindo o fluxograma da Figura 30, avaliou-se a correlação cruzada entre todas as componentes dos pesos do ICA do primeiro conjunto de dados com o segundo conjunto de dados. Ambos conjuntos são apresentados na Figura 32. Neste caso, percebe-se que a componente 7, mostrada na Figura 32b, possui menos similaridade que as demais componentes e assume-se como a componente relacionada ao dano. Realizou-se a busca pelo valor máximo de cada correlação cruzada a partir de três intervalos de *lag* (representado pelas linhas vermelhas verticais da Figura 33) denominados como: caso 1 (vetor de *lag* inteiro); caso 2 (intervalo de amostragem de *lag* restringido em ± 10); e caso 3 (intervalo de amostragem de *lag* restringido em ± 2). Esta etapa tenta minimizar os erros escolhendo apenas a componente mais similar. Em seguida, é ge-

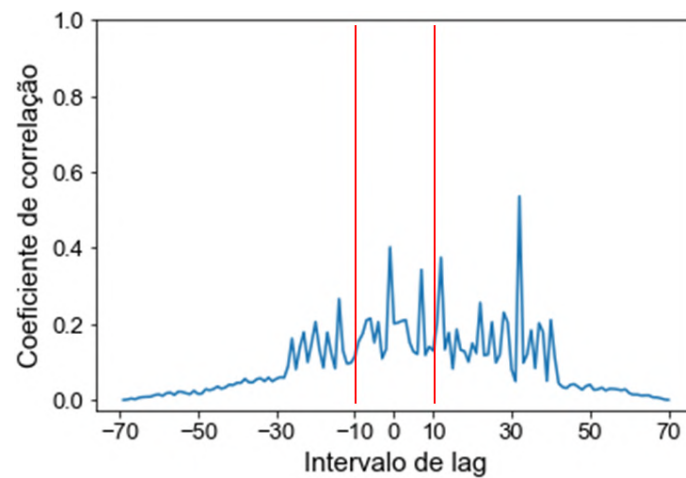
rada uma matriz relacionando (usando o valor máximo da correlação cruzada) as componentes do primeiro conjunto de componentes com as componentes do segundo conjunto.

Figura 33: Correlação cruzada entre a componente do primeiro conjunto de componentes com a componente do segundo conjunto de componentes.

(a) Correlação cruzada entre a componente dos pesos número 2 (*baseline*) e a componente 10 (*baseline* mais sinal do defeito).



(b) Correlação cruzada entre a componente dos pesos número 2 (*baseline*) e a componente 7 (*baseline* mais sinal do defeito).



Fonte: Próprio Autor.

Na Figura 33a é apresentado um exemplo a partir da correlação cruzada da componente 2 do primeiro conjunto de componentes, mostrado na Figura 32a, com a componente 10 do segundo conjunto de componentes, mostrado na Figura 32b. Já na Figura 33b é apresentado um exemplo a partir da correlação cruzada da componente 2 do primeiro conjunto de componentes, mostrado na Figura 32a, com a componente 7 do segundo conjunto de componentes, mostrado na Figura 32b.

No resultado da correlação cruzada da Figura 33a, verifica-se que o valor máximo do coeficiente de correlação é de aproximadamente 0,8 na região próxima ao *lag* 0. Já no resultado

apresentado na Figura 33b, verifica-se que o valor máximo do coeficiente de correlação é de aproximadamente 0,4 na região próxima ao *lag* 0. O maior valor do coeficiente de correlação cruzada da Figura 33a indica maior similaridade entre as duas componentes. Ao contrário, o menor valor do coeficiente de correlação cruzada da Figura 33b indica menor similaridade entre as duas componentes. Nesse caso, a componente do segundo conjunto de dados com a menor similaridade indica que a mesma está relacionada ao dano, pois relacionando as componentes dos dois conjuntos entre si, a componente com menor similaridade tenderá a não estar vinculada.




Após a conclusão da primeira parte do processo, a acurácia e os erros do tipo I e II para a identificação de danos são quantificados através do número de realizações aleatórias realizadas. Finalmente, o SNR é calculado apenas para as componentes dos pesos do segundo conjunto de componentes que obtiveram a menor similaridade na correlação cruzada.

Para analisar a influência do número de componentes do ICA, realizou-se testes variando esse número de 5 a 35 em intervalos de 5 componentes independentes em todos os valores de frequência central considerados nos testes experimentais. A partir do valor da amplitude de pico na componente que tem o valor máximo na posição onde o sinal de defeito foi adicionado, pretende-se analisar o número de componentes independentes necessários para detectar e quantificar os danos em todas os estágios de profundidade. Além disso, analisou-se a influência do número de sinais aleatórios de *baseline*, usados para construir os conjuntos de dados, na detecção e quantificação do dano realizando-se testes com 50, 100 e 150 sinais.

Na Figura 34 é mostrado um exemplo do resultado da aplicação do algoritmo orientado a dados no par de sensores e2r3 considerando o caso 3, frequência central de 45 kHz, 25 componentes independentes e 100 sinais aleatórios de *baseline*. Na Figura 34a é mostrado os resultados da acurácia para a estrutura não danificada e danificada de acordo com o número de realizações aleatórias. No eixo da profundidade do dano, a acurácia para o valor 0 está relacionada à estrutura não danificada e os demais valores de acurácia estão relacionados à estrutura danificada com perdas de espessura entre 10% e 60%. Na Figura 34b é mostrado os resultados das taxas de erro do tipo I, o qual estão relacionadas à estrutura danificada, de acordo com o número de realizações aleatórias. Por último, na Figura 34c, são apresentados os resultados das taxas de erro do tipo II, que estão relacionadas à estrutura não danificada, de acordo com o número de realizações aleatórias.

Para analisar a influência do número de realizações aleatórias e do par de sensores nos casos 1, 2 e 3, utilizou-se a média e o desvio padrão da acurácia (eixo da profundidade do dano), considerando a estrutura intacta e danificada em todos os estágios de profundidade, conforme o número de realizações aleatórias. Quanto ao erro do tipo I, também utilizou-se a média e a variância das taxas de erro do eixo da profundidade do dano, considerando apenas a estrutura danificada em todos os estágios de profundidade, de acordo com o número de realizações aleatórias. Por fim, para o erro do tipo II foi considerado o valor da taxa de erro do eixo da profundidade do defeito, considerando apenas a estrutura intacta, de acordo com o número de realizações aleatórias.

Figura 34: Influência do número de realizações aleatórias na acurácia e erros tipo I e II no par de sensores e2r3 para o caso 3, frequência central de 45 kHz, 25 componentes independentes e 100 sinais aleatórios de *baseline*.



Fonte: Próprio Autor.

5 RESULTADOS E DISCUSSÕES

Neste capítulo são apresentados os resultados e discussões da aplicação do método de detecção e quantificação de danos utilizando os sinais experimentais de ondas guiadas coletados no painel de testes instrumentado com o conjunto de transdutores piezoelétricos. O capítulo é dividido em três seções principais, onde na primeira são apresentados os resultados do estudo da influência do número de componentes independentes do ICA, do número de sinais aleatórios de *baseline* e da frequência de operação na detecção e na quantificação dos danos, na segunda são apresentados os resultados da detecção dos danos e na terceira são apresentados os resultados da quantificação dos danos.

5.1 Influência do Número de Componentes do ICA, do Número de Sinais Aleatórios de *Baseline* e da Frequência de Operação na Detecção e Quantificação dos Danos

Para a realização dos estudos iniciais sobre a influência do número de componentes do ICA, do número de sinais aleatórios de *baseline* e da frequência de operação, selecionou-se o par de sensores e2r3 devido às características do caminho percorrido pela onda, mostrado no desenho esquemático da Figura 24b. Alguns fatores que podem favorecer a detecção e a quantificação são a distância entre os transdutores desse par de sensores que é relativamente menor que outras combinações de pares e as suas localizações próximas do dano. Por outro lado, devido o painel de testes reproduzir uma estrutura complexa, selecionou-se esse par de transdutores devido a presença de um elemento estrutural entre os sensores, fator que poderá tornar a detecção e quantificação do dano mais desafiadora.

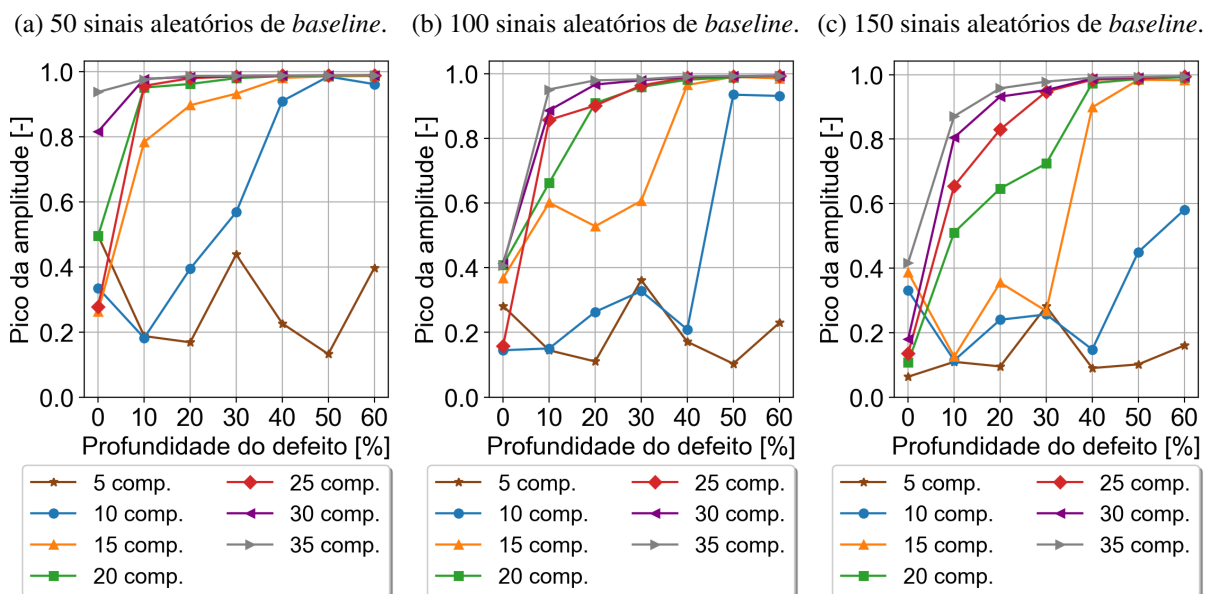
Nas Figuras 35 e 36 são apresentados a influência do tamanho da dimensão reduzida na amplitude da componente que possui o valor máximo na posição que foi acrescentado o sinal para os danos I e II respectivamente, considerando o par de sensores e2r3, frequência central de 45 kHz e 50, 100 e 150 sinais aleatórios de *baseline*. Já nos Apêndices A.1 e A.2 são apresentados a influência do tamanho da dimensão reduzida na amplitude da componente para os demais valores de frequência central considerados nos testes experimentais para os danos I e II.

Na Figura 35 é mostrado a influência do número de componentes independentes para o par de sensores e2r3, dano I e frequência central de 45 kHz para o número de sinais aleatórios de *baseline*, em diferentes temperaturas de coleta, de 50, 100 e 150. Observando-se os resultados para os diferentes números de sinais aleatórios de *baseline*, verifica-se comportamentos distintos em relação ao valor da amplitude de pico na componente que possui o valor máximo na posição onde o sinal foi adicionado. O sinal adicionado trata-se de um sinal de *baseline* (0% de perda de espessura) diferente dos demais sinais que compõem a matriz de dados, ou um sinal de defeito (10% a 60% de perda de espessura), que é adicionado entre os demais sinais que compõem a matriz e em uma posição aleatória.

Verifica-se que à medida que o número de componentes aumenta, os valores de amplitude de pico também aumentam, principalmente em danos menos severos. Para danos mais severos, a estabilização do aumento nos valores de amplitude de pico ocorre com números menores de componentes. Os danos menos severos tendem a ter um valor de amplitude de pico mais baixo que os danos mais severos. No entanto, quando o número de componentes é aumentado, os valores de amplitude de pico dos danos menos severos tendem a se estabilizar com os valores de amplitude de pico dos danos mais severos.

Além disso, conforme o número de sinais aleatórios aumenta, os valores de amplitude de pico de cada número de componentes diminui, principalmente para os danos menos severos. Por último, observou-se valores distintos de amplitude de pico para os demais valores de frequência central, apresentados no Apêndice A.1, porém com comportamentos similares ao descrito para a frequência central de 45 kHz.

Figura 35: Influência do número de componentes do ICA e do número de sinais aleatórios de *baseline* para o par de sensores e2r3, dano I e frequência central de 45 kHz.

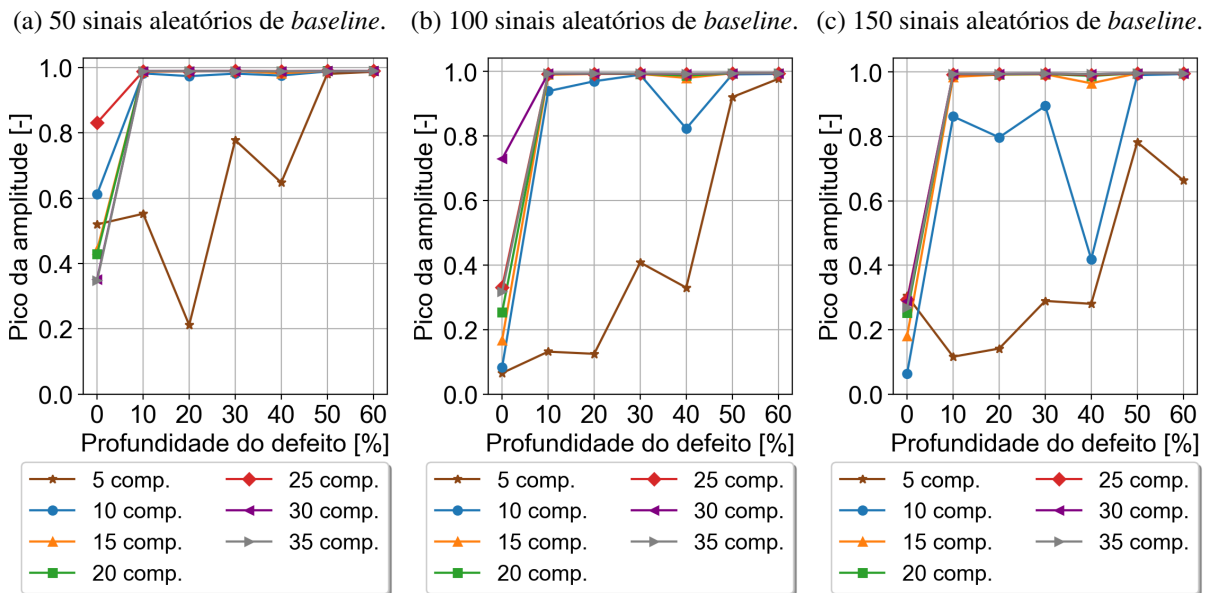


Fonte: Próprio Autor.

Já na Figura 36 é mostrado a influência do número de componentes independentes para o par de sensores e2r3, dano II e frequência central de 45 kHz para o número de sinais aleatórios de *baseline*, em diferentes temperaturas de coleta, de 50, 100 e 150. Para o dano II, também observou-se comportamentos distintos nos diferentes números de sinais aleatórios de *baseline* em relação ao valor da amplitude de pico na componente que possui o valor máximo na posição onde o sinal foi adicionado.

Conforme o número de sinais aleatórios aumenta, os valores de amplitude de pico diminuem, principalmente para os menores números de componentes. A diminuição dos valores de amplitude de pico são significativamente menores em relação ao dano I. Observa-se que a maioria dos números de componentes já possuem o valor de amplitude de pico estabilizado no seu valor máximo em todas as profundidades. Este mesmo comportamento foi observado nas profundidades maiores do dano I. Esta característica favorece a detecção do dano, porém, dificulta a sua quantificação. Ao contrário do dano I, para o dano II observou-se comportamentos similares para os demais valores de frequência central, apresentados no Apêndice A.2, exceto para os números de componentes menores que apresentaram uma diminuição no valor da amplitude de pico em algumas profundidades.

Figura 36: Influência do número de componentes do ICA e do número de sinais aleatórios de *baseline* para o par de sensores e2r3, dano II e frequência central de 45 kHz.



Fonte: Próprio Autor.

Para o dano I, considerando-se todos os valores de frequência central, observou-se que as amplitudes de pico para os valores de frequência de 35 kHz a 50 kHz, apresentados no Apêndice A.1, possuem características parecidas. Nessa faixa de valores de frequência central, os valores de amplitude mostraram-se crescentes de 0 a 60% de perda de espessura. Devido a esta característica favorecer a quantificação do dano, selecionou-se o valor de 45 kHz para realizar

o estudo de detecção e quantificação do dano I. Já para o dano II, observou-se que os valores de amplitude de pico possuem comportamentos parecidos em toda faixa de valores de frequência central, conforme mostrado no Apêndice A.2. Dessa forma, para realizar o estudo de detecção e quantificação do dano II, considerou-se o mesmo valor de frequência selecionado para o dano I.

Para a realização dos testes com diferentes números de componentes independentes, sinais aleatórios de *baseline* e intervalos de *lag* considerou-se o par de sensores e2r3 e dano I, o qual observou-se que as taxas de erro do tipo II, relacionados a estrutura não danificada, são menores para números de componentes independentes menores. Para os números de componentes maiores, as taxas de erro do tipo II diminuem quando o número de sinais aleatórios de *baseline* são maiores. Também observou-se que os intervalos de *lag* (casos 1, 2 e 3) possuem pouca influência nas taxas de erro do tipo II. Já para os erros do tipo I, relacionados a estrutura danificada, as taxas diminuem para os números de componentes maiores.

Quanto aos valores dos SNRs dos *outliers*, observou-se que os mesmos estão relacionados aos valores de amplitude de pico, ou seja, números de componentes com valores de amplitudes de pico baixos possuem valores de SNRs dos *outliers* baixos. Além disso, observou-se que os valores dos SNRs dos *outliers* são maiores para números de sinais aleatórios de *baseline* maiores, aumentando, assim, a distância entre os valores de não-*outliers* e *outliers*.

De um modo geral, as maiores taxas de acurácia e as menores taxas de erro para a estrutura danificada foram obtidas considerando o menor intervalo de *lag* (caso 3) e o maior número de sinais aleatórios de *baseline*. Já para a quantificação do dano, os melhores resultados foram obtidos utilizando números de componentes com valores de amplitude de pico crescentes de 0 a 60% de perda de espessura e números de sinais aleatórios de *baseline* maiores.

Os testes realizados no par de sensores e2r3 para a avaliação da identificação e quantificação do dano I com diferentes números de componentes independentes, sinais aleatórios de *baseline* e intervalos de *lag* para frequência central de 45 kHz são apresentados nos Apêndices B.1, B.2 e B.3, exceto para 15, 20 e 25 componentes independentes, o qual apresentaram os resultados mais satisfatórios para 50, 100 e 150 sinais aleatórios de *baseline* respectivamente e são apresentados nas Figuras 37, 38 e 39.

Para a quantificação do dano, utilizou-se uma curva sigmóide para ajustar os dados dos vários pares de sensores conforme apresentado na Equação (55):

$$SNR(p_d) = \frac{k_{cs1}}{k_{cs2} + k_{cs3} \exp(p_d k_{cs4})} + k_{cs5}, \quad (55)$$

onde p_d é o tamanho do defeito em % de perda de espessura e k_{cs1} , k_{cs2} , k_{cs3} , k_{cs4} e k_{cs5} são constantes a serem ajustadas. O ajuste da curva sigmoidal e as curvas de limite de confiança nos *outliers* permitirão estimar a profundidade do dano. Os resultados da regressão usando a função sigmóide nos *outliers* nos diferentes pares de sensores são representados por uma linha sólida e os limites de confiança de 95% são representados por linhas tracejadas.

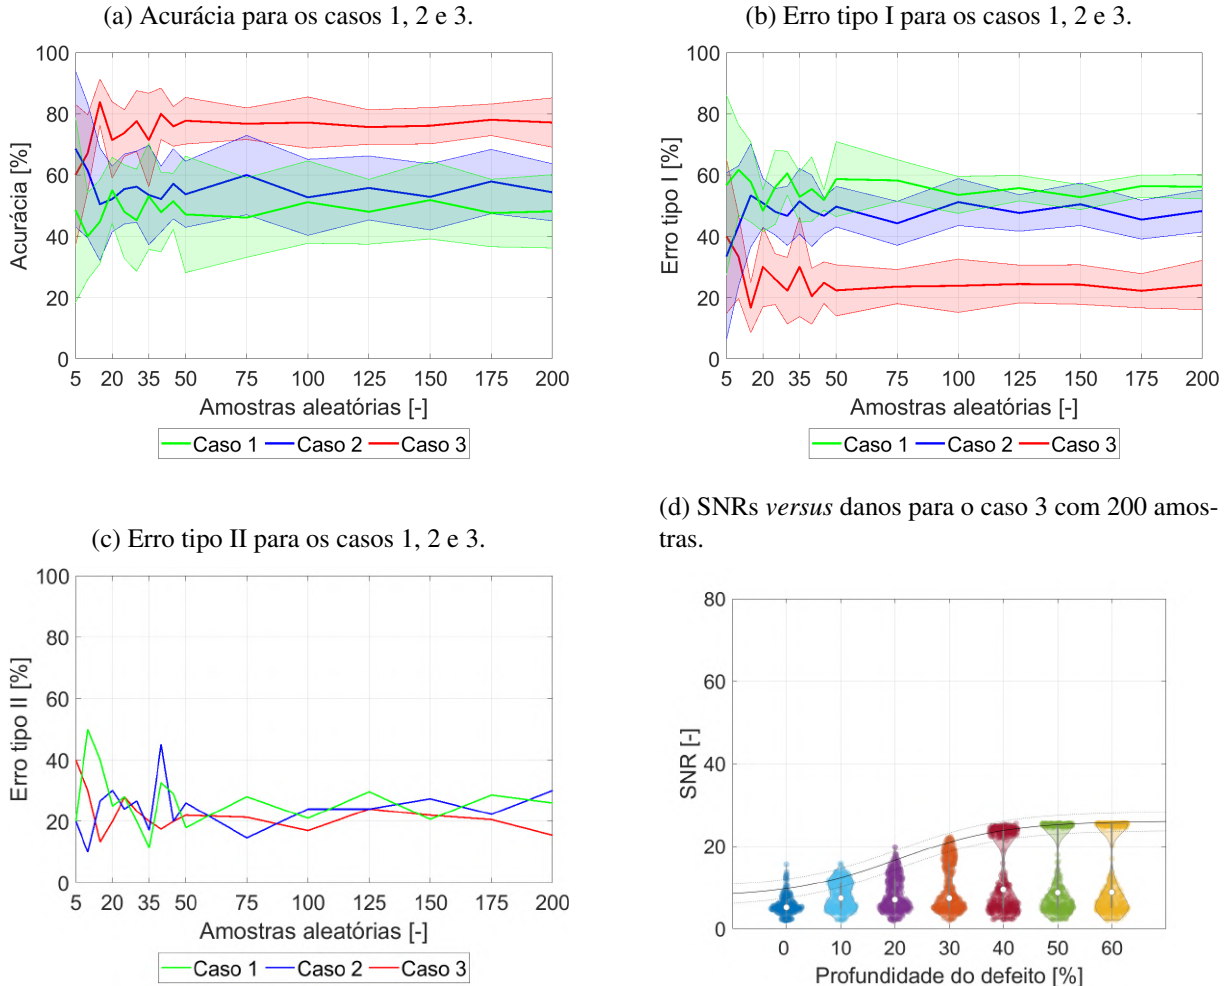
Nas Figuras 37, 38 e 39 são apresentados os resultados da influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e os SNRs *versus* danos para o caso 3 com 200 amostras no par de sensores e 2r3 para 50 sinais aleatórios de *baseline* com 15 componentes independentes, 100 sinais aleatórios de *baseline* com 20 componentes independentes e 150 sinais aleatórios de *baseline* com 25 componentes independentes. Os casos 1, 2 e 3 são apresentados através do valor médio representado por linhas sólidas e as regiões sombreadas representam um desvio padrão. A apresentação dos resultados dos casos 1, 2 e 3 para o par de sensores e 2r3 tem o intuito de representar o comportamento de todos os pares de sensores.

Nas Figuras 37a, 38a e 39a são apresentados a acurácia do modelo. Pode-se observar que à medida que o intervalo de *lag* é restringido, os valores médios das taxas de acurácia de acordo com o número de realizações aleatórias aumentam e a variância diminui. Além disso, observa-se que a variância diminui e torna-se mais estável à medida que o número de realizações aleatórias aumentam. A estabilização da variância indica que a acurácia média de detecção de danos é mais estável. Ressalta-se que pequenos defeitos apresentam menor acurácia, ao contrário, defeitos maiores apresentam maior acurácia, conforme mostrado na Figura 34. Por último, observa-se que conforme o número de sinais aleatórios de *baseline* aumentam, as taxas de acurácia também aumentam e as variâncias diminuem.

Nas Figuras 37b, 38b e 39b são mostrados as taxas de erro do tipo I, o qual pode-se obter conclusões similares às feitas para a acurácia. No entanto, as taxas de erro diminuem à medida que o intervalo de *lag* é restringido. Ressalta-se que a redução na variância se deve ao teorema do limite central, o qual afirma que a variância deve reduzir quando o número de amostras aumenta. Já os erros são em função do algoritmo proposto e não em função do número de amostras aleatórias, razão pela qual não reduziu. Nas Figuras 37c, 38c e 39c são mostrados os resultados das taxas de erro do tipo II, onde observou-se pouca influência da restrição do intervalo de *lag* ou das amostras aleatórias no resultado do modelo.

Por fim, nas Figuras 37d, 38d e 39d são apresentados os SNRs *versus* profundidades dos danos, considerando o caso 3 e 200 realizações aleatórias. Já nas Tabelas 5, 6 e 7 são mostrados os valores obtidos na regressão para os resultados apresentados nas Figuras 37d, 38d e 39d, respectivamente. A partir da curva sigmoidal, observa-se uma relação sigmoidal entre os *outliers* dos SNRs e o dano na estrutura, o qual pode ser usada para estimar a severidade do dano. Além disso, observa-se que os SNRs dos *outliers* possuem comportamentos parecidos com as amplitudes de pico apresentadas na Figura 35. Analisando-se os valores dos SNRs dos *outliers* de cada nível de profundidade, observa-se que conforme o número de sinais aleatórios de *baseline* aumenta, os valores dos SNRs também aumentam, e, conseqüentemente, a distância entre os *outliers* em cada nível profundidade também aumenta.

Figura 37: Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs *versus* danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 50 sinais aleatórios de *baseline* e 15 componentes independentes.



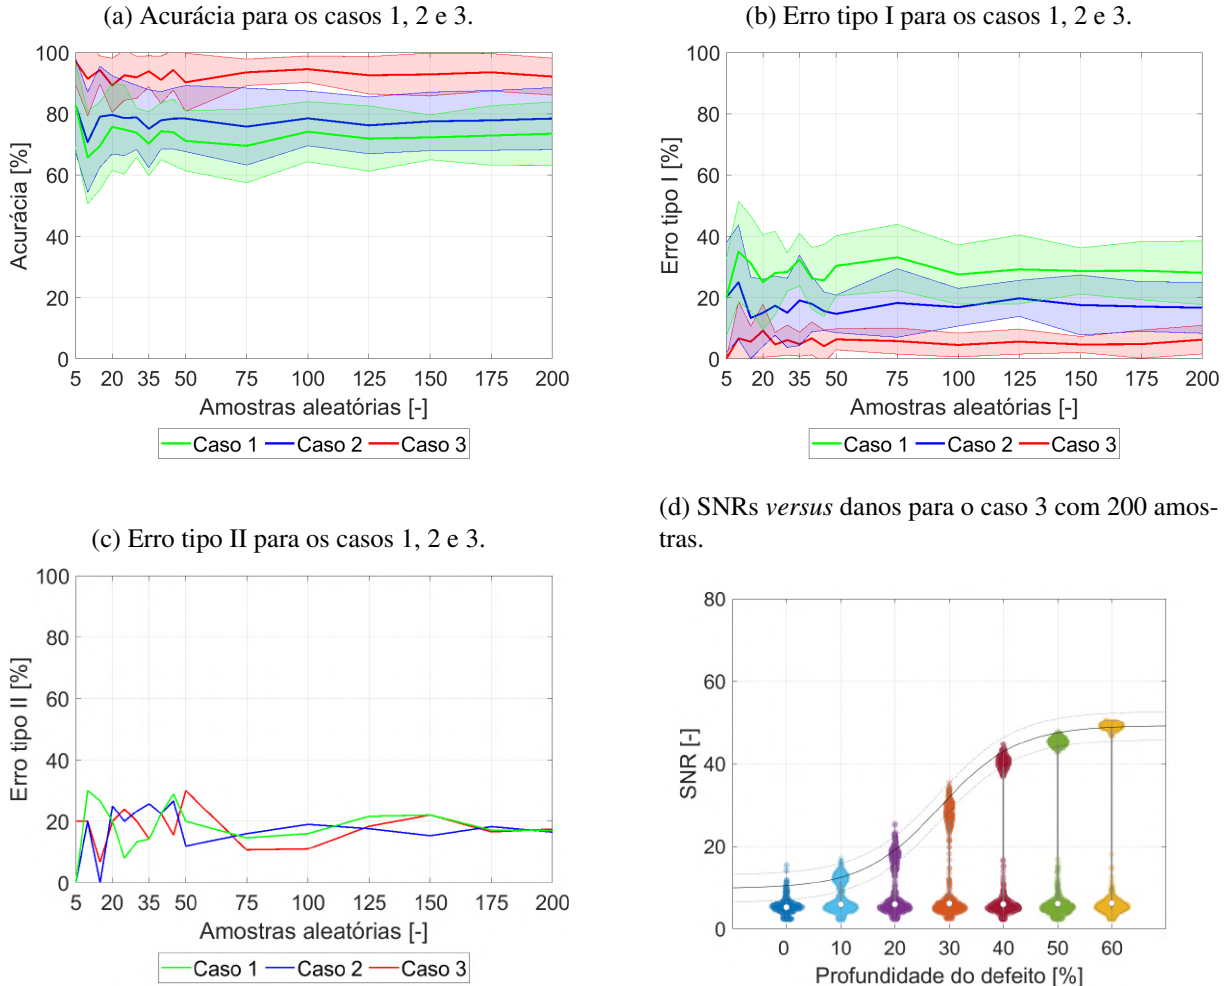
Fonte: Próprio Autor.

Tabela 5: Valores obtidos na regressão usando a função sigmóide nos *outliers* do par de sensores e2r3 para o caso 3 com 200 realizações aleatórias, dano I, frequência central de 45 kHz, 50 sinais aleatórios de *baseline* e 15 componentes independentes.

	50 sinais 15 comp.	Limite de confiança de 95%
a	-2689	(-1.927e+09, 1.927e+09)
b	-6116	(-4.384e+09, 4.384e+09)
c	7.742	(6.834, 8.65)
d	-1.01	(-1.123, -0.8976)
e	-332.9	(-2.386e+08, 2.386e+08)
r^2	0.9668	-

Fonte: Próprio Autor.

Figura 38: Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs *versus* danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 100 sinais aleatórios de *baseline* e 20 componentes independentes.



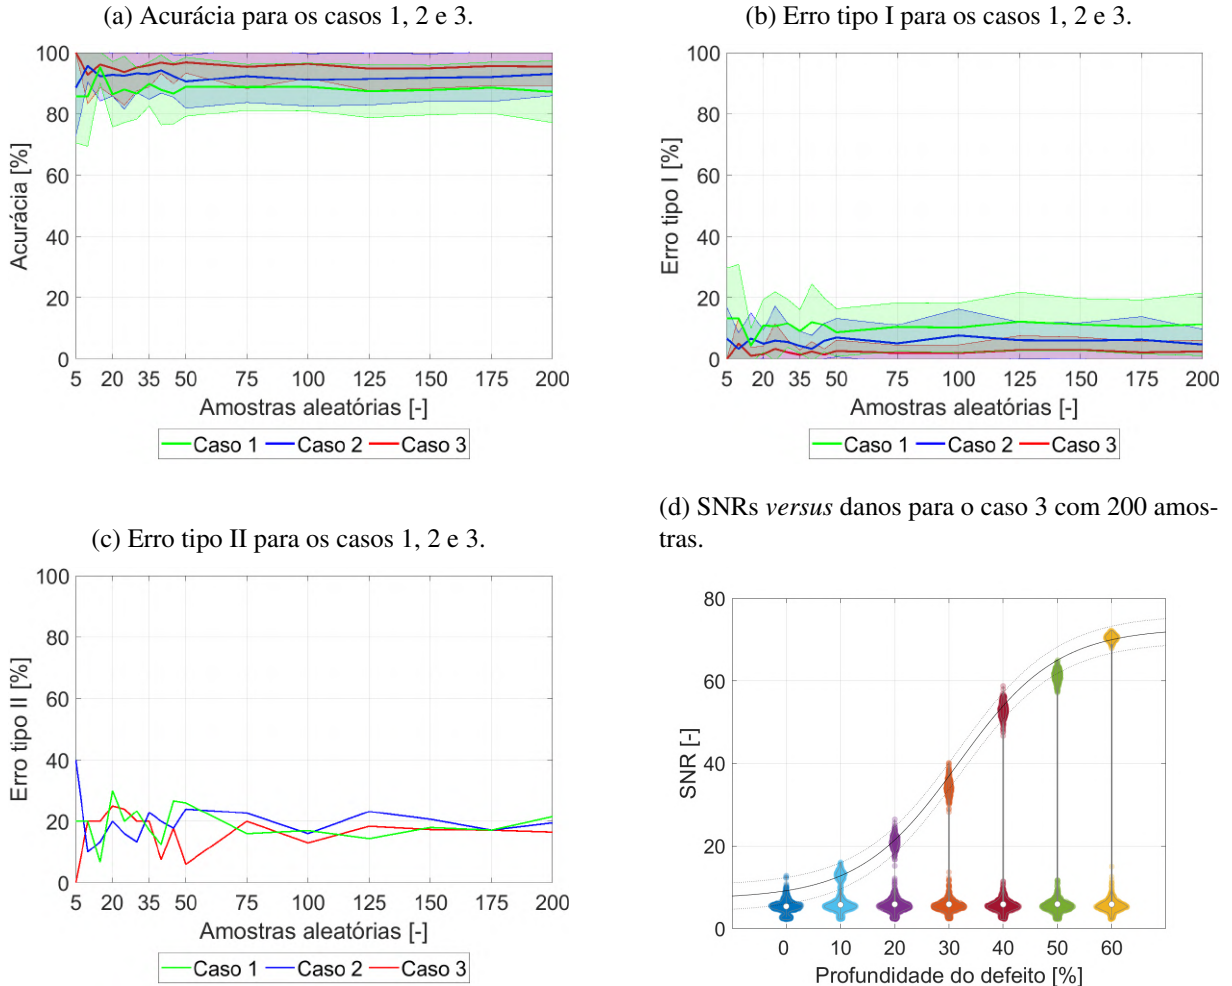
Fonte: Próprio Autor.

Tabela 6: Valores obtidos na regressão usando a função sigmóide nos *outliers* do par de sensores e2r3 para o caso 3 com 200 realizações aleatórias, dano I, frequência central de 45 kHz, 100 sinais aleatórios de *baseline* e 20 componentes independentes.

	100 sinais 20 comp.	Limite de confiança de 95%
a	2.86e+04	(-1.815e+10, 1.815e+10)
b	2.104e+04	(-1.335e+10, 1.335e+10)
c	9.701	(9.222, 10.18)
d	-1.409	(-1.492, -1.326)
e	531.5	(-3.372e+08, 3.372e+08)
r^2	0.9885	-

Fonte: Próprio Autor.

Figura 39: Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs *versus* danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 150 sinais aleatórios de *baseline* e 25 componentes independentes.



Fonte: Próprio Autor.

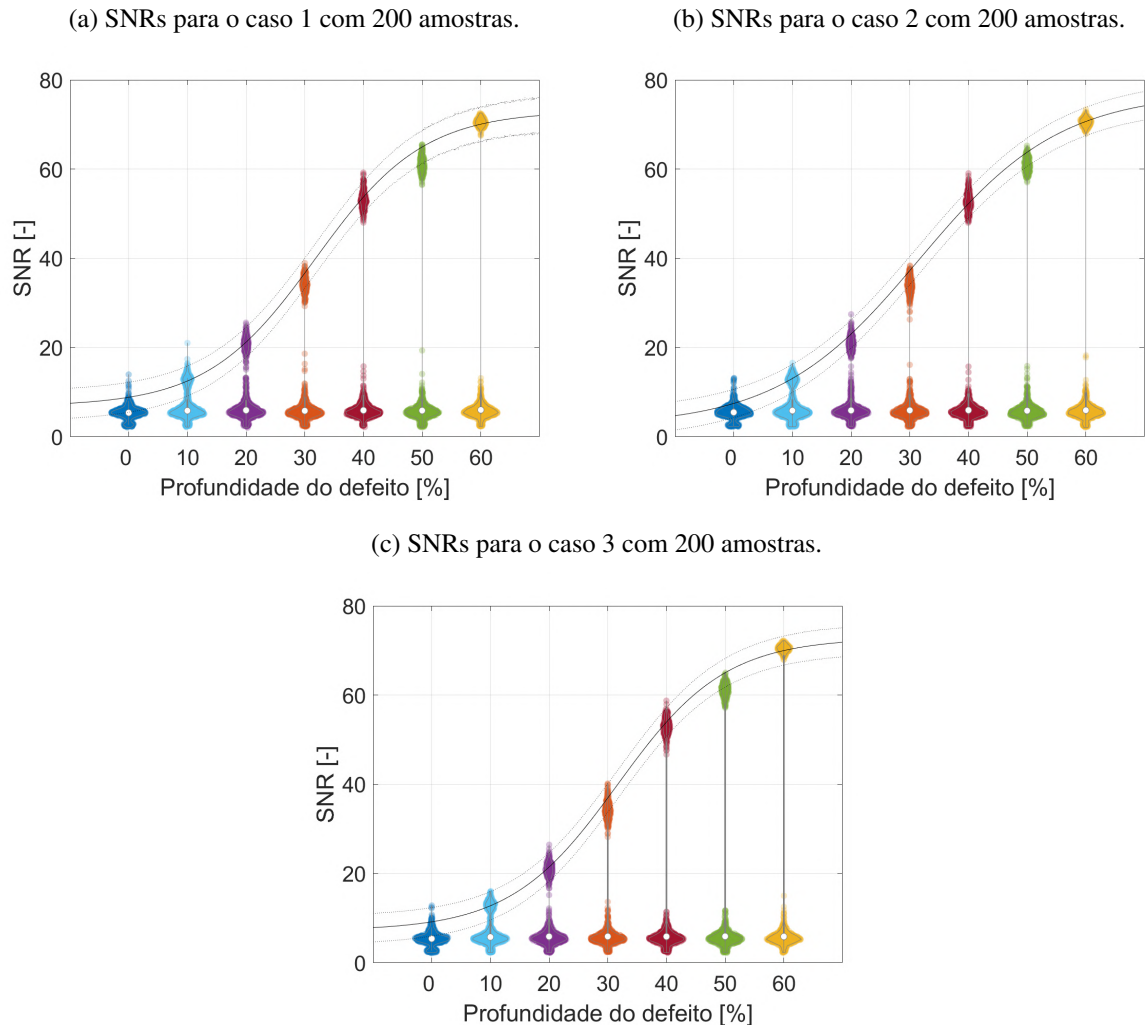
Tabela 7: Valores obtidos na regressão usando a função sigmóide nos *outliers* do par de sensores e2r3 para o caso 3 com 200 realizações aleatórias, dano I, frequência central de 45 kHz, 150 sinais aleatórios de *baseline* e 25 componentes independentes.

	150 sinais 25 comp.	Limite de confiança de 95%
a	-1.889e+04	(-7.328e+09, 7.328e+09)
b	-3.857e+04	(-1.497e+10, 1.497e+10)
c	7.208	(6.778, 7.638)
d	-1.094	(-1.124, -1.065)
e	-587.8	(-2.281e+08, 2.281e+08)
r^2	0.9957	-

Fonte: Próprio Autor.

Na Figura 40 é mostrado os resultados dos SNRs *versus* danos dos casos 1, 2 e 3 com 200 realizações aleatórias para o par de sensores e2r3, dano I e 25 componentes independentes com 150 sinais aleatórios de *baseline*, onde as linhas sólidas representam uma regressão usando uma função sigmóide nos *outliers* e as linhas tracejadas representam os limites de confiança de 95%. Nas Tabelas 8, 9 e 10 são mostrados os valores obtidos na regressão. Observa-se que a quantificação do dano é levemente influenciada pelo intervalo de *lag*. Realizando-se a contagem dos *outliers* e não-*outliers*, verificou-se que a quantidade de *outliers* aumenta na mesma proporção que a acurácia aumenta. Da mesma forma, verificou-se que a quantidade de não-*outliers*, relacionados aos valores mais baixos, diminui na mesma proporção que a taxa de erro do tipo I diminui. Por fim, observou-se nos demais pares de sensores o mesmo comportamento descrito para o par de sensores e2r3.

Figura 40: Influência do número de realizações aleatórias nos SNRs da estrutura não danificada e danificada em todos os estágios de profundidade para o par de sensores e2r3 para os casos 1, 2 e 3 com 200 amostras, dano I, frequência central de 45 kHz, 150 sinais aleatórios de *baseline* e 25 componentes independentes.



Fonte: Próprio Autor.

Tabela 8: Valores obtidos na regressão usando a função sigmóide nos *outliers* do par de sensores e2r3 para o caso 1 com 200 realizações aleatórias, dano I, frequência central de 45 kHz, 150 sinais aleatórios de *baseline* e 25 componentes independentes.

	Caso 1	Limite de confiança de 95%
a	-7.038e+04	(-6.302e+10, 6.302e+10)
b	-1.479e+05	(-1.324e+11, 1.324e+11)
c	6.826	(6.403, 7.249)
d	-1.085	(-1.116, -1.053)
e	-2233	(-2e+09, 2e+09)
r^2	0.9953	-

Fonte: Próprio Autor.

Tabela 9: Valores obtidos na regressão usando a função sigmóide nos *outliers* do par de sensores e2r3 para o caso 2 com 200 realizações aleatórias, dano I, frequência central de 45 kHz, 150 sinais aleatórios de *baseline* e 25 componentes independentes.

	Caso 2	Limite de confiança de 95%
a	-609.5	(-1.237e+08, 1.237e+08)
b	-3299	(-6.696e+08, 6.696e+08)
c	2.439	(1.728, 3.15)
d	-0.8295	(-0.8604, -0.7986)
e	-44.14	(-8.96e+06, 8.96e+06)
r^2	0.9957	-

Fonte: Próprio Autor.

Tabela 10: Valores obtidos na regressão usando a função sigmóide nos *outliers* do par de sensores e2r3 para o caso 3 com 200 realizações aleatórias, dano I, frequência central de 45 kHz, 150 sinais aleatórios de *baseline* e 25 componentes independentes.

	Caso 3	Limite de confiança de 95%
a	-1.889e+04	(-7.328e+09, 7.328e+09)
b	-3.857e+04	(-1.497e+10, 1.497e+10)
c	7.208	(6.778, 7.638)
d	-1.094	(-1.124, -1.065)
e	-587.8	(-2.281e+08, 2.281e+08)
r^2	0.9957	-

Fonte: Próprio Autor.

De acordo com a análise de detecção e quantificação de danos realizado no par de sensores e2r3, para as demais combinações de pares de sensores considerou-se o caso 3 para o intervalo de *lag*, frequência central de 45 kHz e 150 sinais aleatórios de *baseline*, exceto para as combinações de sensores onde os transdutores 01, 07, 08, 09 e 10 são os atuadores devido possuírem número menor de sinais de *baseline*. Nestes casos, considerou-se 70 sinais para os transdutores atuadores 01, 07 e 09, 60 sinais para o transdutor 08 e 80 sinais para o transdutor 10. Já para os valores de amplitude de pico, considerou-se o número de componentes que obteve valores de amplitude de pico a partir de aproximadamente 0,5 para 150 sinais aleatórios de *baseline*, 0,65 para 100 sinais e 0,8 para 50 sinais. Além disso, considerou-se o número de componentes onde os valores de amplitude de pico eram crescentes de 0 a 60% de perda de espessura.

Os pares de sensores possuem comportamentos distintos em relação ao valor da amplitude de pico na componente que possui o valor máximo na posição onde o sinal foi adicionado. Dessa forma, baseado nos valores de amplitude de pico e no número de sinais de *baseline* do transdutor atuador descritos anteriormente, definiu-se os números de componentes para cada par de sensores para os danos I e II conforme apresentados nas Tabelas 11, 12, 13 e 14.

Tabela 11: Número de componentes selecionados em cada par de sensores para o dano I.

Pares	Comp.	Pares	Comp.	Pares	Comp.	Pares	Comp.	Pares	Comp.
e1r2	20	e2r1	20	e3r1	20	e4r1	15	e5r1	15
e1r3	15	e2r3	25	e3r2	25	e4r2	25	e5r2	20
e1r4	35	e2r4	35	e3r4	35	e4r3	20	e5r3	25
e1r5	20	e2r5	20	e3r5	20	e4r5	20	e5r4	35
e1r6	25	e2r6	35	e3r6	25	e4r6	20	e5r6	25
e1r7	15	e2r7	15	e3r7	10	e4r7	10	e5r7	10
e1r8	25	e2r8	35	e3r8	35	e4r8	25	e5r8	35
e1r9	20	e2r9	35	e3r9	20	e4r9	15	e5r9	20
e1r10	20	e2r10	30	e3r10	25	e4r10	20	e5r10	20

Fonte: Próprio Autor.

Tabela 12: Número de componentes selecionados em cada par de sensores para o dano I.

Pares	Comp.	Pares	Comp.	Pares	Comp.	Pares	Comp.	Pares	Comp.
e6r1	15	e7r1	15	e8r1	10	e9r1	15	e10r1	15
e6r2	20	e7r2	20	e8r2	20	e9r2	20	e10r2	20
e6r3	20	e7r3	15	e8r3	20	e9r3	20	e10r3	15
e6r4	35	e7r4	25	e8r4	30	e9r4	25	e10r4	30
e6r5	25	e7r5	20	e8r5	10	e9r5	15	e10r5	15
e6r7	10	e7r6	10	e8r6	15	e9r6	10	e10r6	10
e6r8	35	e7r8	20	e8r7	10	e9r7	10	e10r7	10
e6r9	20	e7r9	25	e8r9	10	e9r8	35	e10r8	20
e6r10	20	e7r10	25	e8r10	15	e9r10	10	e10r9	10

Fonte: Próprio Autor.

Tabela 13: Número de componentes selecionados em cada par de sensores para o dano II.

Pares	Comp.	Pares	Comp.	Pares	Comp.	Pares	Comp.	Pares	Comp.
e1r2	10	e2r1	15	e3r1	15	e4r1	10	e5r1	10
e1r3	10	e2r3	15	e3r2	20	e4r2	15	e5r2	15
e1r4	25	e2r4	35	e3r4	35	e4r3	15	e5r3	15
e1r5	10	e2r5	15	e3r5	15	e4r5	15	e5r4	30
e1r6	10	e2r6	15	e3r6	15	e4r6	15	e5r6	15
e1r7	10	e2r7	10	e3r7	10	e4r7	10	e5r7	15
e1r8	20	e2r8	25	e3r8	20	e4r8	20	e5r8	20
e1r9	5	e2r9	15	e3r9	10	e4r9	10	e5r9	10
e1r10	5	e2r10	15	e3r10	15	e4r10	15	e5r10	15

Fonte: Próprio Autor.

Tabela 14: Número de componentes selecionados em cada par de sensores para o dano II.

Pares	Comp.	Pares	Comp.	Pares	Comp.	Pares	Comp.	Pares	Comp.
e6r1	10	e7r1	5	e8r1	10	e9r1	10	e10r1	10
e6r2	10	e7r2	15	e8r2	15	e9r2	5	e10r2	10
e6r3	15	e7r3	15	e8r3	10	e9r3	5	e10r3	10
e6r4	25	e7r4	30	e8r4	30	e9r4	25	e10r4	30
e6r5	10	e7r5	10	e8r5	10	e9r5	10	e10r5	15
e6r7	5	e7r6	10	e8r6	10	e9r6	5	e10r6	10
e6r8	15	e7r8	25	e8r7	5	e9r7	5	e10r7	5
e6r9	10	e7r9	10	e8r9	5	e9r8	15	e10r8	10
e6r10	10	e7r10	10	e8r10	5	e9r10	5	e10r9	5

Fonte: Próprio Autor.

5.2 Resultados da Detecção dos Danos

Nesta seção são apresentados e discutidos os resultados da aplicação do método na detecção dos danos I e II em todos os níveis de profundidade a partir da análise das taxas de acurácia e das taxas de erros do tipo I e II.

5.2.1 Dano I

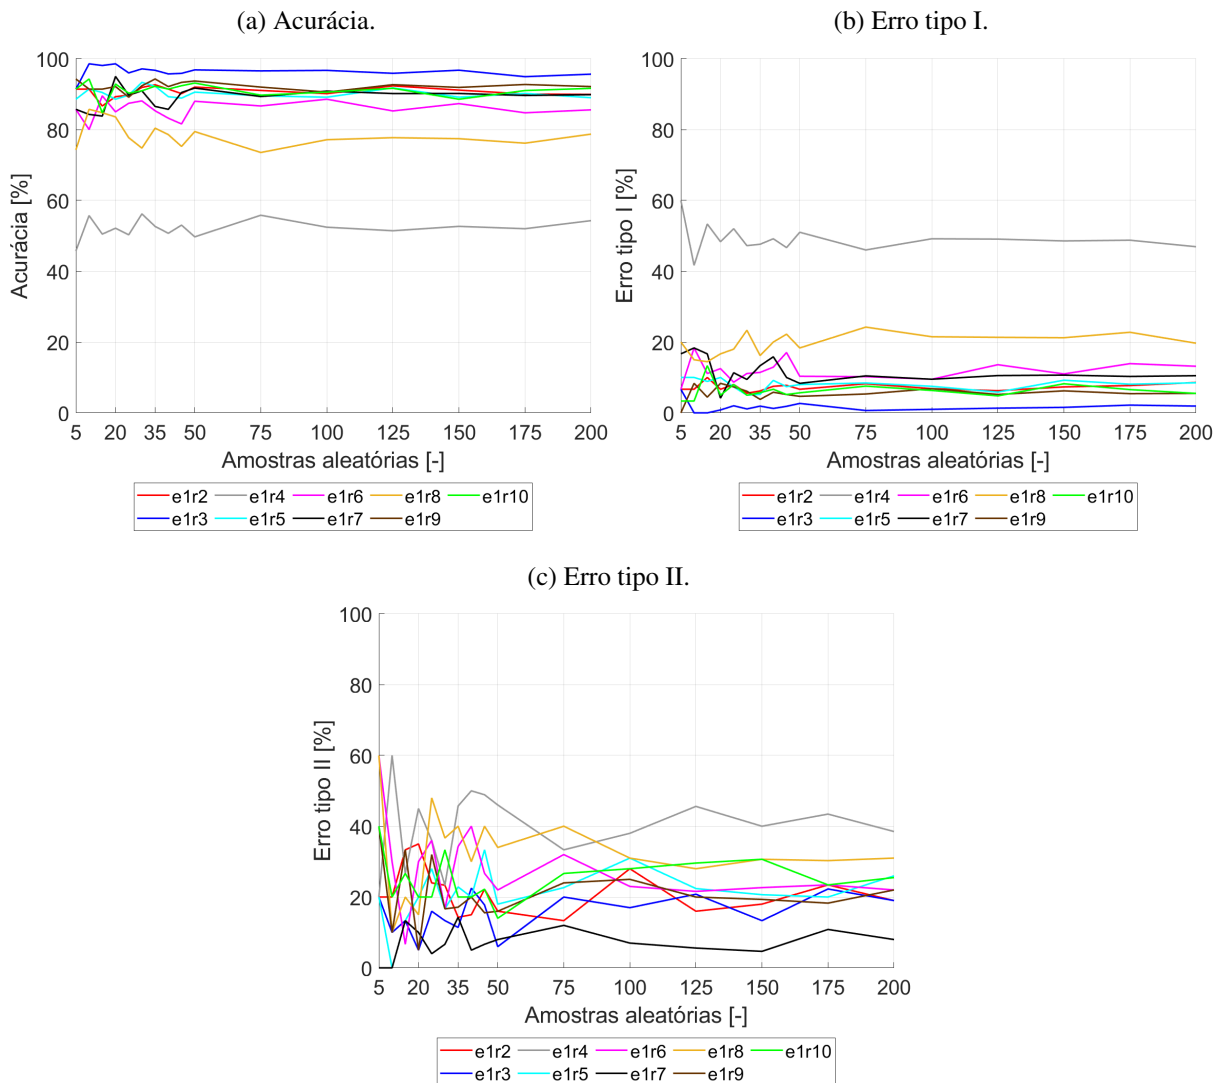
Nas Figuras 41 e 42 são apresentados os resultados da influência do número de realizações aleatórias na acurácia e nos erros tipo I e II nos pares de sensores onde os transdutores 01 e 03 são os atuadores para o dano I e caso 3 de intervalo de *lag*. Para analisar a influência do número de realizações aleatórias e do par de sensores, utilizou-se a média da acurácia considerando a estrutura intacta e danificada em todos os estágios de profundidade, conforme o número de realizações aleatórias. Quanto ao erro do tipo I, utilizou-se a média das taxas de erro considerando apenas a estrutura danificada em todos os estágios de profundidade, de acordo com o número

de realizações aleatórias. Por fim, para o erro do tipo II foi considerado o valor da taxa de erro considerando apenas a estrutura intacta, de acordo com o número de realizações aleatórias.

Na Figura 41, os pares de sensores e1r2, e1r3, e1r4, e1r5, e1r6, e1r7, e1r8, e1r9 e e1r10 são representados por linhas sólidas que representam os valores médios das taxas de acurácia e erros do tipo I e II. Nas Figuras 41a e 41b, os resultados mostram que o comportamento dos pares de sensores parecem ser semelhantes e observa-se que as taxas se tornam mais estáveis quando o número de amostras é aumentado. No entanto, nota-se que alguns pares de sensores realizam uma previsão menos precisa, e, conseqüentemente, esses mesmos pares possuem um erro do tipo I mais alto. Para as amostras aleatórias maiores, observa-se que as taxas de acurácia são superiores a 80%, exceto para os pares de sensores e1r8 que possui taxa pouco abaixo de 80% e e1r4 que possui taxa de aproximadamente 55%. O par de sensores e1r3 apresentou taxa de acurácia de aproximadamente 95%, obtendo a maior acurácia entre todas as combinações de pares de sensores utilizando o transdutor 01 como atuador, seguido pelos pares de sensores e1r2, e1r5, e1r7, e1r9 e e1r10 que obtiveram taxas de acurácia acima de 90% e pelo par de sensores e1r6 que obteve taxa de acurácia pouco abaixo de 90%. Em relação ao erro do tipo II, mostrado na Figura 41c, verifica-se um dado menos consistente com maiores variações nas taxas de erro e maiores erros de previsão. Os pares de sensores preveem taxas de erros abaixo de 30%, exceto o par de sensores e1r4 que apresentou uma taxa de erro de aproximadamente 40%.

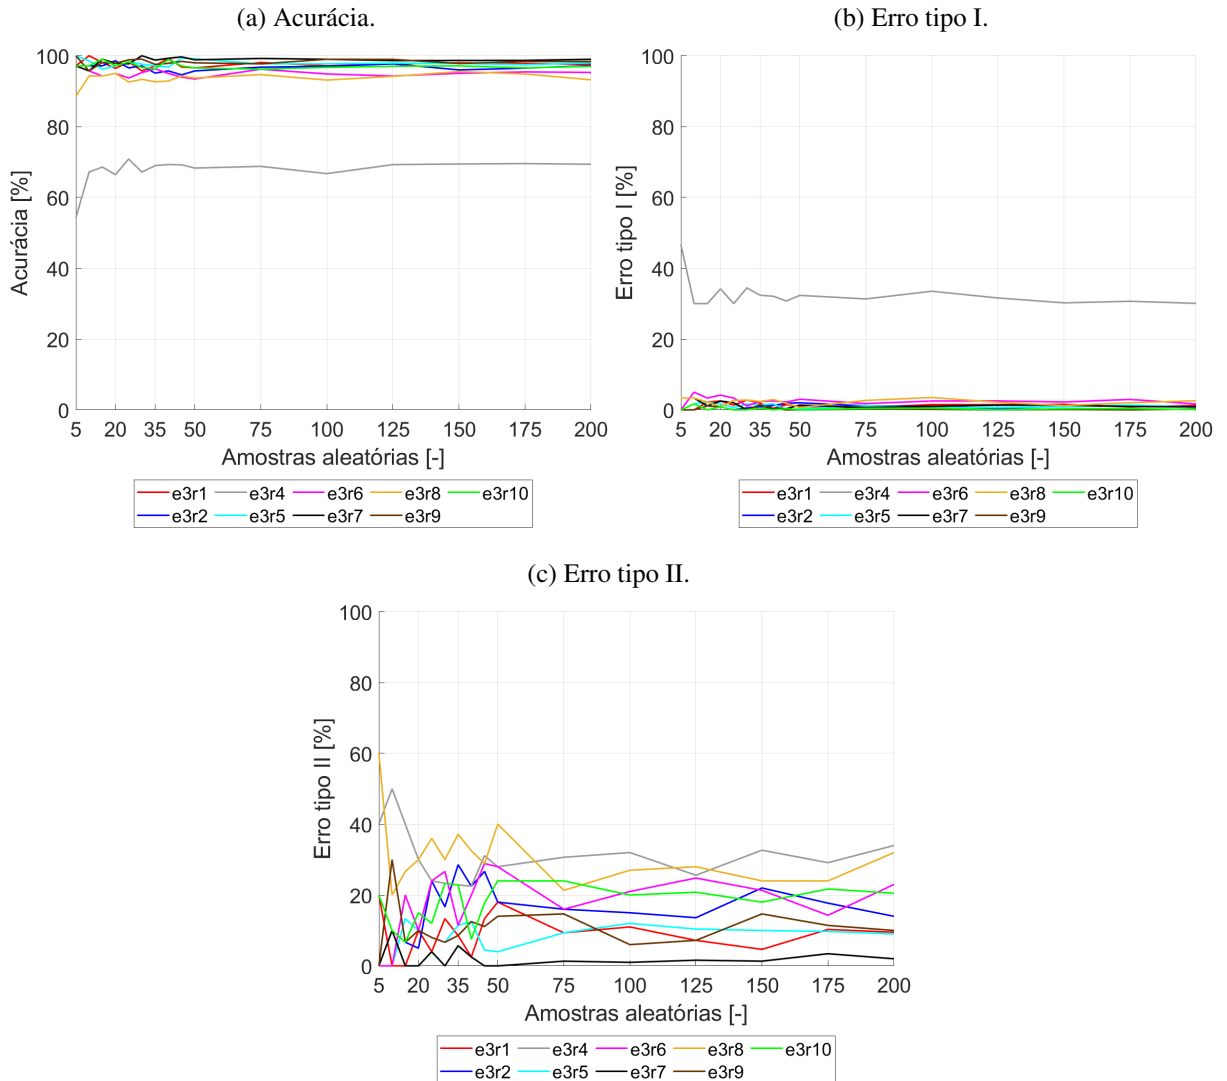
Já na Figura 42, os pares de sensores e3r1, e3r2, e3r4, e3r5, e3r6, e3r7, e3r8, e3r9 e e3r10 são representados por linhas sólidas que representam os valores médios das taxas de acurácia e erros do tipo I e II. Nas Figuras 42a e 42b, os resultados mostram que o comportamento dos pares de sensores parecem ser semelhantes. Observa-se que as taxas possuem uma variação menor em relação aos pares com o transdutor 01 usado como atuador, porém as taxas também se tornam mais estáveis quando o número de amostras é aumentado. Nota-se que alguns pares de sensores realizam uma previsão menos precisa, e, conseqüentemente, esses mesmos pares possuem um erro do tipo I mais alto. Para um número de amostras aleatórias maior, verifica-se que as taxas de acurácia são superiores a 90%, exceto para o par de sensores e3r4 que tem uma taxa de aproximadamente 70%. Os pares de sensores e3r1, e3r2, e3r5, e3r7, e3r9 e e3r10 apresentaram taxas de acurácia superiores a 95%, obtendo as maiores acurácias entre as combinações de pares de sensores utilizando o transdutor 03 como atuador, seguido pelos pares de sensores e3r6 e e3r8 que obtiveram taxas de acurácia próximas de 95%. Em relação ao erro do tipo II, mostrado na Figura 42c, também verifica-se um dado menos consistente com maiores variações nas taxas de erro e maiores erros de previsão. Os pares de sensores preveem taxas de erros abaixo de 25%, exceto os pares de sensores e3r4 e e3r8 que apresentaram taxas de erro entre 25% e 35%.

Figura 41: Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II nos pares de sensores e1r2, e1r3, e1r4, e1r5, e1r6, e1r7, e1r8, e1r9 e e1r10 para o caso 3, dano I, frequência central de 45 kHz e 70 sinais aleatórios de *baseline*.



Fonte: Próprio Autor.

Figura 42: Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II nos pares de sensores e3r1, e3r2, e3r4, e3r5, e3r6, e3r7, e3r8, e3r9 e e3r10 para o caso 3, dano I, frequência central de 45 kHz e 150 sinais aleatórios de *baseline*.



Fonte: Próprio Autor.

Os demais pares de sensores, onde os transdutores 02, 04, 05, 06, 07, 08, 09 e 10 são os atuadores, apresentaram comportamentos parecidos com os pares onde os transdutores 01 e 03 foram os atuadores. Todos os pares de sensores onde o transdutor 04 foi o receptor, apresentaram as piores taxas de acurácia e erros, e em alguns casos onde o transdutor 08 foi o receptor, também obteve-se os piores resultados.

Em relação ao dano I, nos pares de sensores onde o transdutor 01 foi o atuador, obteve-se taxas de identificação do defeito superiores a 80%, exceto quando os receptores foram os transdutores 04 e 08. Já nos pares de sensores onde os transdutores 07 e 08 foram os atuadores, obteve-se taxas de identificação do defeito superiores a 80%, exceto quando o receptor foi o transdutor 04. Nos pares de sensores onde os transdutores 05 e 06 foram os atuadores, obteve-

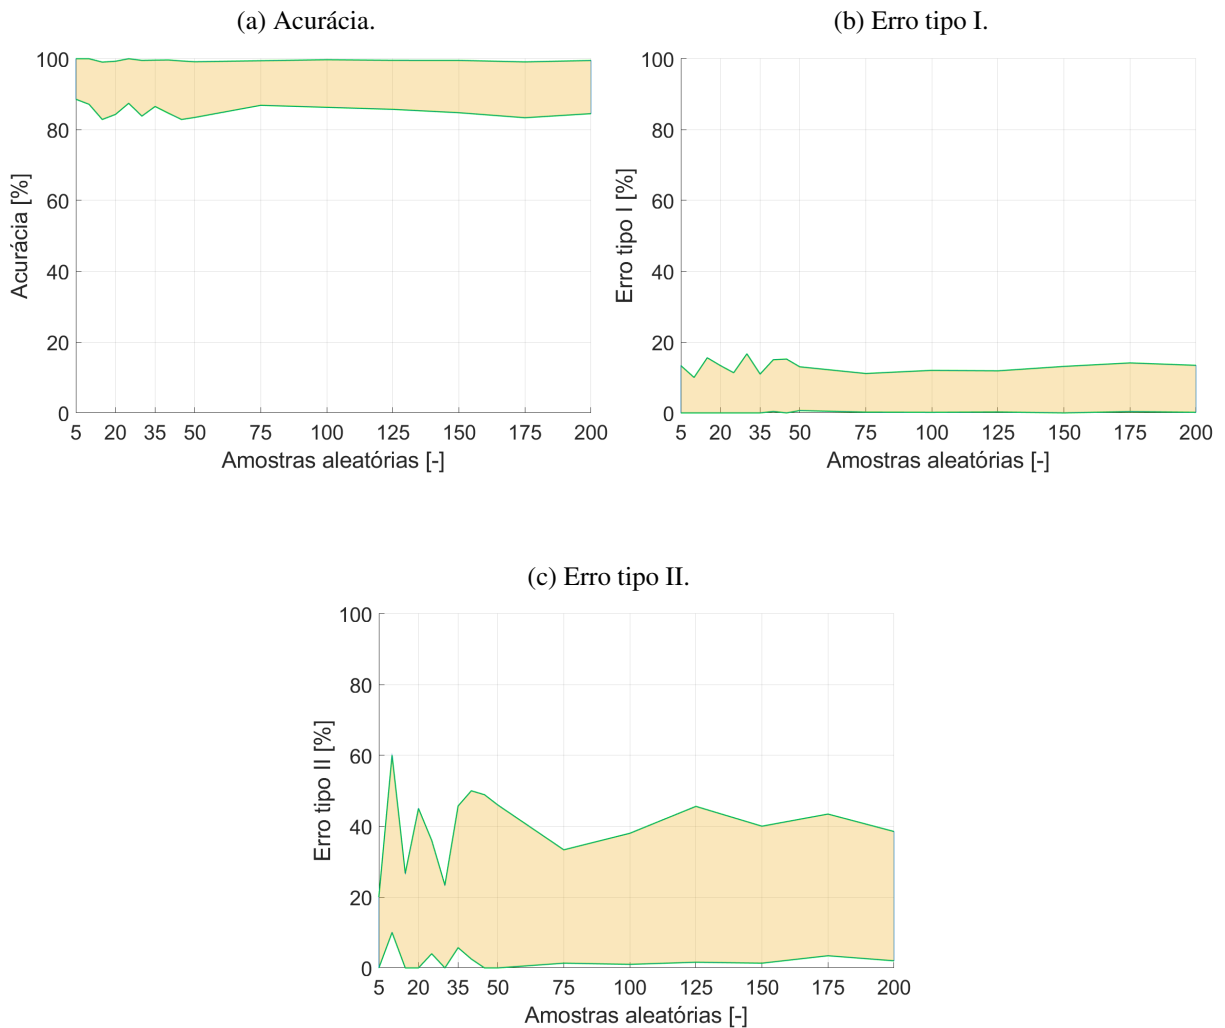
se taxas de identificação do defeito superiores a 90%, exceto quando os receptores foram os transdutores 04 e 08. Nos pares de sensores onde os transdutores 02, 03 e 10 foram os atuadores, obteve-se taxas de identificação do defeito superiores a 90%, exceto quando o receptor foi o transdutor 04. Nos pares de sensores onde o transdutor 09 foi o atuador, obteve-se taxas de identificação do defeito superiores a 90%, exceto quando os receptores foram os transdutores 04 e 08. Por último, nos pares de sensores onde o transdutor 04 foi o atuador, obteve-se taxas de identificação do defeito superiores a 90% em todos os casos.

Na Figura 43 são apresentados os resultados das taxas de acurácia e erros do tipo I e II para todas as combinações de pares de sensores, exceto para algumas combinações onde os transdutores 04 e 08 foram usados como receptores, devido apresentarem instabilidade na resposta. As linhas sólidas representam o resultado de um determinado par de sensores que obteve a menor taxa e de outro par de sensores que obteve a maior taxa. Já a região sombreada, entre as duas linhas sólidas, representa a faixa de taxas de todas as combinações de pares de sensores emissor e receptor. Quando não há uma "nova informação estatística", as componentes dos dois conjuntos de componentes serão muito similares. Dessa forma, o erro do tipo II tende a ser maior em consequência da maior probabilidade de uma determinada componente do segundo conjunto de componentes se relacionar mais de uma vez com as componentes do primeiro conjunto.

Através dos resultados apresentados, observou-se que os pares de sensores com um número maior de sinais aleatórios de *baseline* tendem a obter as melhores taxas de identificação do defeito. Uma das variáveis que pode influenciar os resultados é a fabricação manual dos sensores, que pode produzir variações nas respostas de cada par. Nesse caso, realizaram-se medições de impedância na faixa de frequências estudada e selecionaram-se os sensores que obtiveram respostas semelhantes. Porém, durante o processo de instalação dos sensores no painel, os mesmos podem ter sido danificados por algum tipo de impacto, por exemplo, e conseqüentemente alterado as suas respostas, o qual pode ter sido a causa dos piores resultados para os transdutores 04 e 08 como receptores. Das muitas variáveis que podem influenciar os resultados, algumas são impossíveis de dissociar. A condição de ruído ambiente e variações de temperatura, altas para aplicações de ondas guiadas, e a complexidade da estrutura também podem influenciar nas respostas.

Finalmente, considerando-se todas essas variáveis e comparando-se as taxas de erros com outras abordagens que utilizaram o algoritmo ICA para a detectabilidade de danos [45], o qual apresentaram taxas similares às apresentadas nesse trabalho, pode-se dizer que o método proposto mostrou-se robusto com taxas admissíveis de identificação de danos.

Figura 43: Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II em todas as combinações de pares de sensores para o caso 3, dano I e frequência central de 45 kHz.



Fonte: Próprio Autor.

5.2.2 Dano II

Nas Figuras 44 e 45 são apresentados os resultados da influência do número de realizações aleatórias na acurácia e nos erros tipo I e II nos pares de sensores onde os transdutores 01 e 03 são os atuadores para o dano II e caso 3 de intervalo de *lag*. Para analisar a influência do número de realizações aleatórias e do par de sensores, utilizou-se a média da acurácia considerando a estrutura intacta e danificada em todos os estágios de profundidade, conforme o número de realizações aleatórias. Quanto ao erro do tipo I, utilizou-se a média das taxas de erro considerando apenas a estrutura danificada em todos os estágios de profundidade, de acordo com o número de realizações aleatórias. Por fim, para o erro do tipo II foi considerado o valor da taxa de erro considerando apenas a estrutura intacta, de acordo com o número de realizações aleatórias.

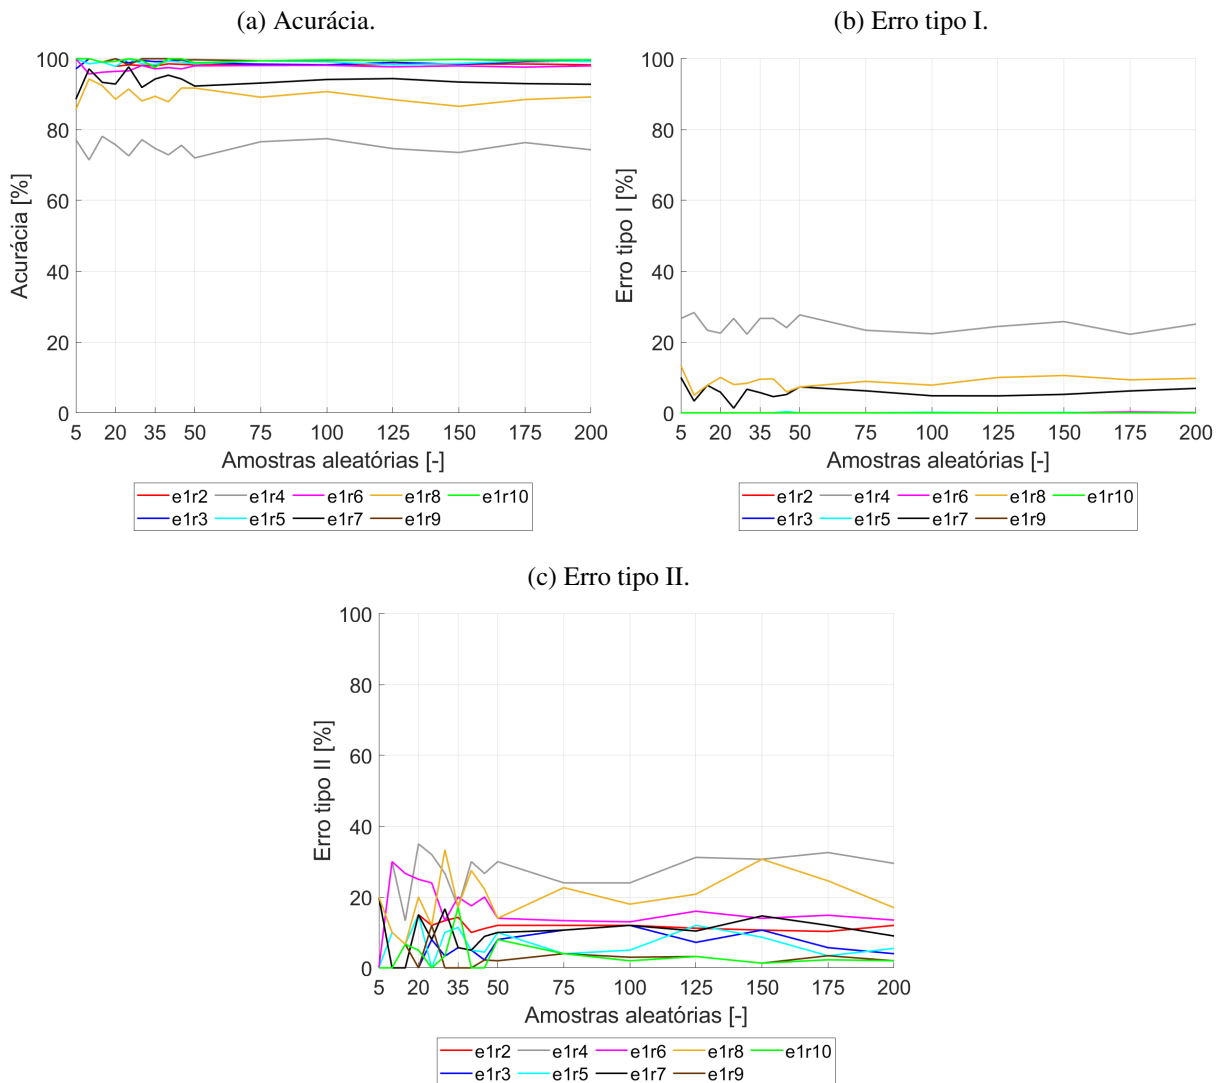
Na Figura 44, os pares de sensores e1r2, e1r3, e1r4, e1r5, e1r6, e1r7, e1r8, e1r9 e e1r10

são representados por linhas sólidas que representam os valores médios das taxas de acurácia e erros do tipo I e II. Assim como apresentado para o dano I, nas Figuras 44a e 44b, os resultados mostram que o comportamento dos pares de sensores parecem ser semelhantes e observa-se que as taxas se tornam mais estáveis quando o número de amostras é aumentado. Também observa-se que alguns pares de sensores realizam uma previsão menos precisa, e, conseqüentemente, esses mesmos pares possuem um erro do tipo I mais alto. Considerando um número maior de amostras aleatórias, observa-se que as taxas de acurácia para os pares de sensores e1r2, e1r3, e1r5, e1r6, e1r9 e e1r10 são muito próximas de 100%. Já o par de sensores e1r7 apresentou taxa de acurácia pouco abaixo de 95%, e1r8 apresentou taxa de aproximadamente 90%, e e1r4 apresentou taxa de acurácia pouco inferior a 80%. Em relação ao erro do tipo II, mostrado na Figura 44c, verifica-se um dado menos consistente com maiores variações nas taxas de erro, principalmente nos pares de sensores e1r4 e e1r8, e maiores erros de previsão. Os pares de sensores preveem taxas de erros abaixo de 20%, exceto os pares de sensores e1r4 e e1r8 que apresentaram taxas de erro na faixa de 15% a 35%.

Já na Figura 45, os pares de sensores e3r1, e3r2, e3r4, e3r5, e3r6, e3r7, e3r8, e3r9 e e3r10 são representados por linhas sólidas que representam os valores médios das taxas de acurácia e erros do tipo I e II. Da mesma forma que nos pares de sensores apresentados anteriormente, nas Figuras 45a e 45b os resultados mostram que o comportamento dos pares parecem ser semelhantes. Observa-se que as taxas possuem pouca variação, no entanto as taxas também se tornam mais estáveis quando o número de amostras é aumentado. Nota-se que alguns pares de sensores realizam uma previsão menos precisa, e, conseqüentemente, esses mesmos pares possuem um erro do tipo I mais alto. Verifica-se que as taxas de acurácia para os pares de sensores e3r1, e3r2, e3r5, e3r6, e3r7, e3r8, e3r9 e e3r10 são muito próximas de 100%. Já o par de sensores e3r4 apresentou uma taxa próxima de 90%. Em relação ao erro do tipo II, mostrado na Figura 45c, também verifica-se um dado menos consistente com maiores variações nas taxas de erro, principalmente no par de sensores e3r4, e maiores erros de previsão. Os pares de sensores preveem taxas de erros abaixo de 20%, exceto o par de sensor e3r4 que apresentou taxa de erro de aproximadamente 35%.

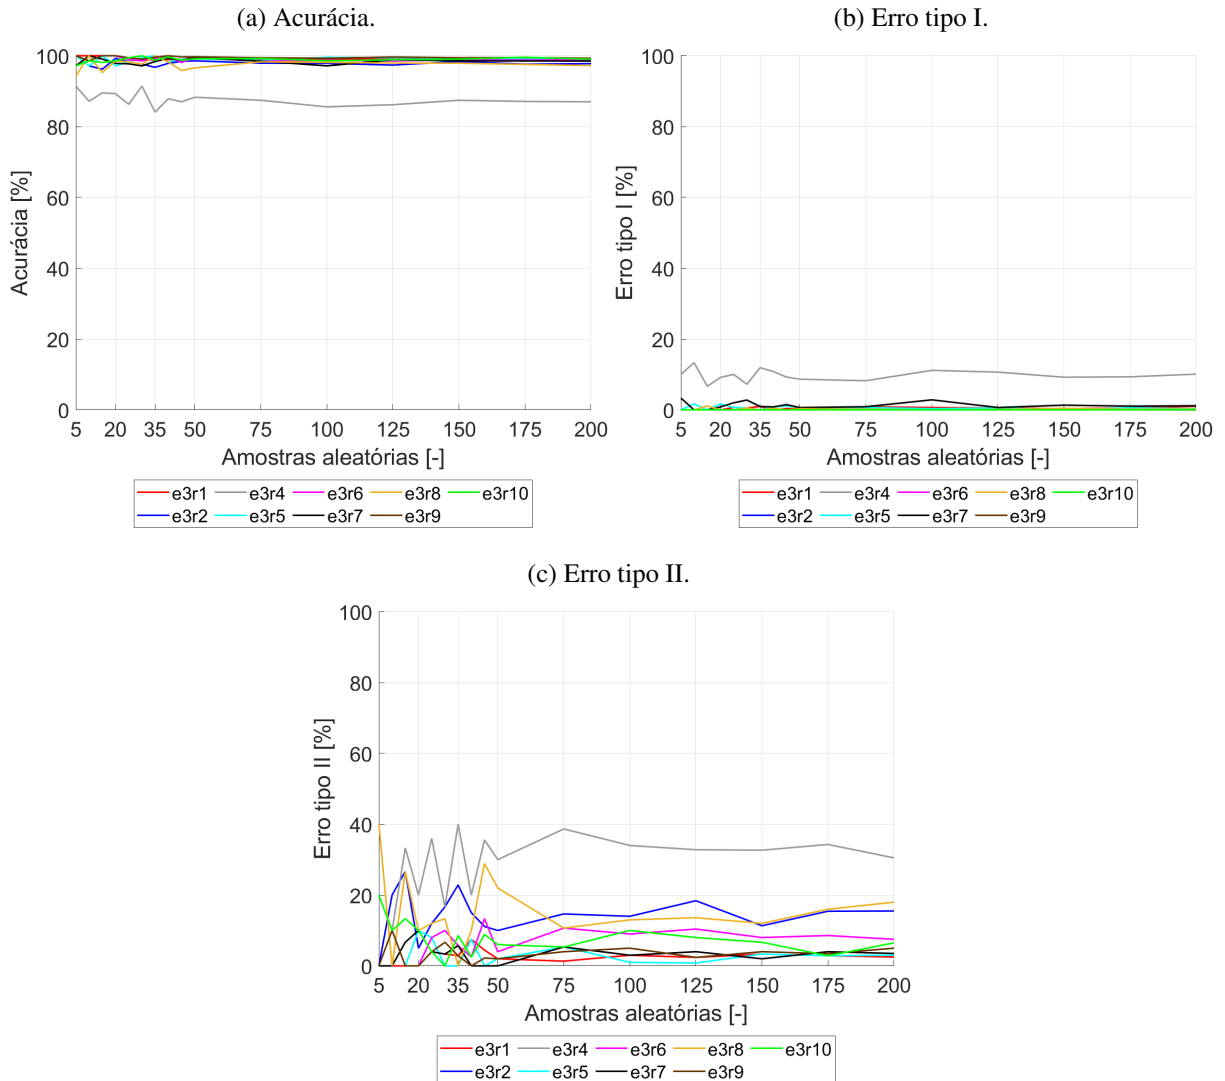
Da mesma forma que os resultados do dano I, os demais pares de sensores para o dano II, onde os transdutores 02, 04, 05, 06, 07, 08, 09 e 10 são os atuadores, apresentaram comportamentos parecidos com os pares onde os transdutores 01 e 03 foram os atuadores. Todos os pares de sensores onde o transdutor 04 foi o receptor, apresentaram as piores taxas de acurácia e erros, e em alguns casos onde o transdutor 08 foi o receptor, também obteve-se os piores resultados.

Figura 44: Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II nos pares de sensores e1r2, e1r3, e1r4, e1r5, e1r6, e1r7, e1r8, e1r9 e e1r10 para o caso 3, dano II, frequência central de 45 kHz e 70 sinais aleatórios de *baseline*.



Fonte: Próprio Autor.

Figura 45: Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II nos pares de sensores e3r1, e3r2, e3r4, e3r5, e3r6, e3r7, e3r8, e3r9 e e3r10 para o caso 3, dano II, frequência central de 45 kHz e 150 sinais aleatórios de *baseline*.

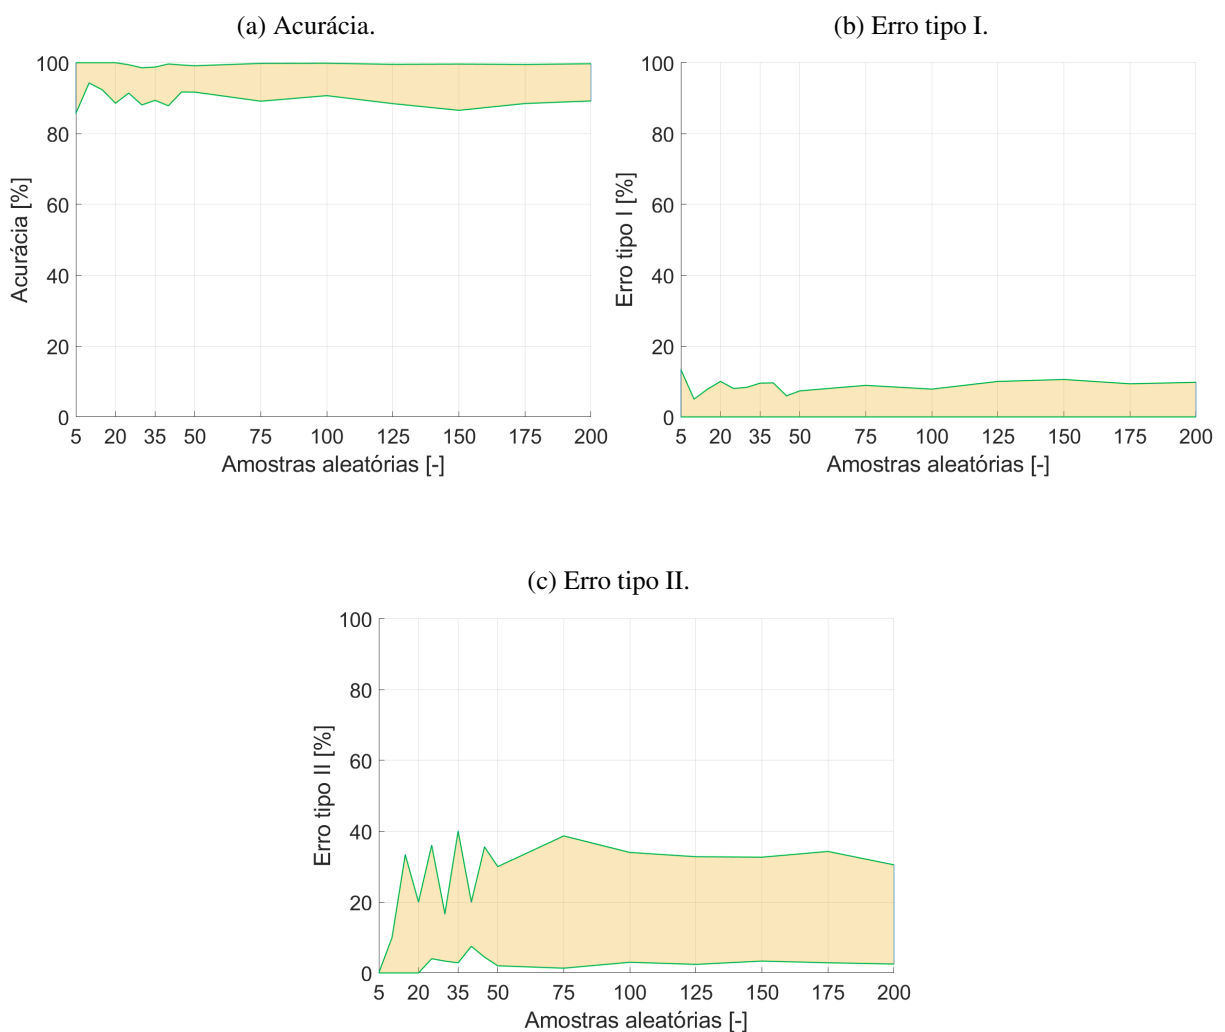


Fonte: Próprio Autor.

Quanto ao dano II, no par de sensores onde o transdutor 01 foi o atuador, obteve-se taxas de identificação do defeito superiores a 90%, exceto quando o receptor foi o transdutor 04. Nos pares de sensores onde os transdutores 05 e 07 foram os atuadores, obteve-se taxas de identificação do defeito superiores a 95%, exceto quando os receptores foram os transdutores 04 e 08. Nos pares de sensores onde os transdutores 02, 03, 08, 09 e 10 foram os atuadores, obteve-se taxas de identificação do defeito superiores a 95%, exceto quando o receptor foi o transdutor 04. Já no par de sensor onde o transdutor 06 foi o atuador, obteve-se taxas de identificação do defeito próximas a 100%, exceto quando os receptores foram os transdutores 04 e 08. Por último, no par de sensor onde o transdutor 04 foi o atuador, obteve-se taxas de identificação do defeito superiores a 95% em todos os casos.

Na Figura 46 são apresentados os resultados das taxas de acurácia e erros do tipo I e II para todas as combinações de pares de sensores, exceto para algumas combinações onde os transdutores 04 e 08 foram usados como receptores, devido apresentarem instabilidade na resposta. As linhas sólidas representam o resultado de um determinado par de sensores que obteve a menor taxa e de outro par de sensores que obteve a maior taxa. Já a região sombreada, entre as duas linhas sólidas, representa a faixa de taxas de todas as combinações de pares de sensores emissor e receptor. Os erros do tipo II tendem a serem maiores devido ao mesmo motivo descrito nos resultados do dano I.

Figura 46: Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II em todas as combinações de pares de sensores para o caso 3, dano II e frequência central de 45 kHz.



Fonte: Próprio Autor.

Assim como no dano I, para o dano II também observou-se que os pares de sensores com um número maior de sinais aleatórios de *baseline* tendem a obter as melhores taxas de identificação do defeito. Além disso, observou-se que as taxas de identificação do defeito para o dano II

foram superiores as taxas relacionadas ao dano I. As melhores taxas de acurácia para o dano II podem ser relacionadas aos maiores valores de amplitude de pico, conforme mostrado nas Figuras 35 e 36. Portanto, quanto maior os valores de amplitude de pico, mais sensível é a detecção do dano. Por último, as mesmas variáveis descritas nos resultados do dano I podem ser a causa dos piores resultados para os transdutores 04 e 08 como receptores.

5.3 Resultados da Quantificação dos Danos

Nesta seção são apresentados e discutidos os resultados da aplicação do método na quantificação dos danos I e II em todos os níveis de profundidade a partir da análise dos valores dos SNRs das componentes *outliers*.

5.3.1 Dano I

Nas Figuras 47 a 52 são apresentados os SNRs *versus* danos para todos os estágios de profundidade para os pares de sensores que se mostraram mais sensíveis na quantificação das diferentes profundidades do dano I, para o caso 3 de intervalo de *lag*, com 200 amostras e frequência central de 45 kHz. A partir da Figura 47a, por exemplo, pode-se observar uma relação sigmoide, por meio da curva sigmoide, entre os SNRs dos *outliers* e o dano na estrutura, o qual pode ser usada para estimar a gravidade do dano. No entanto, observou-se a clara dependência do par de sensores na sensibilidade ao defeito. Ao contrário dos resultados obtidos para a identificação do dano I, onde as variáveis como o caminho da onda (par de sensores) não tiveram influência, na quantificação exerce influência. Os resultados da regressão usando a função sigmoide nos *outliers* dos pares de sensores são representados por uma linha sólida e os limites de confiança de 95% são representados pelas linhas tracejadas. Nas Tabelas 15 e 16 são mostrados os valores obtidos na regressão para os pares de sensores apresentados.

É possível traçar algumas relações entre os caminhos da onda, mostrados na Figura 28b, e os resultados dos SNRs *versus* danos, apresentados nas Figuras 47 a 52. Além da influência de caminhos e elementos estruturais soldados, o próprio dano produz conversão de modo. Assim, mais energia é perdida, tornando a quantificação ainda mais desafiadora. Algumas combinações de pares de sensores emissores e receptores utilizando transdutores de números 01 a 06, mostraram-se mais sensíveis para a quantificação dos níveis de profundidade do dano. A "melhor quantificação" significa uma inclinação na curva sigmoide. Em todas estas combinações, o transdutor atuador possui o número máximo de sinais de *baseline* testados, ou seja, 150 sinais aleatórios de *baseline*. Os resultados da quantificação dos pares de sensores e2r3, e2r5, e3r2, e5r2 e e6r7 podem ser justificados pela passagem da onda guiada no dano. Já os pares de sensores e3r1, e3r5, e3r6, e4r3, e4r6, e5r3 e e6r3 não possuem a passagem da onda guiada no dano, porém, os resultados satisfatórios podem ser justificados pela localização de um transdutor, emissor ou receptor, próximo ao dano e pela ausência de elementos estruturais soldados entre este transdutor e o dano.

Tabela 15: Valores obtidos na regressão usando a função sigmóide nos *outliers* para o caso 3 com 200 realizações aleatórias, dano I e frequência central de 45 kHz.

	e2r3	e2r5	e3r1	e3r2	e3r5	e3r6
a	-1.889e+04	-1.994e+04	3844	-2.471e+04	3739	3.227e+04
b	-3.857e+04	-3.141e+04	5.749e+04	-3.128e+05	7.544e+04	3.754e+04
c	7.208	8.084	1.848	-2.159	-6.286	8.186
d	-1.094	-1.456	-1.087	-0.8751	-0.8945	-1.316
e	-587.8	-499	787.5	-4076	953.5	624.4
r^2	0.9957	0.9936	0.9527	0.9738	0.9867	0.9930

Fonte: Próprio Autor.


Tabela 16: Valores obtidos na regressão usando a função sigmóide nos *outliers* para o caso 3 com 200 realizações aleatórias, dano I e frequência central de 45 kHz.

	e4r3	e4r6	e5r2	e5r3	e6r3	e6r7
a	13.98	1.243e+04	6.064e+04	-3.863e+04	-4.115e+04	-4265
b	407.4	8.854e+04	7.436e+04	-3.254e+05	-1.61e+05	-7.816e+04
c	-8.444	1.81	9.464	5.144	5.547	-5.13
d	-1.172	-0.8593	-1.353	-1.099	-1.123	-1.62
e	5.112	1149	1344	-4914	-2388	-1008
r^2	0.9214	0.9971	0.9842	0.9680	0.9889	0.9686

Fonte: Próprio Autor.

Figura 47: SNRs *versus* danos nos pares de sensores e2r3 e e2r5 para o caso 3 com 200 amostras, dano I e frequência central de 45 kHz.


(a) SNRs para o par de sensores e2r3 com 150 sinais aleatórios de *baseline* e 25 componentes independentes. (b) SNRs para o par de sensores e2r5 com 150 sinais aleatórios de *baseline* e 20 componentes independentes.



Fonte: Próprio Autor.

Figura 48: SNRs *versus* danos nos pares de sensores e3r1 e e3r2 para o caso 3 com 200 amostras, dano I e frequência central de 45 kHz.


(a) SNRs para o par de sensores e3r1 com 150 sinais aleatórios de *baseline* e 20 componentes independentes. (b) SNRs para o par de sensores e3r2 com 150 sinais aleatórios de *baseline* e 25 componentes independentes.



Fonte: Próprio Autor.

Figura 49: SNRs *versus* danos nos pares de sensores e3r5 e e3r6 para o caso 3 com 200 amostras, dano I e frequência central de 45 kHz.

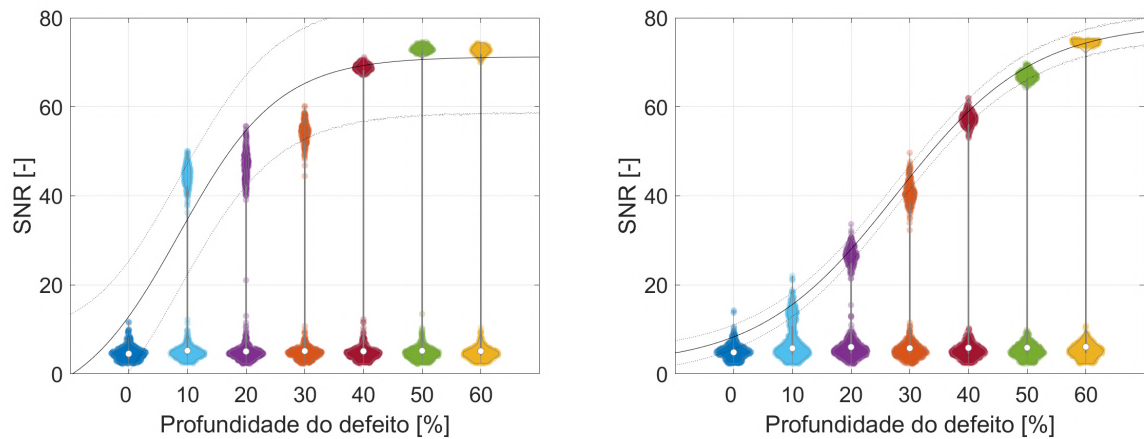
(a) SNRs para o par de sensores e3r5 com 150 sinais aleatórios de *baseline* e 20 componentes independentes. (b) SNRs para o par de sensores e3r6 com 150 sinais aleatórios de *baseline* e 25 componentes independentes.



Fonte: Próprio Autor.

Figura 50: SNRs *versus* danos nos pares de sensores e4r3 e e4r6 para o caso 3 com 200 amostras, dano I e frequência central de 45 kHz.

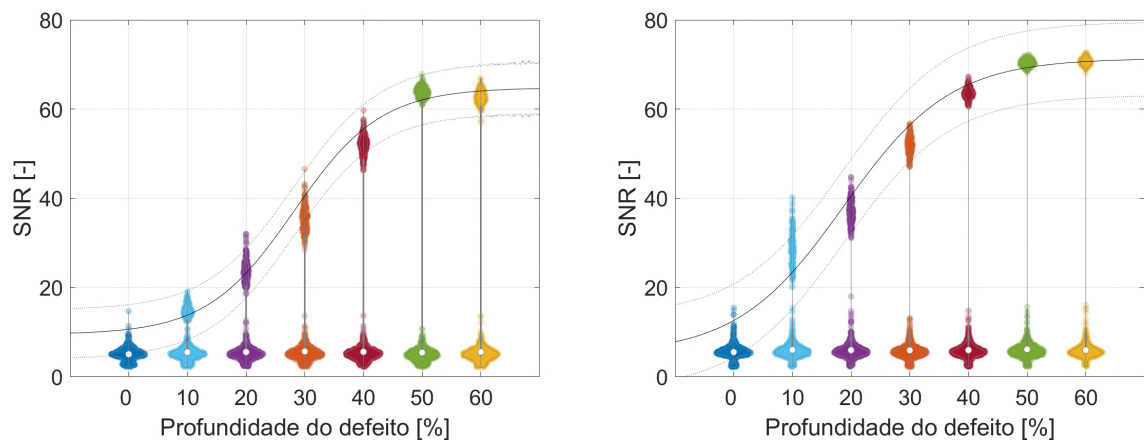
(a) SNRs para o par de sensores e4r3 com 150 sinais aleatórios de *baseline* e 20 componentes independentes. (b) SNRs para o par de sensores e4r6 com 150 sinais aleatórios de *baseline* e 20 componentes independentes.



Fonte: Próprio Autor.

Figura 51: SNRs *versus* danos nos pares de sensores e5r2 e e5r3 para o caso 3 com 200 amostras, dano I e frequência central de 45 kHz.

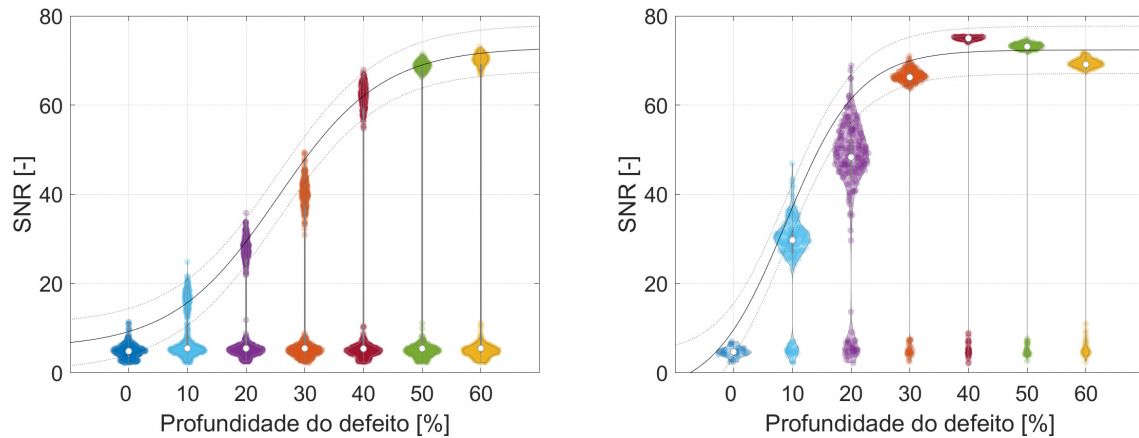
(a) SNRs para o par de sensores e5r2 com 150 sinais aleatórios de *baseline* e 20 componentes independentes. (b) SNRs para o par de sensores e5r3 com 150 sinais aleatórios de *baseline* e 25 componentes independentes.



Fonte: Próprio Autor.

Figura 52: SNRs *versus* danos nos pares de sensores e6r3 e e6r7 para o caso 3 com 200 amostras, dano I e frequência central de 45 kHz.

(a) SNRs para o par de sensores e6r3 com 150 sinais aleatórios de *baseline* e 20 componentes independentes. (b) SNRs para o par de sensores e6r7 com 150 sinais aleatórios de *baseline* e 10 componentes independentes.



Fonte: Próprio Autor.

Observou-se, através dos resultados apresentados, que os SNRs dos *outliers* dos pares de sensores com um número maior de sinais aleatórios de *baseline* mostraram-se mais sensíveis para a quantificação do dano, permitindo estimar a profundidade do mesmo. Além disso, observou-se que o SNR é relativamente sensível para estimar a profundidade de danos com profundidades menores, permitindo estimar a profundidade de danos nas fases iniciais. Já para danos com profundidades maiores, o SNR é menos sensível para estimar a profundidade. A menor sensibilidade para danos com maiores profundidades é uma característica do próprio modelo desenvolvido. Por fim, como o método desenvolvido não realiza a localização de danos, não é possível definir o melhor par de sensores. A partir da localização do dano, possivelmente pode-se escolher o melhor par de sensores para realizar a quantificação do dano através do SNR.

5.3.2 Dano II

Nas Figuras 53 a 58 são apresentados os SNRs *versus* danos para todos os estágios de profundidade de alguns pares de sensores que mostraram certa sensibilidade na quantificação do dano II, principalmente nos estágios iniciais de profundidade, para o caso 3 de intervalo de *lag*, com 200 amostras e frequência central de 45 kHz. Conforme mostrado na Figura 53b, por exemplo, observa-se uma relação sigmoide, por meio da curva sigmoide, entre os SNRs dos *outliers* e o dano na estrutura, o qual pode ser usada para estimar a gravidade do dano. Porém, observou-se que o SNR do dano II é significativamente menos sensível que o SNR do dano I para estimar a profundidade do dano, justamente por tratar-se de um dano mais severo. Por essa razão, não conseguiu-se verificar com clareza a dependência do par de sensores na sensibilidade ao defeito. Ao contrário dos resultados obtidos para a identificação do dano II, onde as variáveis como o caminho da onda (par de sensores) não tiveram influência, na quantificação exerce

influência, porém para o dano II não conseguiu-se traçar alguma relação entre o caminho da onda e os resultados dos pares de sensores apresentados devido à menor sensibilidade do SNR para estimar a profundidade do dano. Os resultados da regressão usando a função sigmóide nos *outliers* dos pares de sensores são representados por uma linha sólida e os limites de confiança de 95% são representados pelas linhas tracejadas. Nas Tabelas 17 e 18 são mostrados os valores obtidos na regressão para os pares de sensores apresentados.

Conforme observado na quantificação do dano I, o SNR é menos sensível para estimar a profundidade de danos com profundidades maiores. Considerando-se que o dano II trata-se de cinco rebaixos circulares usinados em seis estágios de profundidade no entorno do dano I já com 60% de perda de espessura, pode-se afirmar que o dano II é mais severo que o dano I. Por essa razão, o SNR mostrou-se menos sensível para estimar a profundidade do dano II.

Tabela 17: Valores obtidos na regressão usando a função sigmóide nos *outliers* para o caso 3 com 200 realizações aleatórias, dano II e frequência central de 45 kHz.

	e1r6	e1r10	e2r8	e4r8	e6r4	e7r1
a	-5654	-2244	15.56	-13.99	1990	17.99
b	-8.921e+04	-1.702e+04	285.7	-193.1	3.232e+04	163.5
c	-5.973	-0.4048	-0.8881	0.8098	-1.24	2.47
d	-2.089	-1.243	-1.264	-1.83	-0.5739	-1.542
e	-2175	-472.3	3.925	-2.847	654.4	6.48
r^2	0.9934	0.9889	0.9187	0.9198	0.9060	0.8574

Fonte: Próprio Autor.


Tabela 18: Valores obtidos na regressão usando a função sigmóide nos *outliers* para o caso 3 com 200 realizações aleatórias, dano II e frequência central de 45 kHz.

	e7r5	e9r2	e9r3	e9r4	e9r6	e10r6
a	18.4	-36.27	6.81	1891	3842	1.606
b	207.7	-67.03	61.17	8172	4.085e+04	23.06
c	-0.2492	5.693	-2.926	8.372	-3.998	0.8664
d	-1.596	-2.483	-2.682	-1.633	-1.705	-1.248
e	6.576	-2.459	1.676	353.4	1127	0.6092
r^2	0.9394	0.9600	0.9832	0.9012	0.9869	0.9259

Fonte: Próprio Autor.

Figura 53: SNRs *versus* danos nos pares de sensores e1r6 e e1r10 para o caso 3 com 200 amostras, dano II e frequência central de 45 kHz.

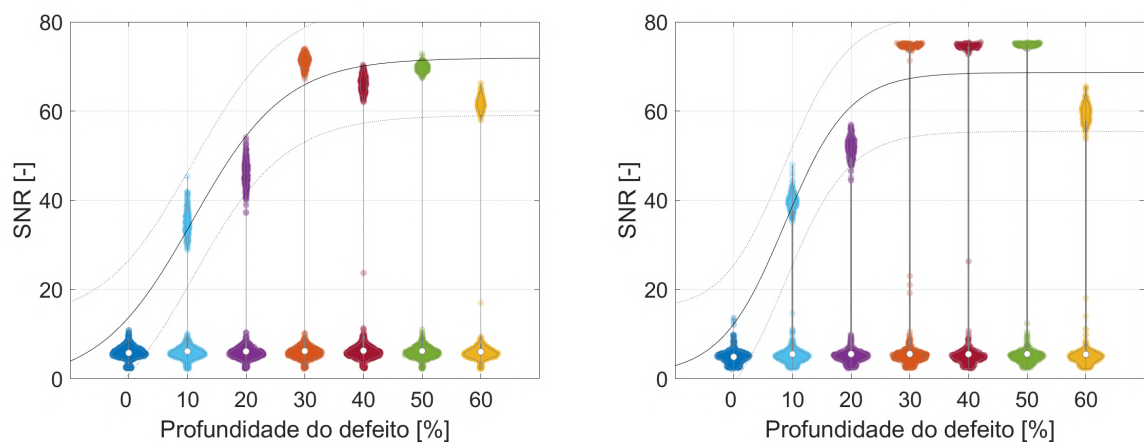
(a) SNRs para o par de sensores e1r6 com 70 sinais aleatórios de *baseline* e 10 componentes independentes. (b) SNRs para o par de sensores e1r10 com 70 sinais aleatórios de *baseline* e 5 componentes independentes.



Fonte: Próprio Autor.

Figura 54: SNRs *versus* danos nos pares de sensores e2r8 e e4r8 para o caso 3 com 200 amostras, dano II e frequência central de 45 kHz.

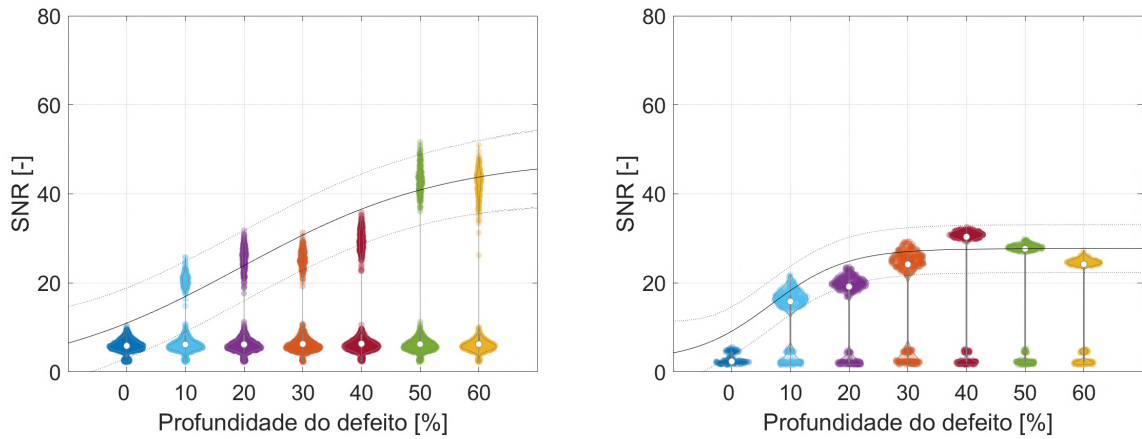
(a) SNRs para o par de sensores e2r8 com 150 sinais aleatórios de *baseline* e 25 componentes independentes. (b) SNRs para o par de sensores e4r8 com 150 sinais aleatórios de *baseline* e 20 componentes independentes.



Fonte: Próprio Autor.

Figura 55: SNRs *versus* danos nos pares de sensores e6r4 e e7r1 para o caso 3 com 200 amostras, dano II e frequência central de 45 kHz.

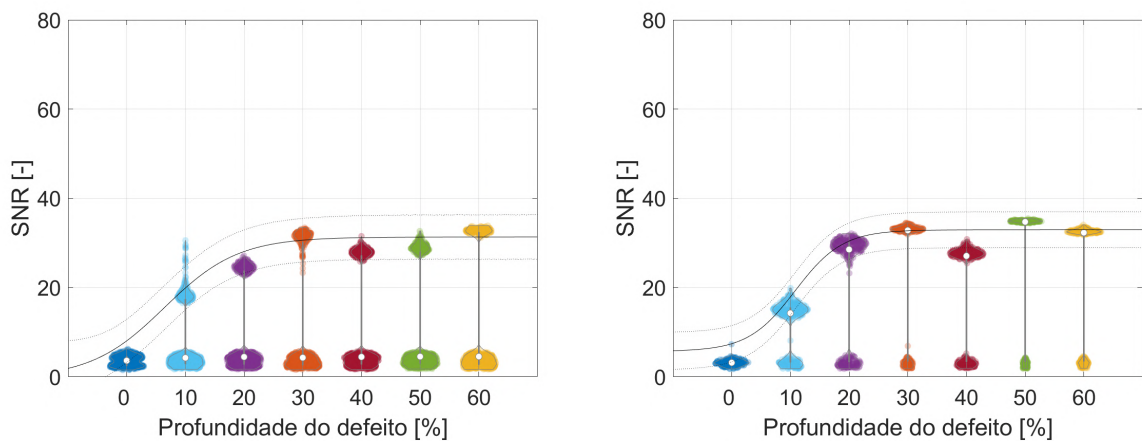
(a) SNRs para o par de sensores e6r4 com 150 sinais aleatórios de *baseline* e 25 componentes independentes. (b) SNRs para o par de sensores e7r1 com 70 sinais aleatórios de *baseline* e 5 componentes independentes.



Fonte: Próprio Autor.

Figura 56: SNRs *versus* danos nos pares de sensores e7r5 e e9r2 para o caso 3 com 200 amostras, dano II e frequência central de 45 kHz.

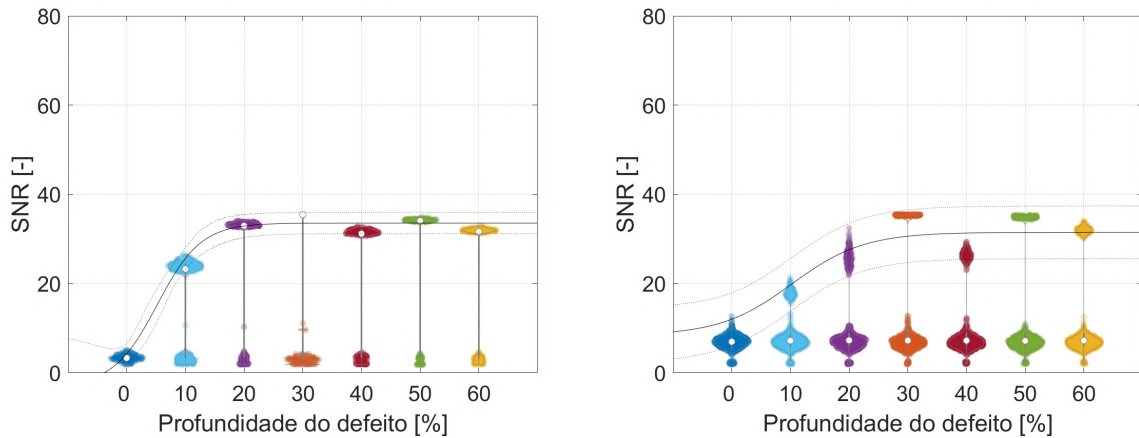
(a) SNRs para o par de sensores e7r5 com 70 sinais aleatórios de *baseline* e 10 componentes independentes. (b) SNRs para o par de sensores e9r2 com 70 sinais aleatórios de *baseline* e 5 componentes independentes.



Fonte: Próprio Autor.

Figura 57: SNRs *versus* danos nos pares de sensores e9r3 e e9r4 para o caso 3 com 200 amostras, dano II e frequência central de 45 kHz.

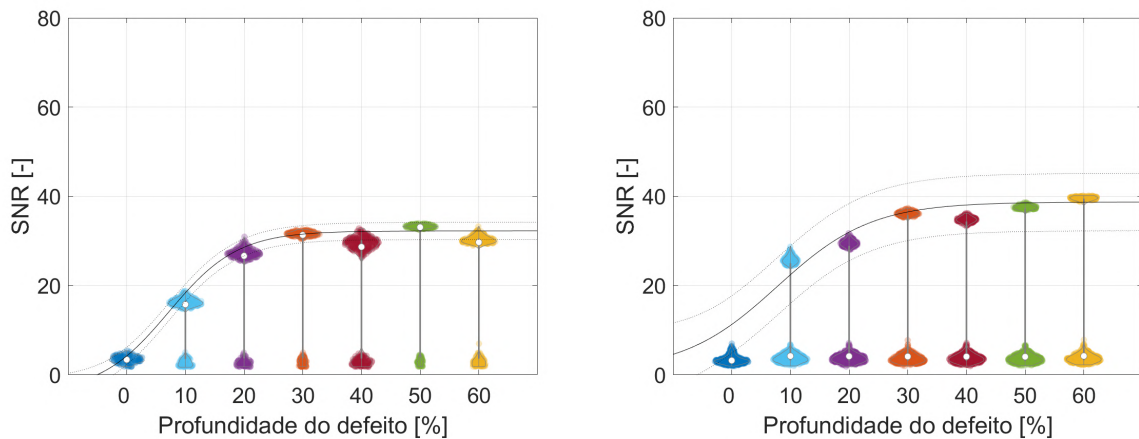
(a) SNRs para o par de sensores e9r3 com 70 sinais aleatórios de *baseline* e 5 componentes independentes. (b) SNRs para o par de sensores e9r4 com 70 sinais aleatórios de *baseline* e 25 componentes independentes.



Fonte: Próprio Autor.

Figura 58: SNRs *versus* danos nos pares de sensores e9r6 e e10r6 para o caso 3 com 200 amostras, dano II e frequência central de 45 kHz.

(a) SNRs para o par de sensores e9r6 com 70 sinais aleatórios de *baseline* e 5 componentes independentes. (b) SNRs para o par de sensores e10r6 com 80 sinais aleatórios de *baseline* e 10 componentes independentes.



Fonte: Próprio Autor.

De modo geral, a partir dos resultados apresentados nas Figuras 53 a 58, verificou-se, através da distância entre os SNRs dos *outliers* das diferentes profundidades, que foi possível estimar a profundidade através do SNR somente nas profundidades menores, mostrando-se menos sensível nas profundidades maiores. Por último, como o método desenvolvido não realiza a localização de danos, não é possível definir o melhor par de sensores. A partir da localização do dano, possivelmente pode-se escolher o melhor par de sensores para realizar a quantificação

do dano através do SNR.

Quanto ao dano II, por possuir uma severidade maior que o dano I, os SNRs dos *outliers* mostraram-se menos sensíveis para estimar a profundidade do dano. Os melhores resultados de quantificação para o dano I podem ser relacionadas aos valores crescentes de amplitude de pico de 0 a 60% de perda de espessura em alguns números de componentes independentes, conforme mostrado na Figura 35. Da mesma forma, os piores resultados de quantificação para o dano II podem ser relacionadas a estabilização dos valores de amplitude de pico em todas as profundidades, conforme mostrado na Figura 36.

6 CONCLUSÕES

Nesse trabalho, foi proposto um método para detectar e quantificar danos relacionados à redução de espessura em estruturas complexas e de difícil acesso, como tanques de armazenamento de FPSOs, por meio de dados de dimensão reduzida de um sistema SHM de ondas guiadas permanentemente instalado em uma estrutura. O método mostrou-se independente da temperatura e de outras condições ambientais. Além disso, o pré-processamento utilizado nos dados de ondas guiadas foi muito simples, sem a necessidade de processamentos complexos.

Um estudo variando o número de componentes independentes do ICA e o número de sinais aleatórios de *baseline* mostrou que conforme o número de componentes aumenta, os valores de amplitude de pico da componente dos pesos na posição do sinal do defeito também aumentam, principalmente em danos menos severos devido os mesmos tenderem a ter um valor de amplitude de pico mais baixo que os danos mais severos. Para os danos mais severos, a estabilização do aumento dos valores de amplitude de pico ocorre com números menores de componentes. Além disso, à medida que é aumentado o número de componentes, os valores de amplitude de pico dos danos menos severos tendem a se estabilizar com os valores de amplitude de pico dos danos mais severos. Por último, conforme o número de sinais aleatórios de *baseline* é aumentado, os valores de amplitude de pico em cada número de componentes tendem a diminuir, principalmente para danos menos severos.

Os melhores resultados obtidos para a detecção e quantificação dos danos foram com o número de componentes independentes que obteve valores de amplitude de pico a partir de aproximadamente 0,5 para 150 sinais aleatórios de *baseline*, 0,65 para 100 sinais aleatórios e 0,8 para 50 sinais aleatórios. Além disso, os melhores resultados, principalmente na quantificação, foram com números de componentes que apresentaram valores crescentes de amplitude de pico de 0 a 60% de perda de espessura. Por fim, o uso de um número maior de sinais aleatórios de *baseline* apresentou os melhores resultados na detecção e na quantificação do dano.

Quanto à detecção de danos, a variação do intervalo de *lag* para a busca do valor máximo da correlação cruzada mostrou que a partir do menor intervalo de *lag* testado, obtiveram-se as maiores taxas de acurácia e as menores taxas de erros, principalmente do tipo I. Os melhores resultados foram obtidos com o caso 3 de *lag*, com faixa de *lag* de -2 a 2. Para o dano I, considerando todas as possíveis combinações de pares de sensores, obteve-se taxas médias de

acurácia acima de 80%, taxas de erro do tipo I abaixo de 20% e taxas de erro do tipo II abaixo de 40%. Já para o dano II, obteve-se taxas médias de acurácia acima de 90%, taxas de erro do tipo I abaixo de 10% e taxas de erro do tipo II abaixo de 40%. Salienta-se que estas taxas referem-se a todas as combinações e que dependendo do transdutor atuador e do par de sensores, as taxas foram significativamente melhores. Quanto menor o intervalo de *lag* para a busca do valor máximo da correlação cruzada e quanto maior o número de realizações aleatórias, mais estáveis são as médias da acurácia e das taxas de erro dos tipos I e II. Além disso, vale salientar que essas taxas tendem a serem formadas pelo limite inferior, uma vez que pequenos defeitos têm menor acurácia.

Por último, utilizando os valores de SNRs dos *outliers* da estrutura não danificada e danificada, foi possível quantificar o dano I em todos os estágios de profundidade em alguns pares de sensores. Já para o dano II, foi possível quantificar os danos menos severos em alguns pares de sensores. O ajuste de uma curva sigmoidal através da função sigmóide nos SNRs dos *outliers* permitiu quantificar a severidade dos danos com mais precisão. A estrutura não danificada sempre obteve os menores valores de SNRs dos *outliers*. Danos menos severos são indicados com valores de SNRs dos *outliers* mais baixos e danos mais severos com valores mais altos. Além disso, os resultados mostraram que a quantificação do dano é levemente influenciada pelo intervalo de *lag* para a busca do valor máximo da correlação cruzada e que o SNR é mais sensível para danos menos severos, permitindo, assim, estimar a profundidade de danos nas fases iniciais.

7 SUGESTÕES PARA TRABALHOS FUTUROS

Como sugestões para trabalhos futuros, novos estudos podem ser realizados para aperfeiçoar o método desenvolvido:

- Automatizar a seleção dos parâmetros de entrada do algoritmo como o número de sinais aleatórios de *baseline* e o número de componentes independentes do ICA;
- Complementar o método para além de detectar e quantificar os danos, também localizar os mesmos. Dessa forma, a partir da localização do dano, possivelmente poderá ser escolhido o melhor par de sensores para realizar a sua quantificação através do SNR;
- Realizar estudos para melhorar a quantificação de danos mais severos, obtendo, assim, um controle maior sobre a severidade do dano.

REFERÊNCIAS

- [1] A. A. Bidgoli, D. J. Dezan, L. O. Salviano, S. de Oliveira Junior, and J. I. Yanagihara, “Lifetime sensitivity analysis of fpos operating parameters on energy consumption and overall oil production in a pre-salt oil field,” *Chemical Engineering Communications*, vol. 207, no. 11, pp. 1483–1507, 2020.
- [2] G. L. N. Leal and H. A. Naked, “A fuzzy logic-possibilistic methodology to analyze the main corrosion damages mechanisms in pipes and equipment installed in an oil and gas platform,” *International Journal of Science and Qualitative Analysis*, vol. 5, no. 1, p. 15, 2019.
- [3] O. Ozguc, “Conversion of an oil tanker into fpos in gulf of mexico: strength and fatigue assessment,” *Ships and Offshore Structures*, pp. 1–19, 2020.
- [4] O. Ozguc, “Fatigue assessment of fpos hull side shell longitudinals using component stochastic and full spectral method,” *Applied Ocean Research*, vol. 101, p. 102289, 2020.
- [5] P. D. Menin, L. de Abreu Corrêa, T. G. R. Clarke, and D. A. Liang, “Enhancing damage localisation in critical areas of storage tanks in floating production storage and offloadings with a guided wave structural health monitoring system,” *Structural Health Monitoring*, p. 14759217211066558, 2022.
- [6] R. B. Hageman, F. H. van der Meulen, A. Rouhan, and M. L. Kaminski, “Quantifying uncertainties for risk-based inspection planning using in-service hull structure monitoring of fpos hulls,” *Marine Structures*, vol. 81, p. 103100, 2022.
- [7] Petrobras, “Steferson faria - banco de imagens petrobras: Fpos na cidade de paraty operando no campo de tupi (atual campo de lula), nordeste da bacia de santos.” Disponível em: < <https://petrobras.com.br/infograficos/tipos-de-plataformas/desktop/index.html> >. Acesso em: 26 mai. 2022.
- [8] H. Huang, D. Li, Z. Xue, X. L. Chen, S. Liu, J. Leng, and Y. Wei, “Design and performance analysis of a tracked wall-climbing robot for ship inspection in shipbuilding,” *Ocean Engineering*, vol. 131, pp. 224–230, 2017.

- [9] R. Caldwell, "Hull inspection techniques and strategy-remote inspection developments," in *SPE Offshore Europe Conference & Exhibition*, OnePetro, 2017.
- [10] L. Poggi, T. Gaggero, M. Gaiotti, E. Ravina, and C. M. Rizzo, "Recent developments in remote inspections of ship structures," *International Journal of Naval Architecture and Ocean Engineering*, vol. 12, pp. 881–891, 2020.
- [11] A. G. Andreev, "Continuous autonomous uav inspection for fpsi vessels," Master's thesis, UiT Norges arktiske universitet, 2021.
- [12] Q. Huan, M. Chen, and F. Li, "A practical omni-directional sh wave transducer for structural health monitoring based on two thickness-poled piezoelectric half-rings," *Ultrasonics*, vol. 94, pp. 342–349, 2019.
- [13] Q. Huan and F. Li, "A baseline-free sh wave sparse array system for structural health monitoring," *Smart Materials and Structures*, vol. 28, no. 10, p. 105010, 2019.
- [14] M. Abbas and M. Shafiee, "Structural health monitoring (shm) and determination of surface defects in large metallic structures using ultrasonic guided waves," *Sensors*, vol. 18, no. 11, p. 3958, 2018.
- [15] T. G. R. Clarke, *Guided wave health monitoring of complex structures*. PhD thesis, Department of Mechanical Engineering, Imperial College London, 2009.
- [16] J. L. Tabjula, S. Kanakambaran, S. Kalyani, P. Rajagopal, and B. Srinivasan, "Outlier analysis for defect detection using sparse sampling in guided wave structural health monitoring," *Structural Control and Health Monitoring*, vol. 28, no. 3, p. e2690, 2021.
- [17] T. Monnier and S.-E. Hebaz, "Guided wave topological energy method for quantitative evaluation of corrosion in metal plates and tubes," in *Forum Acusticum*, pp. 1855–1862, 2020.
- [18] P. C. Giroto, M. A. A. Viera, P. O. Junior, F. A. Alexandre, F. R. Dotto, R. Götz, T. G. Lopes, and P. R. Aguiar, "Development of a piezoelectric transducer coupling system for structural health monitoring applications," in *2019 7th International Engineering, Sciences and Technology Conference (IESTEC)*, pp. 538–543, IEEE, 2019.
- [19] K. Wang, J. Zhang, Y. Shen, B. Karkera, A. J. Croxford, and P. D. Wilcox, "Defect detection in guided wave signals using nonlinear autoregressive exogenous method," *Structural Health Monitoring*, p. 14759217211018698, 2021.
- [20] C. R. Farrar and K. Worden, *Structural health monitoring: a machine learning perspective*. John Wiley & Sons, 2012.

- [21] O. Mesnil, A. Imperiale, E. Demaldent, V. Baronian, and B. Chapuis, “Simulation tools for guided wave based structural health monitoring,” in *AIP Conference Proceedings*, vol. 1949, p. 050001, AIP Publishing LLC, 2018.
- [22] L. A. de Andrade da Rocha *et al.*, “Identificação de dano em estruturas utilizando uma metodologia que integra a técnica da impedância eletromecânica e ondas de lamb,” 2017.
- [23] M. Gordan, S.-R. Sabbagh-Yazdi, Z. Ismail, K. Ghaedi, P. Carroll, D. McCrum, and B. Samali, “State-of-the-art review on advancements of data mining in structural health monitoring,” *Measurement*, p. 110939, 2022.
- [24] R. Soman, “Multi-objective optimization for joint actuator and sensor placement for guided waves based structural health monitoring using fibre bragg grating sensors,” *Ultrasonics*, vol. 119, p. 106605, 2022.
- [25] Q. Huan, M. Chen, and F. Li, “A comparative study of three types shear mode piezoelectric wafers in shear horizontal wave generation and reception,” *Sensors*, vol. 18, no. 8, p. 2681, 2018.
- [26] Q. Huan and F. Li, “Structural health monitoring based on omni-directional sh wave piezoelectric transducers,” in *Health Monitoring of Structural and Biological Systems XII*, vol. 10600, p. 106002O, International Society for Optics and Photonics, 2018.
- [27] P. Cawley, “Ultrasonic structural health monitoring-current applications and potential,” in *2019 IEEE International Ultrasonics Symposium (IUS)*, pp. 2107–2109, IEEE, 2019.
- [28] F. Anowar and S. Sadaoui, “Incremental neural-network learning for big fraud data,” in *2020 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, pp. 3551–3557, IEEE, 2020.
- [29] F. Anowar and S. Sadaoui, “Incremental learning framework for real-world fraud detection environment,” *Computational Intelligence*, vol. 37, no. 1, pp. 635–656, 2021.
- [30] X. Huang, L. Wu, and Y. Ye, “A review on dimensionality reduction techniques,” *International Journal of Pattern Recognition and Artificial Intelligence*, vol. 33, no. 10, p. 1950017, 2019.
- [31] LearnDataSci, “Applied dimensionality reduction - 3 techniques using python.” Disponível em: < <https://www.learndatasci.com/tutorials/applied-dimensionality-reduction-techniques-using-python/> >. Acesso em: 14 fev. 2023.
- [32] B. Ghogh, M. N. Samad, S. A. Mashhadi, T. Kapoor, W. Ali, F. Karray, and M. Crowley, “Feature selection and feature extraction in pattern analysis: A literature review,” *arXiv preprint arXiv:1905.02845*, 2019.

- [33] W. K. Vong, A. T. Hendrickson, D. J. Navarro, and A. Perfors, “Do additional features help or hurt category learning? the curse of dimensionality in human learners,” *Cognitive science*, vol. 43, no. 3, p. e12724, 2019.
- [34] I. Goodfellow, Y. Bengio, A. Courville, and Y. Bengio, *Deep learning*, vol. 1. MIT press Cambridge, 2016.
- [35] F. Anowar, S. Sadaoui, and B. Selim, “Conceptual and empirical comparison of dimensionality reduction algorithms (pca, kpca, lda, mds, svd, lle, isomap, le, ica, t-sne),” *Computer Science Review*, vol. 40, p. 100378, 2021.
- [36] M. Oliveira, *Handshape recognition using principal component analysis and convolutional neural networks applied to sign language*. PhD thesis, Dublin City University, 2018.
- [37] S. Cateni, M. Vannucci, M. Vannocci, and V. Colla, “Variable selection and feature extraction through artificial intelligence techniques,” *Multivariate Analysis in Management, Engineering and the Sciences*, pp. 103–118, 2012.
- [38] M. Rautela, J. Senthilnath, E. Monaco, and S. Gopalakrishnan, “Delamination prediction in composite panels using unsupervised-feature learning methods with wavelet-enhanced guided wave representations,” *Composite Structures*, p. 115579, 2022.
- [39] D. Agis and F. Pozo, “A frequency-based approach for the detection and classification of structural changes using t-sne,” *Sensors*, vol. 19, no. 23, p. 5097, 2019.
- [40] A. A. Jiménez, C. Q. G. Muñoz, and F. P. G. Márquez, “Dirt and mud detection and diagnosis on a wind turbine blade employing guided waves and supervised learning classifiers,” *Reliability Engineering & System Safety*, vol. 184, pp. 2–12, 2019.
- [41] S. Ahmed and F. Kopsaftopoulos, “Active sensing acousto-ultrasound shm via stochastic time series models,” in *Health Monitoring of Structural and Biological Systems XVI*, vol. 12048, pp. 358–366, SPIE, 2022.
- [42] A. Khan and H. S. Kim, “Classification and prediction of multidamages in smart composite laminates using discriminant analysis,” *Mechanics of Advanced Materials and Structures*, pp. 1–11, 2020.
- [43] C. Liu, J. Dobson, and P. Cawley, “Efficient generation of receiver operating characteristics for the evaluation of damage detection in practical structural health monitoring applications,” *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, vol. 473, no. 2199, p. 20160736, 2017.

- [44] Z. Fang, J. He, and J. Liu, “Imbalanced classification of fatigue crack for aluminum plates using lamb wave,” in *European Workshop on Structural Health Monitoring*, pp. 161–170, Springer, 2020.
- [45] J. Wu, Z. Tang, F. Lv, K. Yang, C. B. Yun, and Y. Duan, “Ultrasonic guided wave-based switch rail monitoring using independent component analysis,” *Measurement Science and Technology*, vol. 29, no. 11, p. 115102, 2018.
- [46] J. Dobson and P. Cawley, “Independent component analysis for improved defect detection in guided wave monitoring,” *Proceedings of the IEEE*, vol. 104, no. 8, pp. 1620–1631, 2015.
- [47] A. Mardanshahi, V. Nasir, S. Kazemirad, and M. M. Shokrieh, “Detection and classification of matrix cracking in laminated composites using guided wave propagation and artificial neural networks,” *Composite Structures*, vol. 246, p. 112403, 2020.
- [48] C. Schnur, P. Goodarzi, Y. Lugovtsova, J. Bulling, J. Prager, K. Tschöke, J. Moll, A. Schütze, and T. Schneider, “Towards interpretable machine learning for automated damage detection based on ultrasonic guided waves,” *Sensors*, vol. 22, no. 1, p. 406, 2022.
- [49] L. Tang, Y. Li, Q. Bao, W. Hu, Q. Wang, Z. Su, and D. Yue, “Quantitative identification of damage in composite structures using sparse sensor arrays and multi-domain-feature fusion of guided waves,” *Measurement*, p. 112482, 2023.
- [50] S. Bosse, D. Weiss, and D. Schmidt, “Supervised distributed multi-instance and unsupervised single-instance autoencoder machine learning for damage diagnostics with high-dimensional data—a hybrid approach and comparison study,” *Computers*, vol. 10, no. 3, p. 34, 2021.
- [51] R. Miorelli, A. Kulakovskiy, O. Mesnil, and O. d’Almeida, “Automatic defect localization and characterization through machine learning based inversion for guided wave imaging in shm,” in *AIP Conference Proceedings*, vol. 2102, p. 050005, AIP Publishing LLC, 2019.
- [52] J.-Q. Tu, Z.-F. Tang, C.-B. Yun, J.-J. Wu, and X. Xu, “Guided wave-based damage assessment on welded steel i-beam under ambient temperature variations,” *Structural Control and Health Monitoring*, vol. 28, no. 4, p. e2696, 2021.
- [53] M. El Mountassir, S. Yaacoubi, G. Mourot, and D. Maquin, “An adaptive pca-based method for more reliable ultrasonic guided waves shm: Data-driven modeling and experimental validation in high attenuating medium,” *Structural Control and Health Monitoring*, vol. 28, no. 1, p. e2634, 2021.

- [54] C. Liu, J. B. Harley, M. Bergés, D. W. Greve, and I. J. Oppenheim, “Robust ultrasonic damage detection under complex environmental conditions using singular value decomposition,” *Ultrasonics*, vol. 58, pp. 75–86, 2015.
- [55] H. Meng, B. Aupetit, L. Kloul, and A. Rauzy, “Production performance of an offshore system by applying altarica 3.0,” *Congrès Lambda Mu 20 de Maîtrise des Risques et de Sécurité de Fonctionnement, 11-13 Octobre 2016, Saint Malo, France*, 2016.
- [56] D. K. Kim, M. S. Liew, S. A. M. Youssef, M. H. Mohd, H. B. Kim, and J. K. Paik, “Time-dependent ultimate strength performance of corroded fpsos,” *Arabian Journal for Science and Engineering*, vol. 39, no. 11, pp. 7673–7690, 2014.
- [57] J. Lappi *et al.*, “Utilization potential of high strength steel in fatigue loaded floating production storage and offloading unit structures,” Master’s thesis, 2015.
- [58] L. Li, Q. Jia, Z. Wan, Y. Zhang, P. Qian, and J. Li, “Experimental and numerical investigation of effects of residual stress and its release on fatigue strength of typical fpso-unit welded joint,” *Ocean Engineering*, vol. 196, p. 106858, 2020.
- [59] A. A. Bidgoli, *Simulation and optimization of primary oil and gas processing plant of FPSO operating in pre-salt oil field*. PhD thesis, Universidade de São Paulo, 2018.
- [60] A. A. Bidgoli, L. O. Salviano, D. J. Dezan, S. de Oliveira Junior, and J. I. Yanagihara, “Energy optimization of an fpso operating in the brazilian pre-salt region,” *Energy*, vol. 164, pp. 390–399, 2018.
- [61] U. Bhardwaj, A. P. Teixeira, and C. G. Soares, “Analysis of fpso accident and incident data,” in *Progress in the analysis and design of marine structures*, pp. 773–782, CRC Press, 2017.
- [62] J. M. de Moraes, *Petróleo em águas profundas: Uma história tecnológica da Petrobras na exploração e produção offshore*. Brasília: Ipea: Petrobras, 2013.
- [63] X. Wang, H. Sun, T. Yao, M. Fujikubo, and R. Basu, “Methodologies on hull girder ultimate strength assessment of fpsos,” *Journal of offshore mechanics and Arctic engineering*, vol. 133, no. 3, 2011.
- [64] A. C. Rossi, “A condition based, risk analysis and life cycle oriented approach for life extension of fpso units,” Master’s thesis, NTNU, 2020.
- [65] B. V. de Farias and T. A. Netto, “FpsO hull structural integrity evaluation via bayesian updating of inspection data,” *Ocean Engineering*, vol. 56, pp. 10–19, 2012.

- [66] N. Vladimir, I. Senjanović, N. Alujević, S. Tomašević, and D. S. Cho, “Strength assessment of an aged single hull tanker grounded in mud and used as port oil storage,” in *Proceedings of the 4th International Conference on Maritime Technology and Engineering MARTECH*, pp. 345–356, 2018.
- [67] J. C. Garrett, H. Mei, and V. Giurgiutiu, “An artificial intelligence approach to fatigue crack length estimation from acoustic emission waves in thin metallic plates,” *Applied Sciences*, vol. 12, no. 3, p. 1372, 2022.
- [68] N.-Z. Chen, “Hull girder reliability assessment for fpsos,” *Engineering Structures*, vol. 114, pp. 135–147, 2016.
- [69] K. Tatsis, “Structural health assessment through vibration monitoring on fpsos,” Master’s thesis, Delft University of Technology, Delft, Netherlands, 2016.
- [70] C. Rizzo, “Inspection of aged ships and offshore structures,” *Condition assessment of aged structures*, pp. 367–406, 2008.
- [71] P. D. Menin and T. G. R. Clarke, “Development of an omnidirectional shear horizontal wave transducer for structural health monitoring,” *Journal of Nondestructive Evaluation*, vol. 37, no. 4, pp. 1–10, 2018.
- [72] A. P. A. Guimarães, “Utilização do algoritmo de aprendizado de máquinas para monitoramento de falhas em estruturas inteligentes,” Master’s thesis, Universidade Estadual Paulista - UNESP - Campus de Ilha Solteira, Ilha Solteira, 2016.
- [73] M. A. de Oliveira, “Monitoramento de integridade estrutural baseada em sensores piezolétricos e análise de sinais no domínio do tempo,” 2013.
- [74] D. C. de Oliveira, “Diagnóstico de falhas em estruturas isotrópicas utilizando sistemas imunológicos artificiais com seleção negativa e clonal,” 2019.
- [75] A. Malekloo, E. Ozer, M. AlHamaydeh, and M. Girolami, “Machine learning and structural health monitoring overview with emerging technology and high-dimensional data source highlights,” *Structural Health Monitoring*, p. 14759217211036880, 2021.
- [76] D. A. T. Burgos, R. C. G. Vargas, C. Pedraza, D. Agis, and F. Pozo, “Damage identification in structural health monitoring: A brief review from its implementation to the use of data-driven applications,” *Sensors*, vol. 20, no. 3, p. 733, 2020.
- [77] M. Mitra and S. Gopalakrishnan, “Guided wave based structural health monitoring: A review,” *Smart Materials and Structures*, vol. 25, no. 5, p. 053001, 2016.

- [78] Y. Tian, Y. Song, Y. Shen, and Z. Yu, “A metamaterial ultrasound mode convertor for complete transformation of lamb waves into shear horizontal waves,” *Ultrasonics*, vol. 119, p. 106627, 2022.
- [79] P. D. Menin, “Desenvolvimento de transdutor de modo sh0 omnidirecional utilizando arranjo de cerâmicas piezoelétricas,” Master’s thesis, Universidade Federal do Rio Grande do Sul - UFRGS, Porto Alegre, 2017.
- [80] A. J. Croxford, P. D. Wilcox, B. W. Drinkwater, and G. Konstantinidis, “Strategies for guided-wave structural health monitoring,” *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, vol. 463, no. 2087, pp. 2961–2981, 2007.
- [81] Y. Y. Li and L. H. Yam, “Sensitivity analyses of sensor locations for vibration control and damage detection of thin-plate systems,” *Journal of Sound and Vibration*, vol. 240, no. 4, pp. 623–636, 2001.
- [82] A. B. M. Bayoumi, I. Mueller, T. Vogt, and P. Kraemer, “Approaches combining multiple paths to establish the probability of detection of a guided wave-based structural health monitoring system,” (Prague, Czech Republic), European NDT CM, 2021.
- [83] J. L. Rose, *Ultrasonic guided waves in solid media*. Cambridge university press, 2014.
- [84] K. F. Graff, *Wave motion in elastic solids*. Courier Corporation, 2012.
- [85] P. O. Moore, E. v. K. Hill, and R. K. Miller, *Nondestructive Testing Handbook: Acoustic Emission Testing*, vol. 6. Columbus: American Society for Nondestructive Testing, 3 ed., 2005.
- [86] J. L. Rose, “Dispersion curves in guided wave testing,” *Materials Evaluation*, vol. 61, no. 1, pp. 20–22, 2003.
- [87] H. Miao and F. Li, “Shear horizontal wave transducers for structural health monitoring and nondestructive testing: A review,” *Ultrasonics*, vol. 114, p. 106355, 2021.
- [88] B. A. Auld, *Acoustic fields and waves in solids*, vol. II. Stanford: John Wiley Sons Inc., 1973.
- [89] GuidedWave, “Plates and shells.” Disponível em: < <http://www.gwultrasonics.com/knowledge/plateshell/> >. Acesso em: 02 nov. 2022.
- [90] J. Achenbach, *Wave propagation in elastic solids*. Elsevier, 2012.
- [91] P. D. Menin, *Desenvolvimento de Sistema de Monitoramento de Integridade Estrutural por Ondas Guiadas para Tanques de Unidades FPSO*. PhD thesis, Universidade Federal do Rio Grande do Sul - UFRGS, Porto Alegre, 2022.

- [92] P. D. Wilcox, M. J. S. Lowe, and P. Cawley, “Mode and transducer selection for long range lamb wave inspection,” *Journal of intelligent material systems and structures*, vol. 12, no. 8, pp. 553–565, 2001.
- [93] J. Ma and P. Cawley, “Low-frequency pulse echo reflection of the fundamental shear horizontal mode from part-thickness elliptical defects in plates,” *The Journal of the Acoustical Society of America*, vol. 127, no. 6, pp. 3485–3493, 2010.
- [94] P. D. Wilcox, “Omni-directional guided wave transducer arrays for the rapid inspection of large areas of plate structures,” *IEEE transactions on ultrasonics, ferroelectrics, and frequency control*, vol. 50, no. 6, pp. 699–709, 2003.
- [95] A. Galvagni, *Pipeline health monitoring*. PhD thesis, Imperial College London London, 2013.
- [96] Ferroperm, “High quality components and materials for the electronic industry.” Disponível em: < <https://silو.tips/download/high-quality-components-and-materials-for-the-electronic-industry> >. Acesso em: 03 nov. 2022.
- [97] T. L. Jordan and Z. Ounaies, “Piezoelectric ceramics characterization,” tech. rep., Institute for Computer Applications in Science and Engineering, Hampton VA, 2001.
- [98] G. S. Kino, *Acoustic waves: devices, imaging, and analog signal processing*, vol. 107. Prentice-hall Englewood Cliffs, NJ, 1987.
- [99] D. C. P. Barbosa *et al.*, “Diagnóstico de falhas estruturais em hastes de âncora por meio da análise de sinais eletromagnéticos por ferramentas de inteligência artificial,” Master’s thesis, Universidade Federal de Pernambuco, 2020.
- [100] K. A. Cardillo, *Artificial Intelligence Approaches for Structural Health Monitoring of Aerospace Structures*. PhD thesis, University of South Carolina, 2020.
- [101] H. Salehi and R. Burgueño, “Emerging artificial intelligence methods in structural engineering,” *Engineering structures*, vol. 171, pp. 170–189, 2018.
- [102] A. Mistry, “Emerging artificial intelligence methods in structural engineering,” *VIVA-Tech International Journal for Research and Innovation*, vol. 1, no. 4, pp. 1–2, 2021.
- [103] Medium, “Diferença de ia, ml e dl.” Disponível em: < <https://medium.com/ranbookm/diferenÃça-de-ia-ml-e-dl-6f1a06882859> >. Acesso em: 06 nov. 2022.
- [104] TowardsDataScience, “Ai, ml, and dl: How not to get them mixed!.” Disponível em: < <https://towardsdatascience.com/> >

- understanding-the-difference-between-ai-ml-and-dl-cceb63252a6c >. Acesso em: 05 nov. 2022.
- [105] M. Mohri, A. Rostamizadeh, and A. Talwalkar, *Foundations of machine learning*. MIT press, 2018.
- [106] J. Gareth, W. Daniela, H. Trevor, and T. Robert, *An introduction to statistical learning: with applications in R*. Springer, 2013.
- [107] C. M. Bishop and N. M. Nasrabadi, *Pattern recognition and machine learning*, vol. 4. Springer, 2006.
- [108] O. Faust, E. J. Ciaccio, and U. R. Acharya, “A review of atrial fibrillation detection methods as a service,” *International journal of environmental research and public health*, vol. 17, no. 9, p. 3093, 2020.
- [109] Medium, “As diferenças entre ai, ml e dl.” Disponível em: < <https://medium.com/ipnet-growth-partner/as-diferenÃas-entre-ai-ml-e-dl-3d5898a35465> >. Acesso em: 06 nov. 2022.
- [110] H. Salehi, S. Biswas, and R. Burgueno, “Data interpretation framework integrating machine learning and pattern recognition for self-powered data-driven damage identification with harvested energy variations,” *Engineering Applications of Artificial Intelligence*, vol. 86, pp. 136–153, 2019.
- [111] D. C. de Oliveira, “Localização de danos em estruturas isotrópicas com a utilização de aprendizado de máquina,” Master’s thesis, Universidade Estadual Paulista - UNESP - Campus de Ilha Solteira, Ilha Solteira, 2017.
- [112] S. Ayesha, M. K. Hanif, and R. Talib, “Overview and comparative study of dimensionality reduction techniques for high dimensional data,” *Information Fusion*, vol. 59, pp. 44–58, 2020.
- [113] S. da Silva Camargo, *Um modelo neural de aprimoramento progressivo para redução de dimensionalidade*. PhD thesis, Universidade Federal do Rio Grande do Sul - UFRGS, Porto Alegre, 2010.
- [114] Medium, “Redução de dimensionalidade.” Disponível em: < <https://medium.com/@lucasgmpaiva1/reduÃo-de-dimensionalidade-6b98b360ff6a> >. Acesso em: 15 fev. 2023.
- [115] S. Liu, D. Maljovec, B. Wang, P.-T. Bremer, and V. Pascucci, “Visualizing high-dimensional data: Advances in the past decade,” *IEEE transactions on visualization and computer graphics*, vol. 23, no. 3, pp. 1249–1268, 2016.

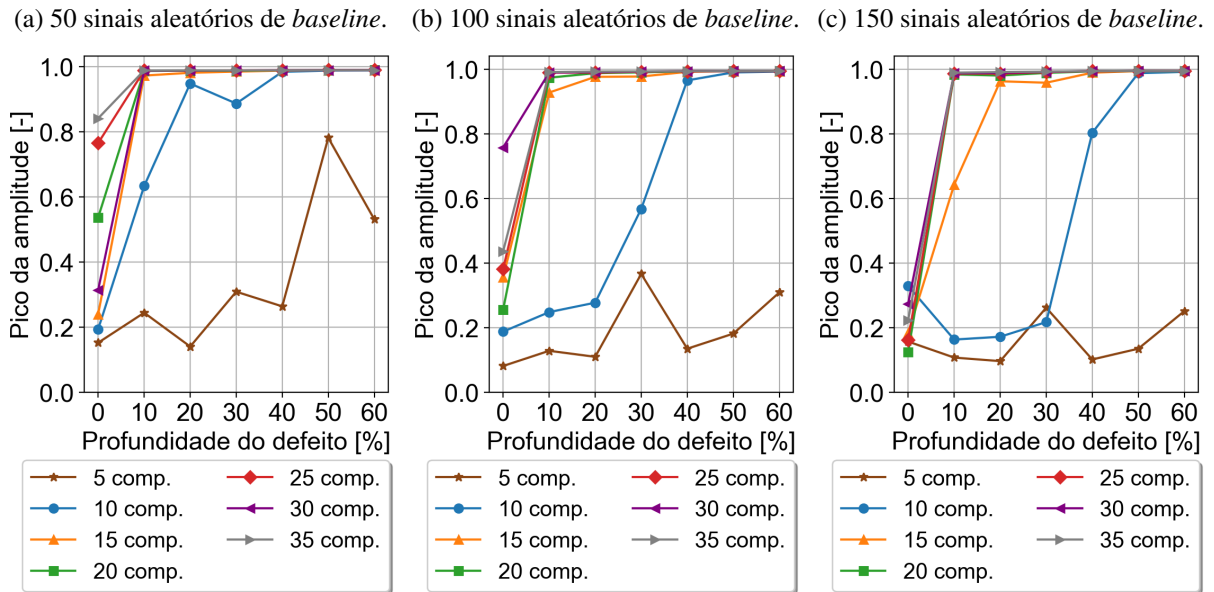
- [116] M. Kotani, H. Takabatake, and S. Ozawa, “Supervised independent component analysis with class information,” in *International Conference on Neural Information Processing*, pp. 1052–1057, Springer, 2004.
- [117] A. J. Bell and T. J. Sejnowski, “An information-maximization approach to blind separation and blind deconvolution,” *Neural computation*, vol. 7, no. 6, pp. 1129–1159, 1995.
- [118] A. Hyvärinen, “Fast and robust fixed-point algorithms for independent component analysis,” *IEEE transactions on Neural Networks*, vol. 10, no. 3, pp. 626–634, 1999.
- [119] P. A. Højen-Sørensen, O. Winther, and L. K. Hansen, “Mean-field approaches to independent component analysis,” *Neural Computation*, vol. 14, no. 4, pp. 889–918, 2002.
- [120] A. Delorme and S. Makeig, “Eeglab: an open source toolbox for analysis of single-trial eeg dynamics including independent component analysis,” *Journal of neuroscience methods*, vol. 134, no. 1, pp. 9–21, 2004.
- [121] A. Hyvärinen, J. Karhunen, and E. Oja, “Independent component analysis,” *New York: John Wiley & Sons, INC.*, p. 481, 2001.
- [122] J. L. Marchini, C. Heaton, and B. D. Ripley, “Fastica algorithms to perform ica and projection pursuit,” *R package version 1.1-11,2009*, vol. 10, no. 3, pp. 626–634, 1999.
- [123] J. F. Cardoso and A. Souloumiac, “Blind beamforming for non gaussian signals,” *IEEE Proc. F. v140 i6 362-370, 2002*, vol. 41, no. 1-4, pp. 1–24, 2001.
- [124] A. Hyvärinen and E. Oja, “A fast fixed-point algorithm for independent component analysis,” *Neural computation*, vol. 9, no. 7, pp. 1483–1492, 1997.
- [125] A. Hyvärinen and E. Oja, “Independent component analysis: algorithms and applications,” *Neural networks*, vol. 13, no. 4-5, pp. 411–430, 2000.
- [126] J. N. Kutz, *Data-driven modeling & scientific computation: methods for complex systems & big data*. Oxford University Press, 2013.
- [127] J. V. Stone, “Independent component analysis: a tutorial introduction,” 2004.
- [128] M. A. Moraes, *Uma Proposta para a Atribuição de Responsabilidades sobre Desequilíbrios de Tensão através da Análise de Componentes Independentes*. PhD thesis, Universidade Federal de Uberlândia - UFU, Uberlândia, 2022.
- [129] S. K. S. Carmo, *Desenvolvimento de Estratégia de Desacoplamento no Controle de Coluna de Destilação Usando a Técnica de Separação de Sinais*. PhD thesis, Universidade Federal de Campina Grande - UFCG, Campina Grande, 2015.

- [130] BritishSteel, “Bulb flats.” Disponível em: < <https://britishsteel.co.uk/media/40438/bulb-flats-brochure.pdf> >. Acesso em: 08 nov. 2022.
- [131] T. G. R. Clarke, E. S. Bastos, E. Bertoldi, H. T. H. de Oliveira, L. da Luz Dorneles, and P. D. Menin, “Desenvolvimento de sistema de inspeção e monitoramento de chapas de cascos de navios por ondas guiadas,” Tech. Rep. 10, UFRGS / LAMEF - Petrobras / CENPES, Fevereiro 2022.
- [132] E. Bertoldi, M. Oliveira, L. de Abreu Corrêa, P. D. Menin, and T. G. R. Clarke, “Guided wave shm system for detection and quantification of damages in fpsos storage tanks using data-driven algorithm,” *Structural Health Monitoring*, p. 14759217221111977, 2022.
- [133] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay, “Scikit-learn: Machine learning in Python,” *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.

APÊNDICE A INFLUÊNCIA DO NÚMERO DE COMPONENTES DO ICA, DO NÚMERO DE SINAIS ALEATÓRIOS DE *BASELINE* E DA FREQUÊNCIA DE OPERAÇÃO NOS VALORES DE AMPLITUDES DE PICO

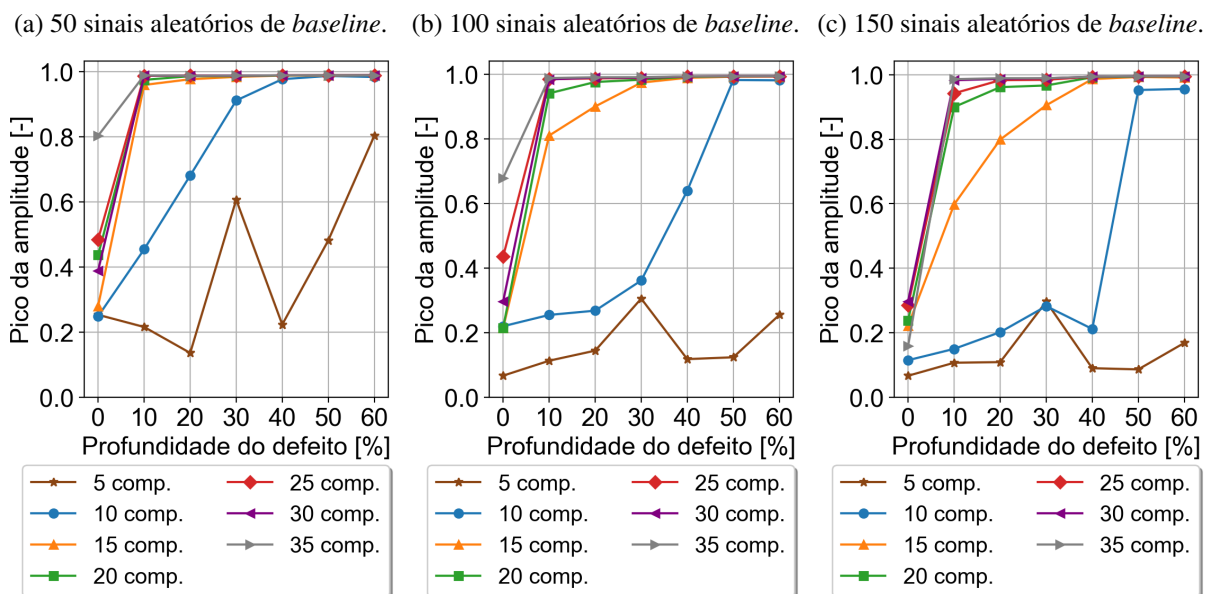
A.1 Dano I

Figura 59: Influência do número de componentes do ICA e do número de sinais aleatórios de *baseline* para o par de sensores e2r3, dano I e frequência central de 30 kHz.



Fonte: Próprio Autor.

Figura 60: Influência do número de componentes do ICA e do número de sinais aleatórios de *baseline* para o par de sensores e2r3, dano I e frequência central de 35 kHz.



Fonte: Próprio Autor.

Figura 61: Influência do número de componentes do ICA e do número de sinais aleatórios de *baseline* para o par de sensores e2r3, dano I e frequência central de 40 kHz.

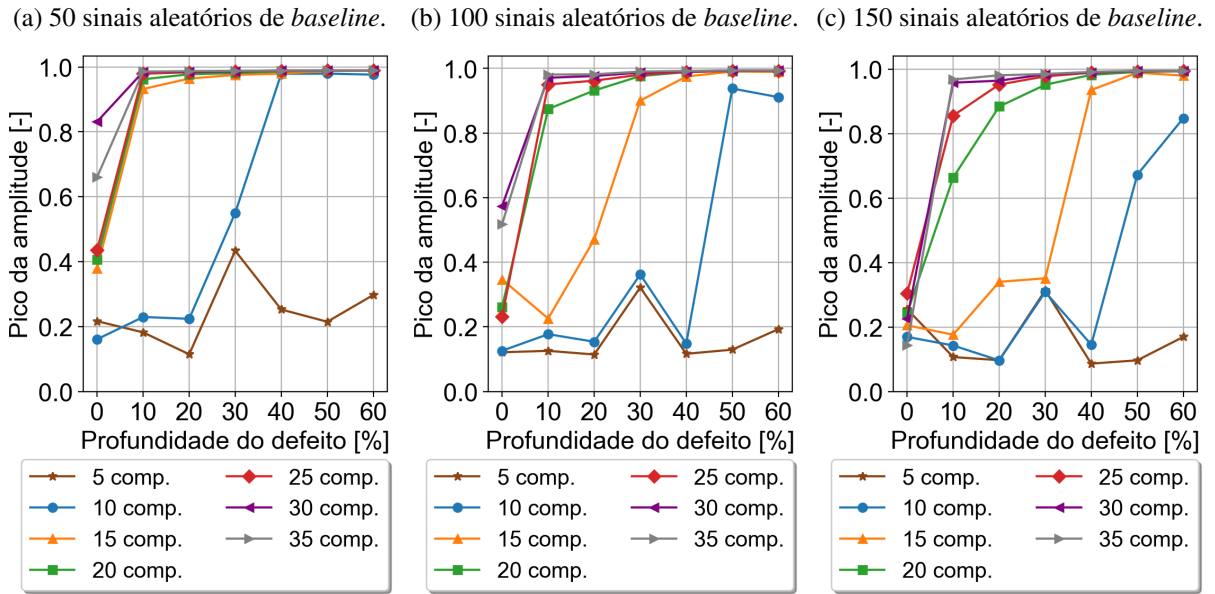


Figura 62: Influência do número de componentes do ICA e do número de sinais aleatórios de *baseline* para o par de sensores e2r3, dano I e frequência central de 50 kHz.

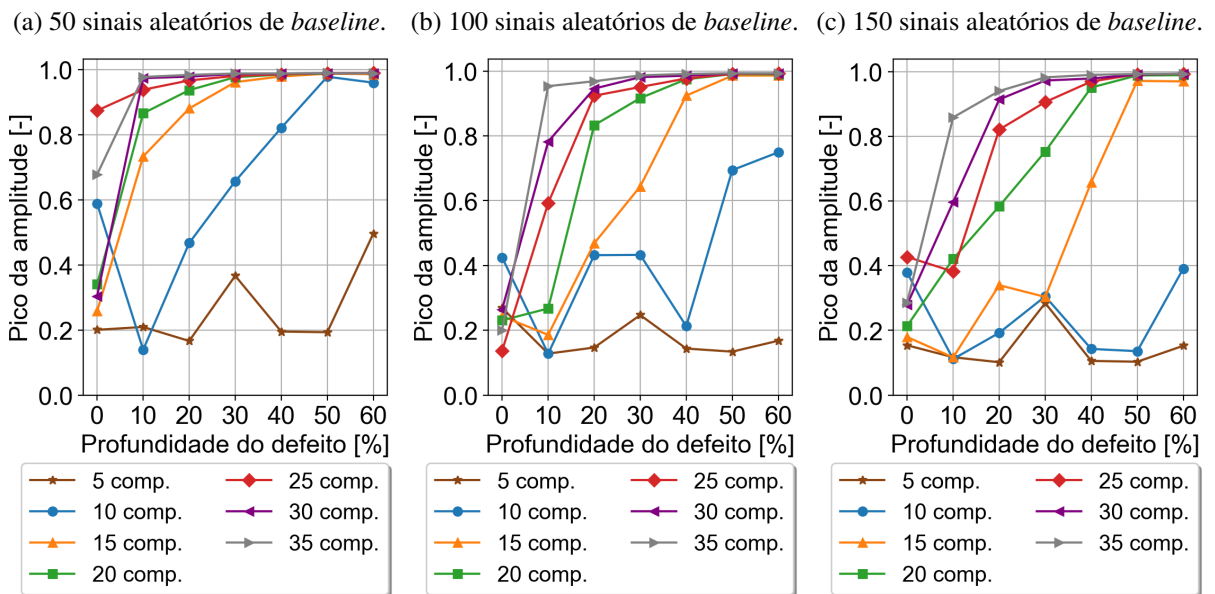


Figura 63: Influência do número de componentes do ICA e do número de sinais aleatórios de *baseline* para o par de sensores e2r3, dano I e frequência central de 55 kHz.

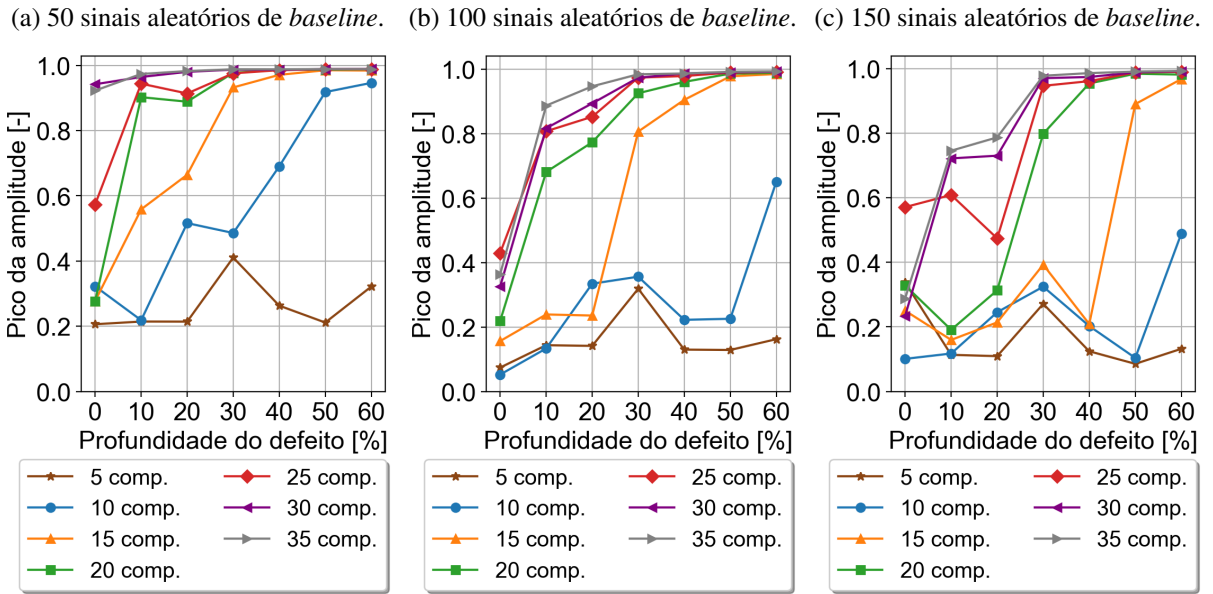


Figura 64: Influência do número de componentes do ICA e do número de sinais aleatórios de *baseline* para o par de sensores e2r3, dano I e frequência central de 60 kHz.

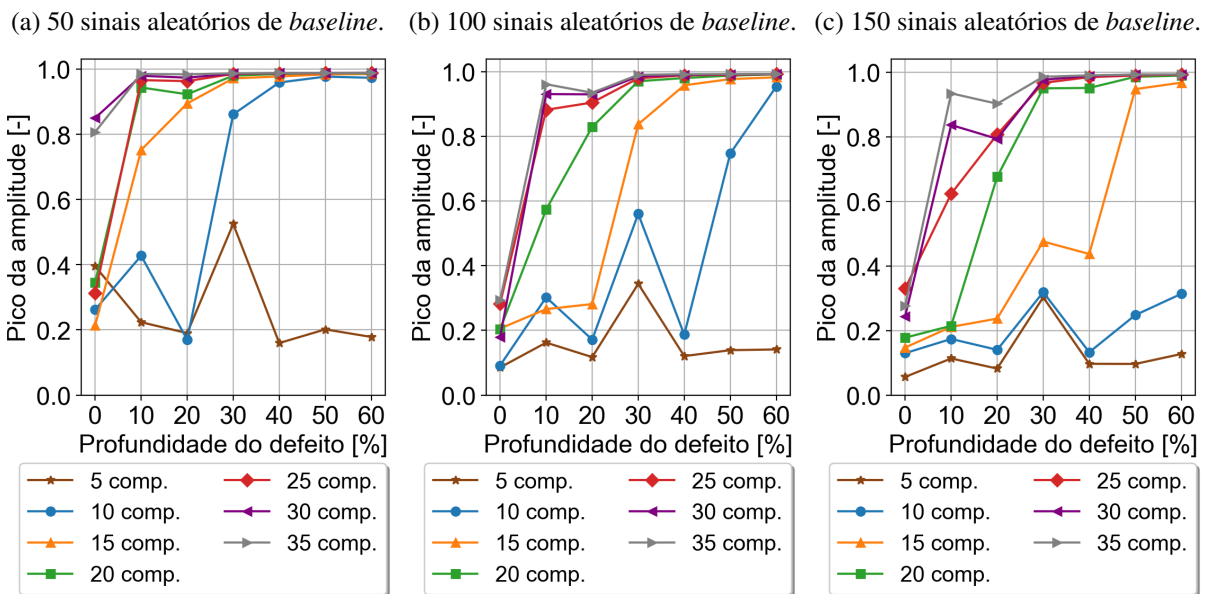


Figura 65: Influência do número de componentes do ICA e do número de sinais aleatórios de *baseline* para o par de sensores e2r3, dano I e frequência central de 65 kHz.

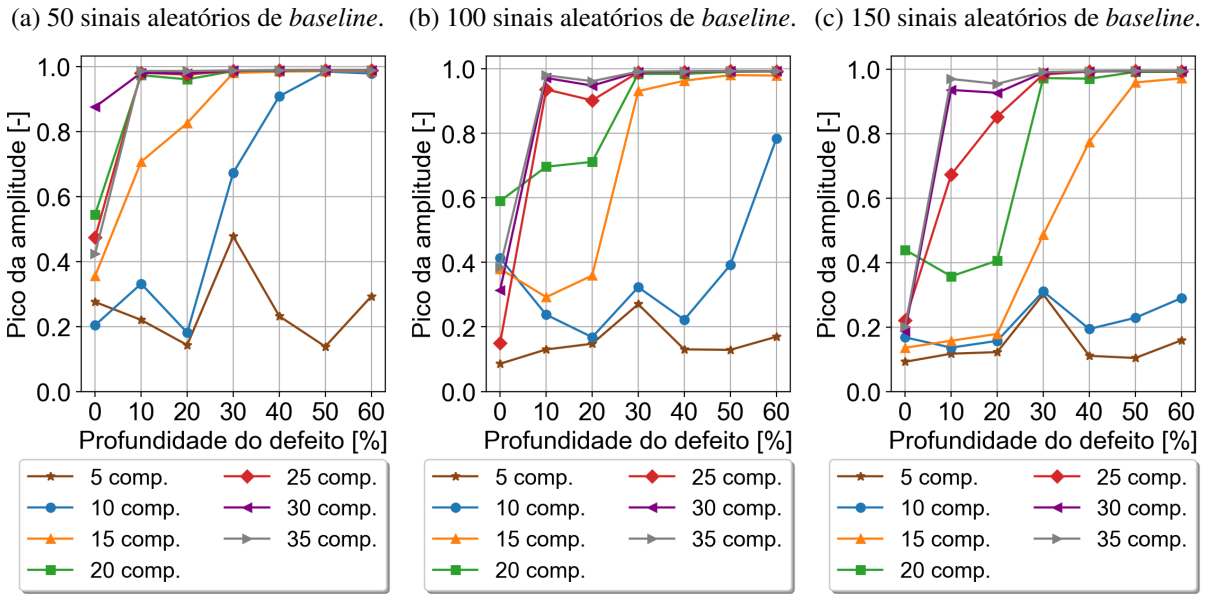


Figura 66: Influência do número de componentes do ICA e do número de sinais aleatórios de *baseline* para o par de sensores e2r3, dano I e frequência central de 70 kHz.

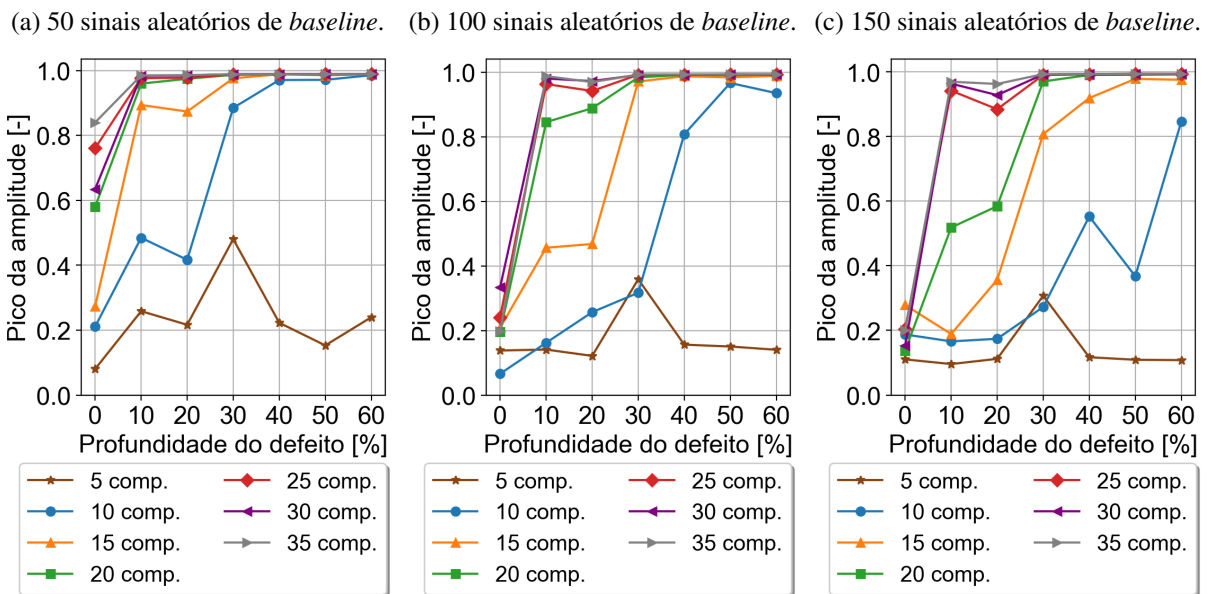


Figura 67: Influência do número de componentes do ICA e do número de sinais aleatórios de *baseline* para o par de sensores e2r3, dano I e frequência central de 75 kHz.

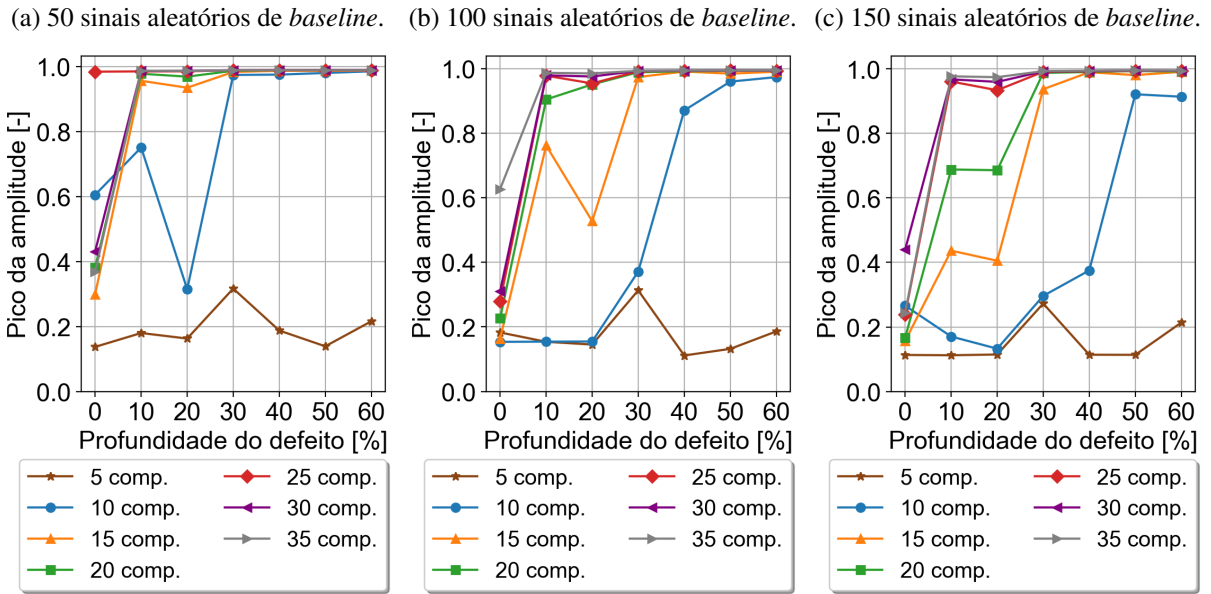
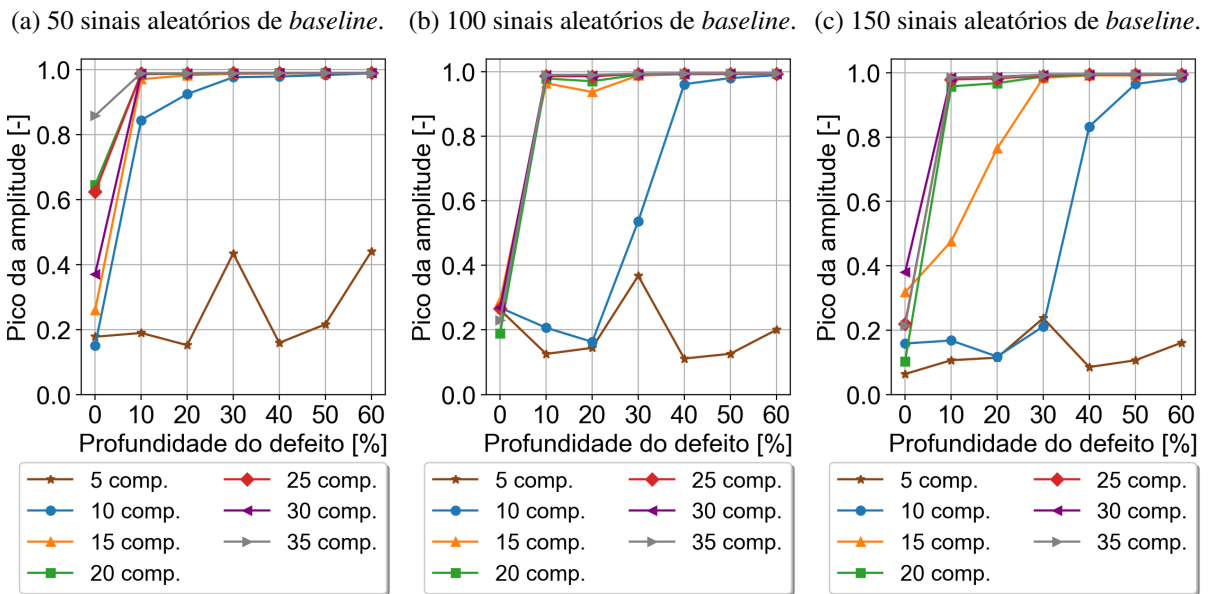


Figura 68: Influência do número de componentes do ICA e do número de sinais aleatórios de *baseline* para o par de sensores e2r3, dano I e frequência central de 80 kHz.



A.2 Dano II

Figura 69: Influência do número de componentes do ICA e do número de sinais aleatórios de *baseline* para o par de sensores e2r3, dano II e frequência central de 30 kHz.

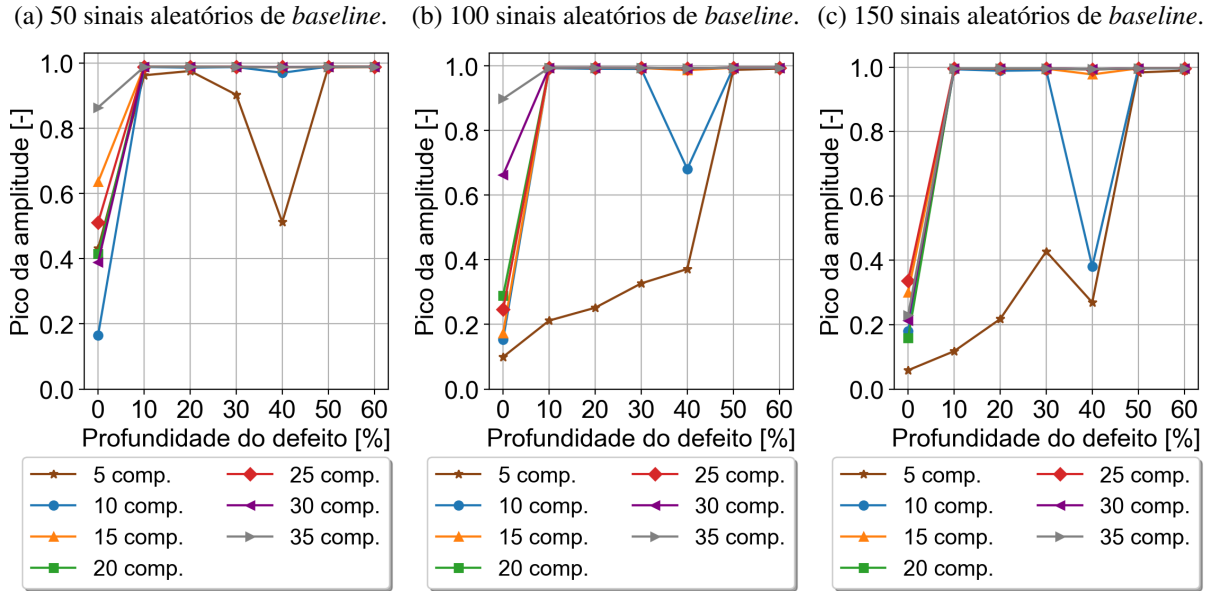


Figura 70: Influência do número de componentes do ICA e do número de sinais aleatórios de *baseline* para o par de sensores e2r3, dano II e frequência central de 35 kHz.

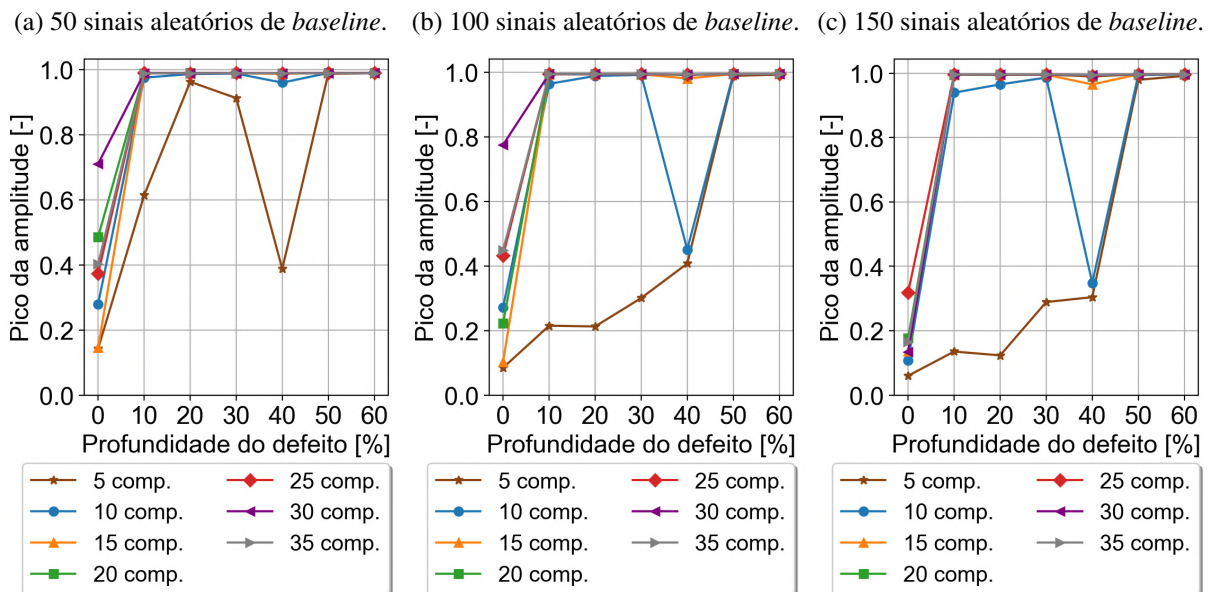
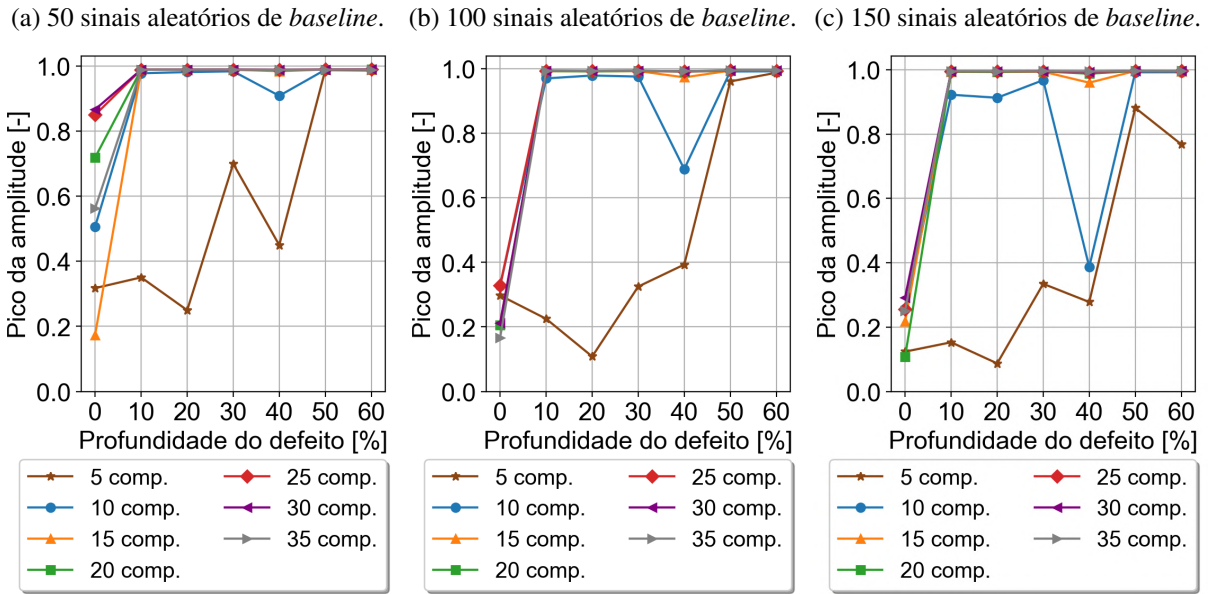
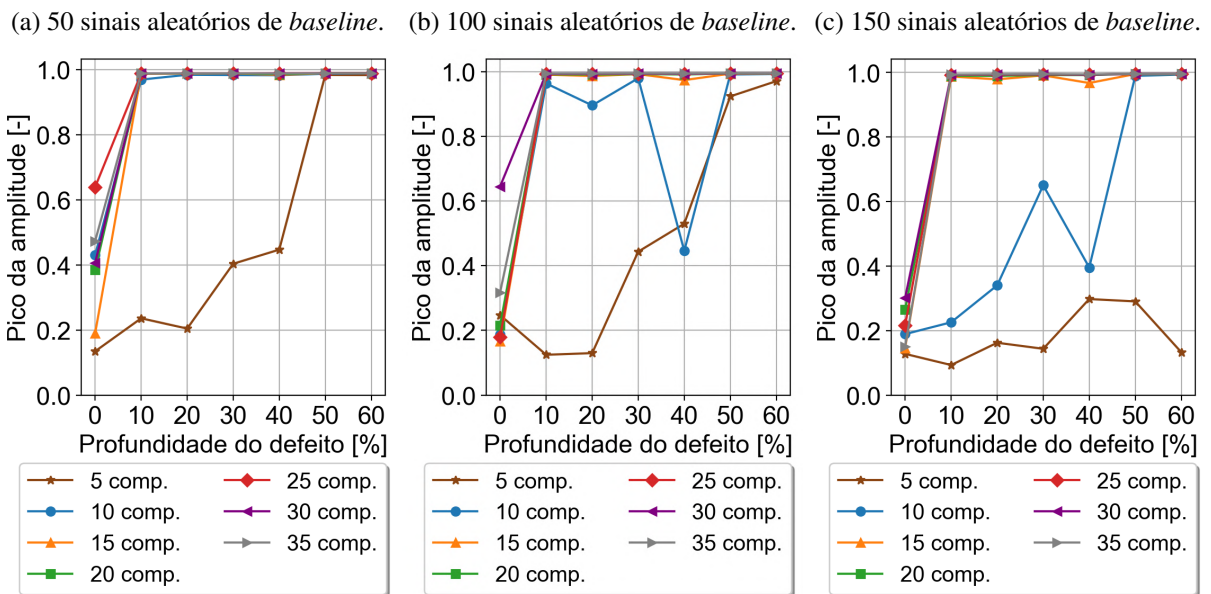


Figura 71: Influência do número de componentes do ICA e do número de sinais aleatórios de *baseline* para o par de sensores e2r3, dano II e frequência central de 40 kHz.



Fonte: Próprio Autor.

Figura 72: Influência do número de componentes do ICA e do número de sinais aleatórios de *baseline* para o par de sensores e2r3, dano II e frequência central de 50 kHz.



Fonte: Próprio Autor.

Figura 73: Influência do número de componentes do ICA e do número de sinais aleatórios de *baseline* para o par de sensores e2r3, dano II e frequência central de 55 kHz.

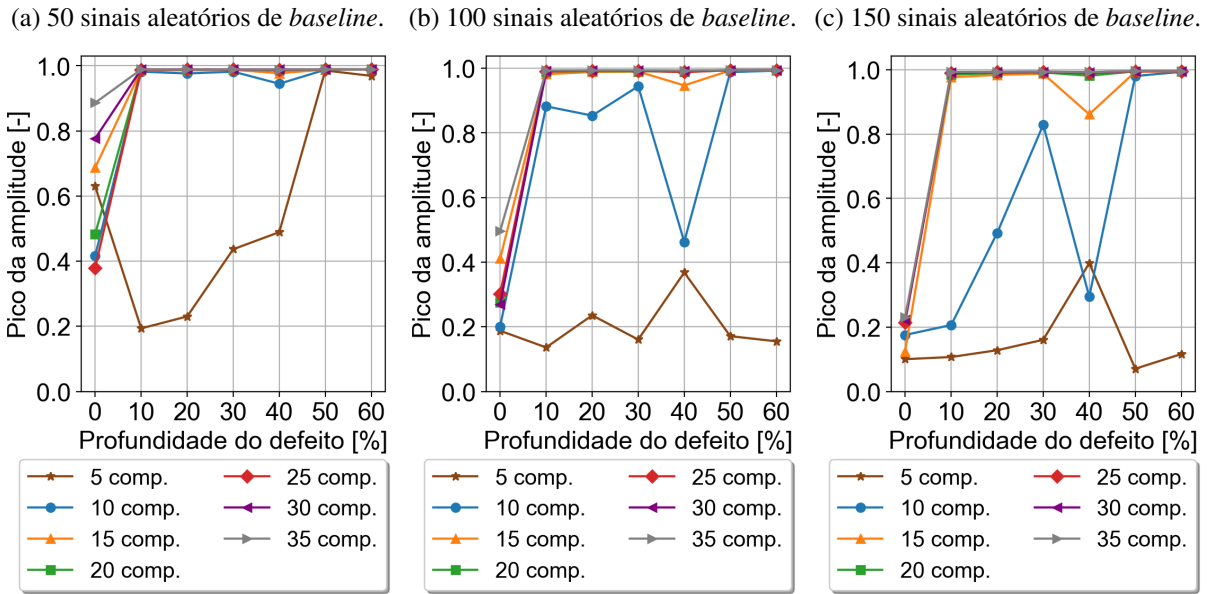


Figura 74: Influência do número de componentes do ICA e do número de sinais aleatórios de *baseline* para o par de sensores e2r3, dano II e frequência central de 60 kHz.

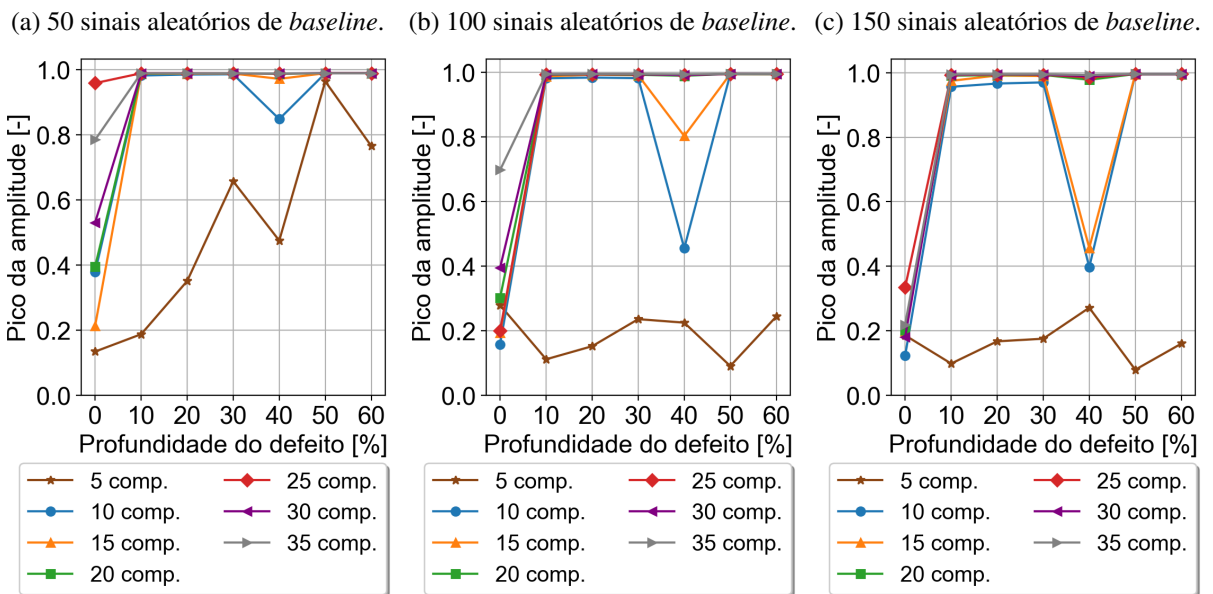
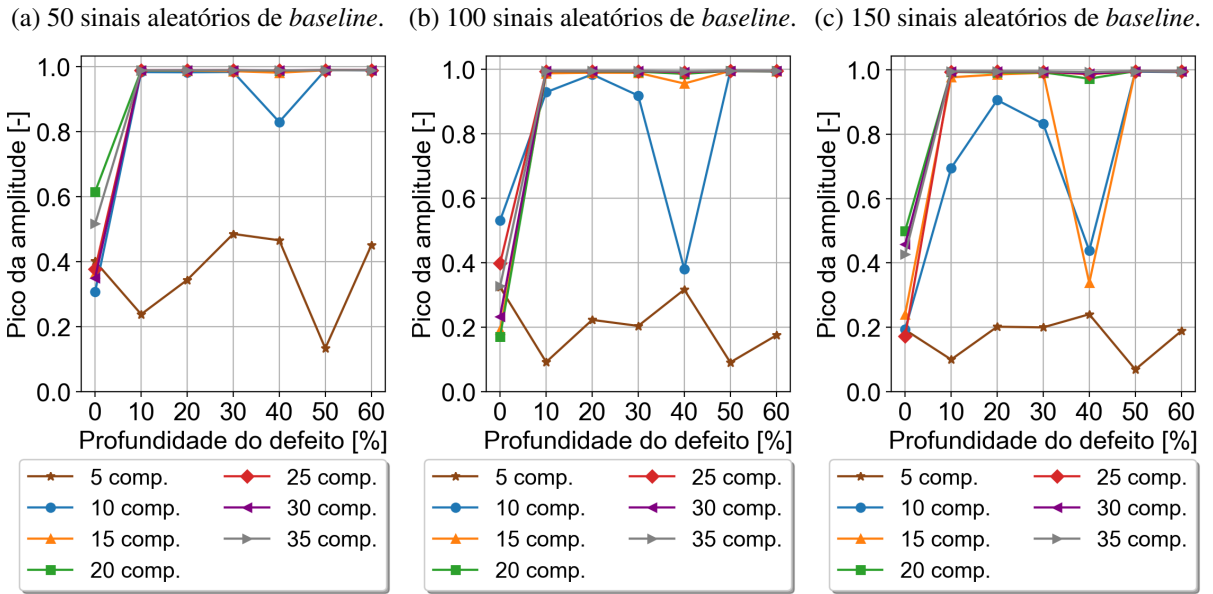
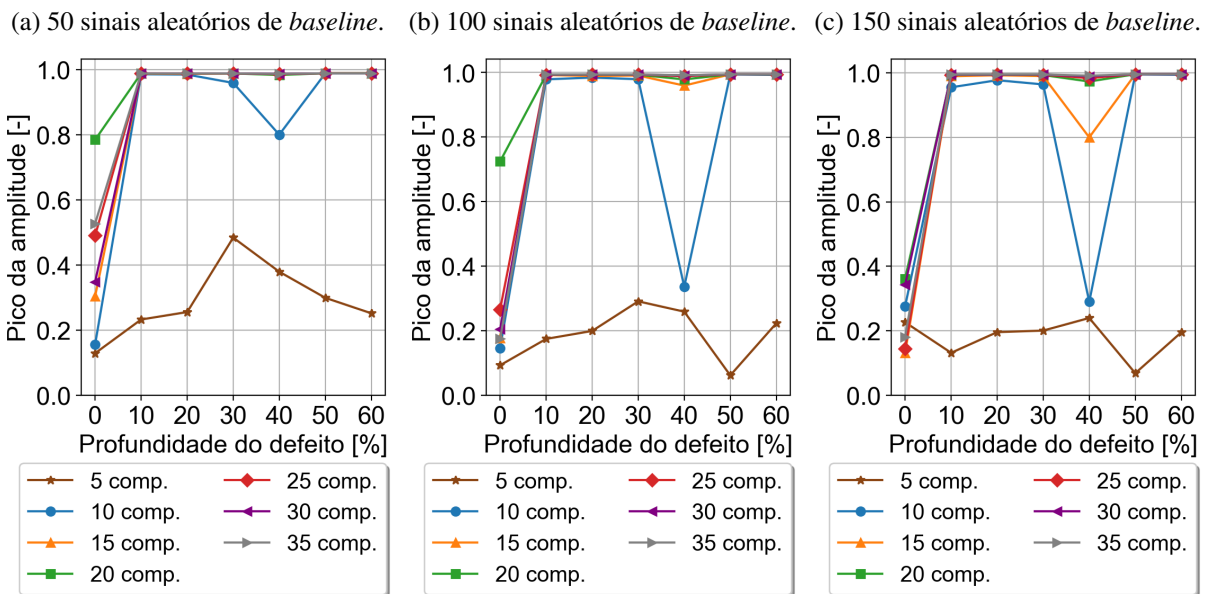


Figura 75: Influência do número de componentes do ICA e do número de sinais aleatórios de *baseline* para o par de sensores e2r3, dano II e frequência central de 65 kHz.



Fonte: Próprio Autor.

Figura 76: Influência do número de componentes do ICA e do número de sinais aleatórios de *baseline* para o par de sensores e2r3, dano II e frequência central de 70 kHz.



Fonte: Próprio Autor.

Figura 77: Influência do número de componentes do ICA e do número de sinais aleatórios de *baseline* para o par de sensores e2r3, dano II e frequência central de 75 kHz.

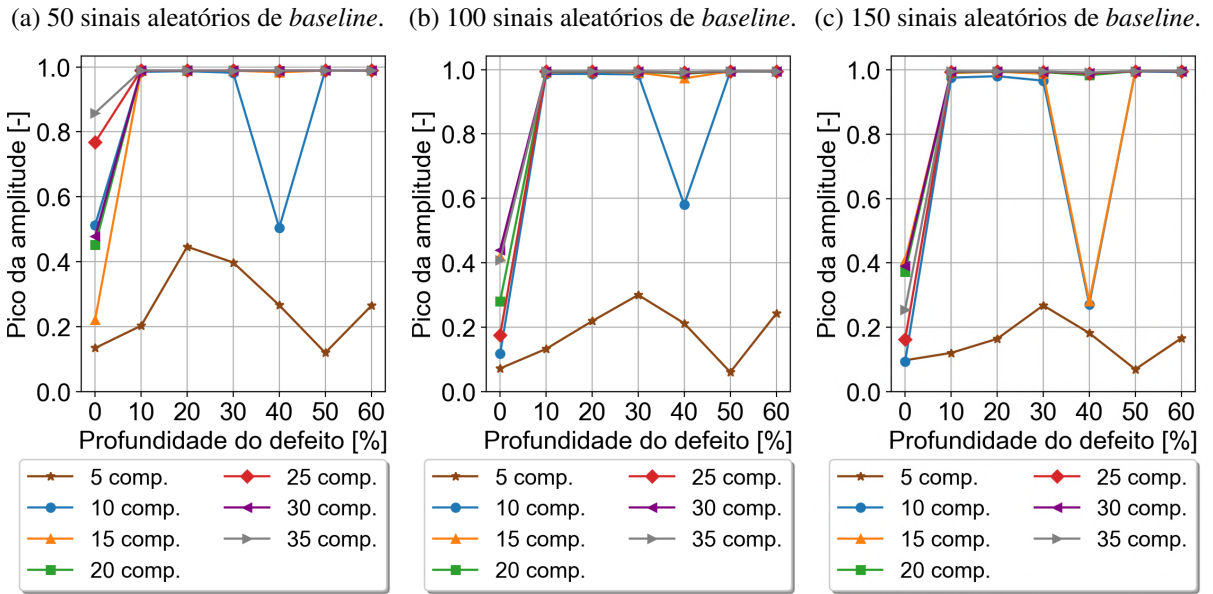
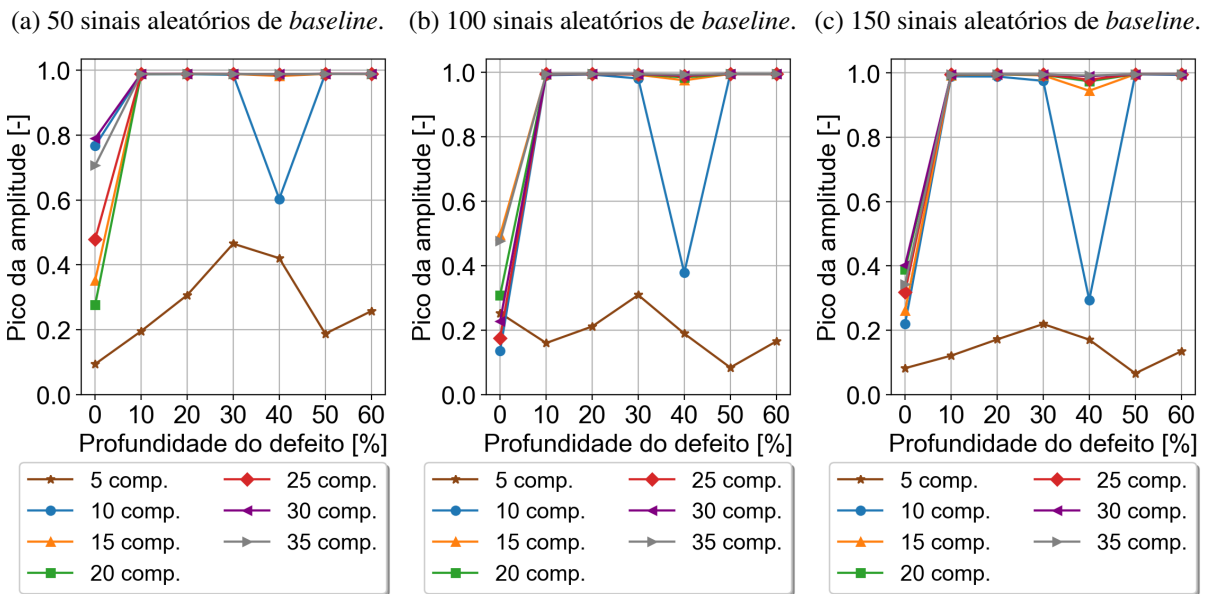


Figura 78: Influência do número de componentes do ICA e do número de sinais aleatórios de *baseline* para o par de sensores e2r3, dano II e frequência central de 80 kHz.



APÊNDICE B INFLUÊNCIA DO NÚMERO DE COMPONENTES DO ICA E DO NÚMERO DE SINAIS ALEATÓRIOS DE *BASELINE* NA DETECÇÃO E QUANTIFICAÇÃO DO DANO I

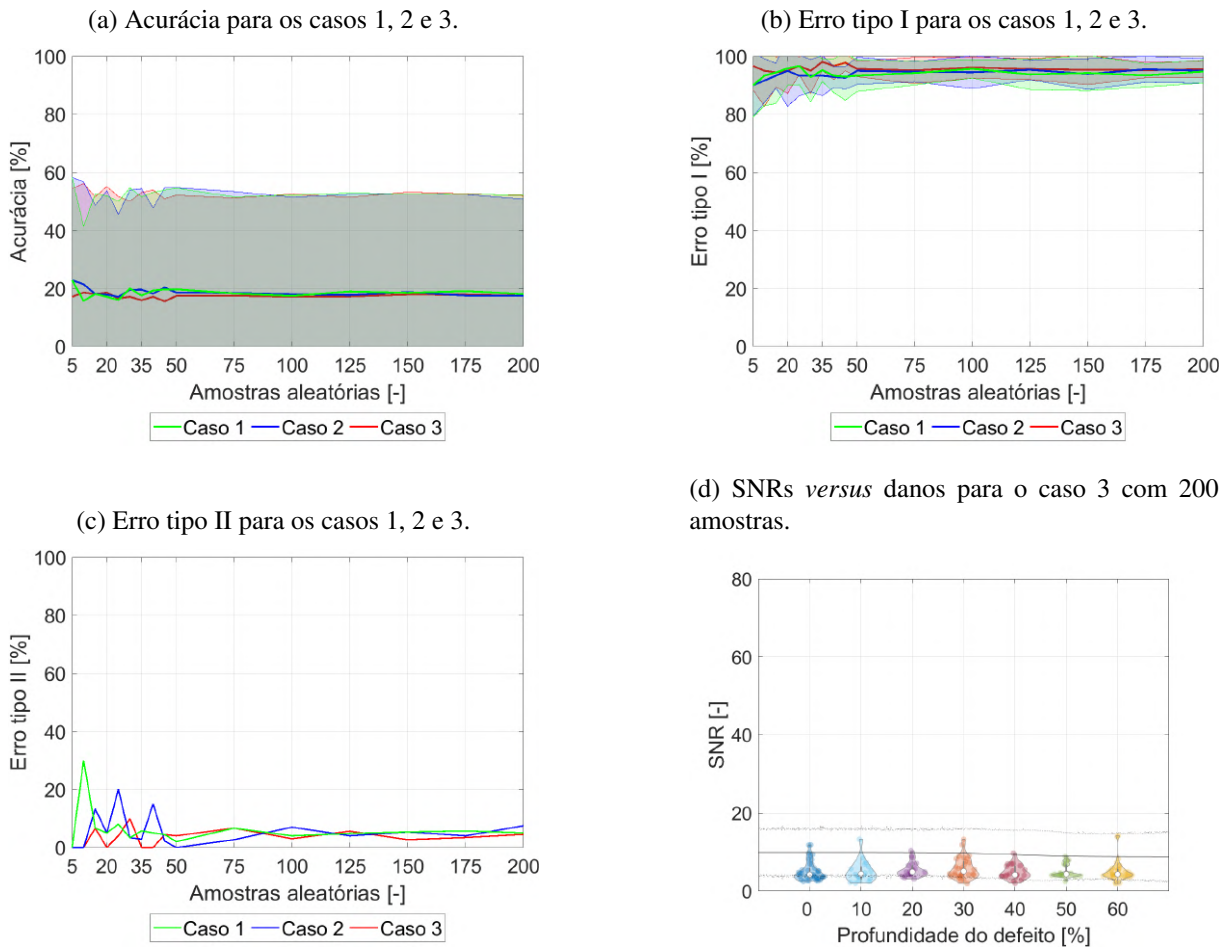
B.1 50 sinais aleatórios de *baseline*

Tabela 19: Valores obtidos na regressão usando a função sigmóide nos *outliers* do par de sensores e2r3 para o caso 3 com 200 realizações aleatórias, dano I, frequência central de 45 kHz, 50 sinais aleatórios de *baseline* e 5, 10, 20, 25, 30 e 35 componentes independentes.

	5 comp.	10 comp.	20 comp.	25 comp.	30 comp.	35 comp.
a	-0.03376	-3555	505.4	-3.644	0.9755	-15.75
b	-39.26	-3297	1.034e+04	-1.028	27.39	97.28
c	8.803	8.879	-0.8559	17.89	2.388	11.49
d	1.748	-0.9675	-0.9702	-2.621	-1.99	0.02738
e	-35.72	-255.1	389.9	-0.1537	1.292	31.55
r^2	0.0446	0.7464	0.9614	0.5347	0.4201	0.0168

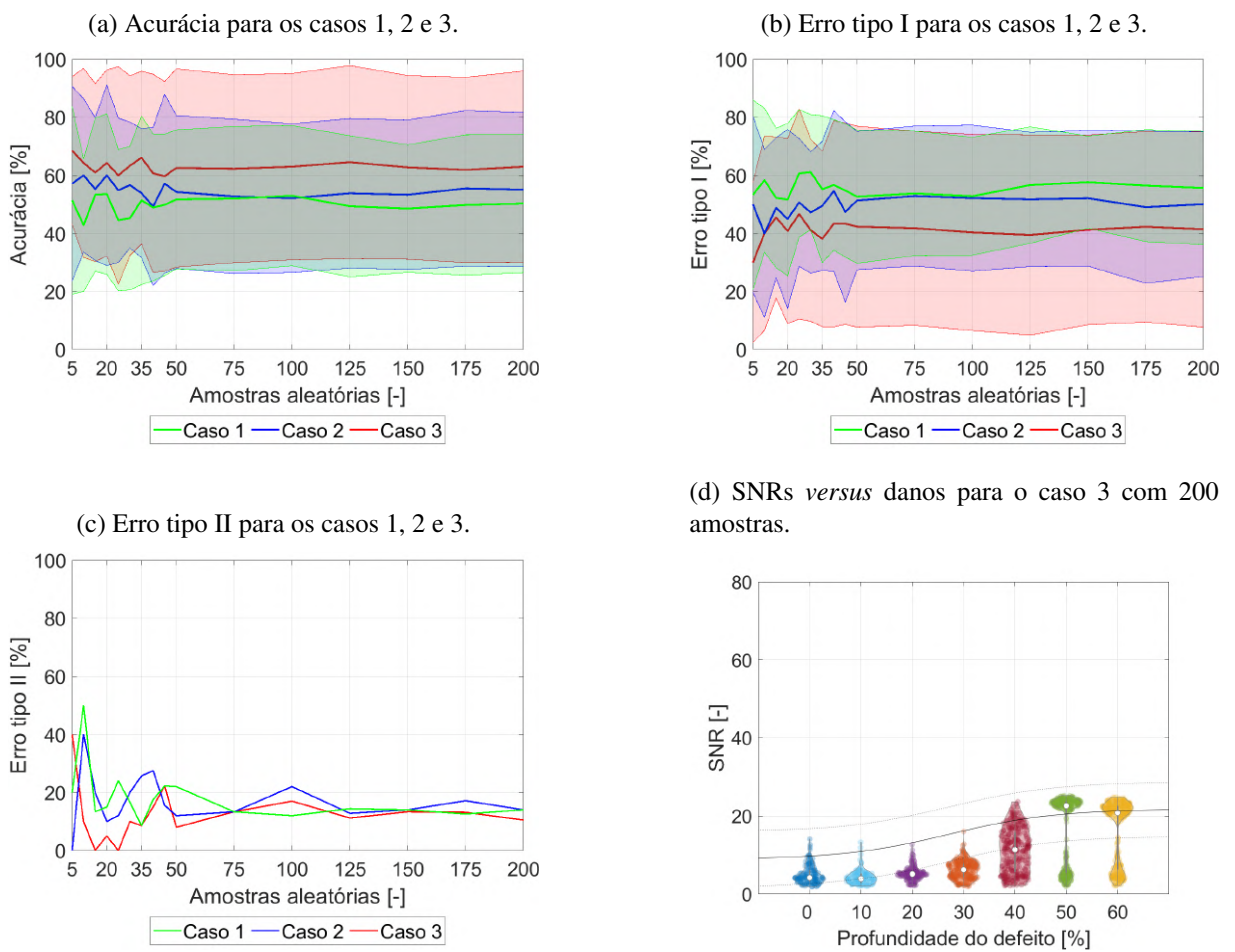
Fonte: Próprio Autor.

Figura 79: Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs *versus* danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 50 sinais aleatórios de *baseline* e 5 componentes independentes.



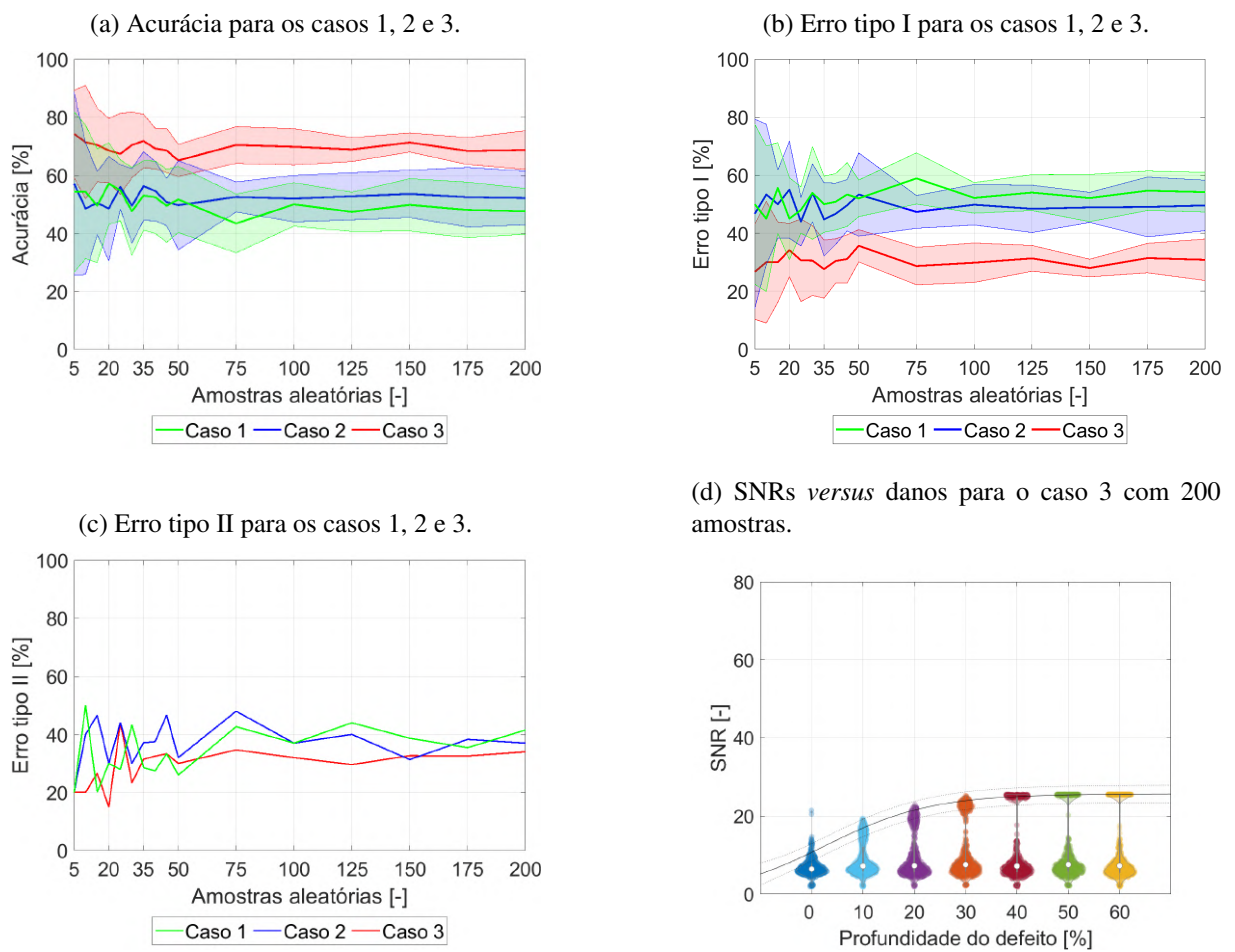
Fonte: Próprio Autor.

Figura 80: Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs *versus* danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 50 sinais aleatórios de *baseline* e 10 componentes independentes.



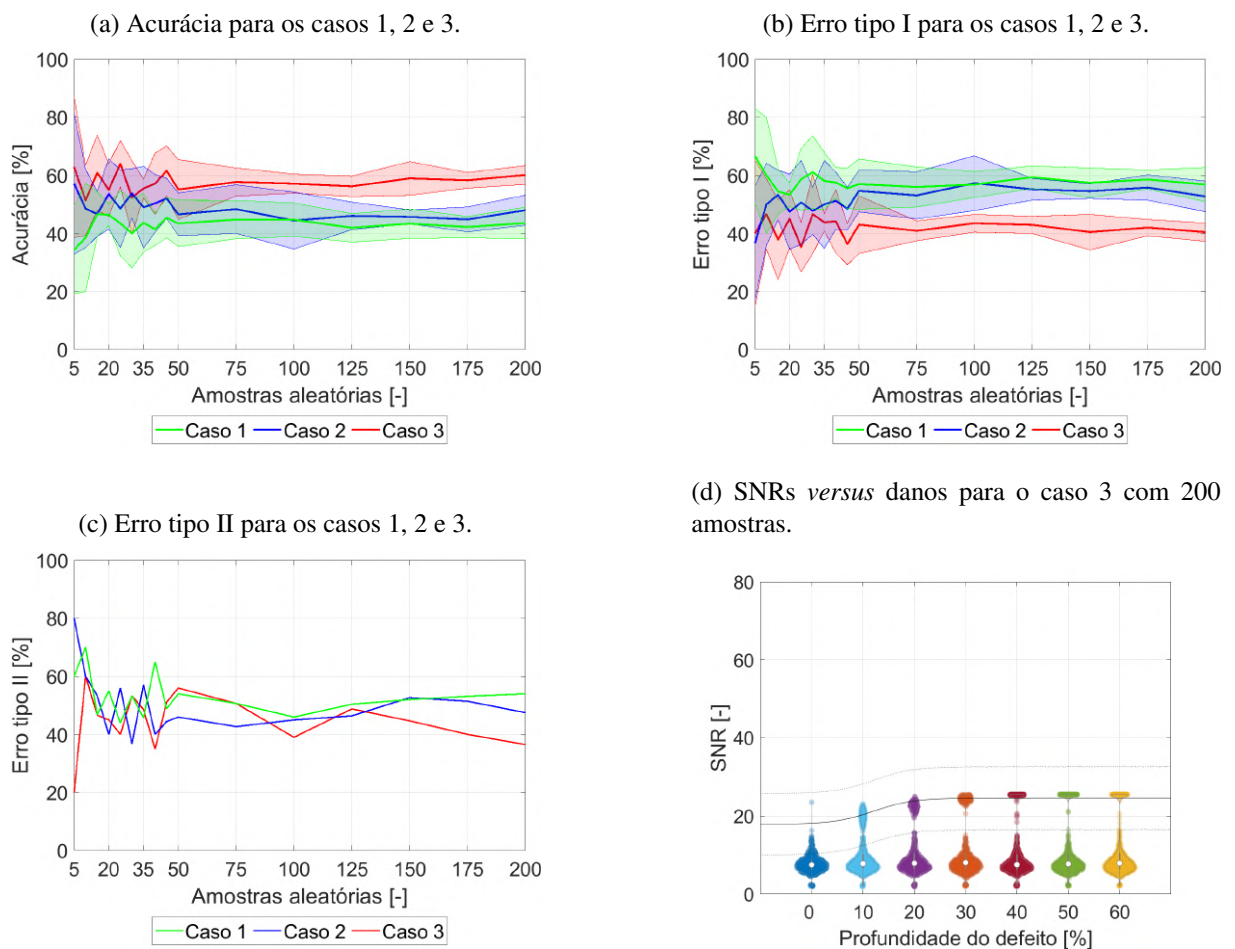
Fonte: Próprio Autor.

Figura 81: Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs *versus* danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 50 sinais aleatórios de *baseline* e 20 componentes independentes.



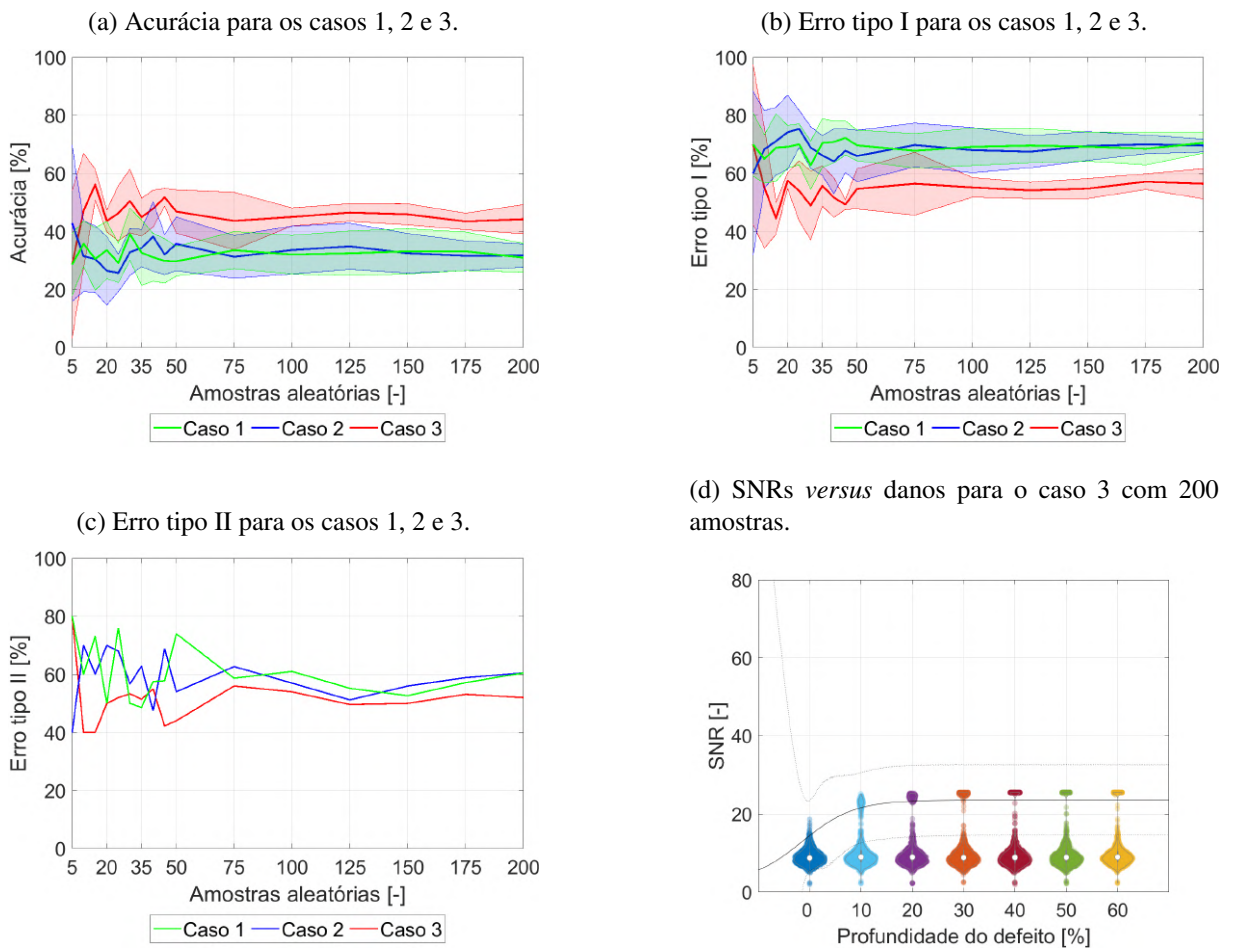
Fonte: Próprio Autor.

Figura 82: Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs *versus* danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 50 sinais aleatórios de *baseline* e 25 componentes independentes.



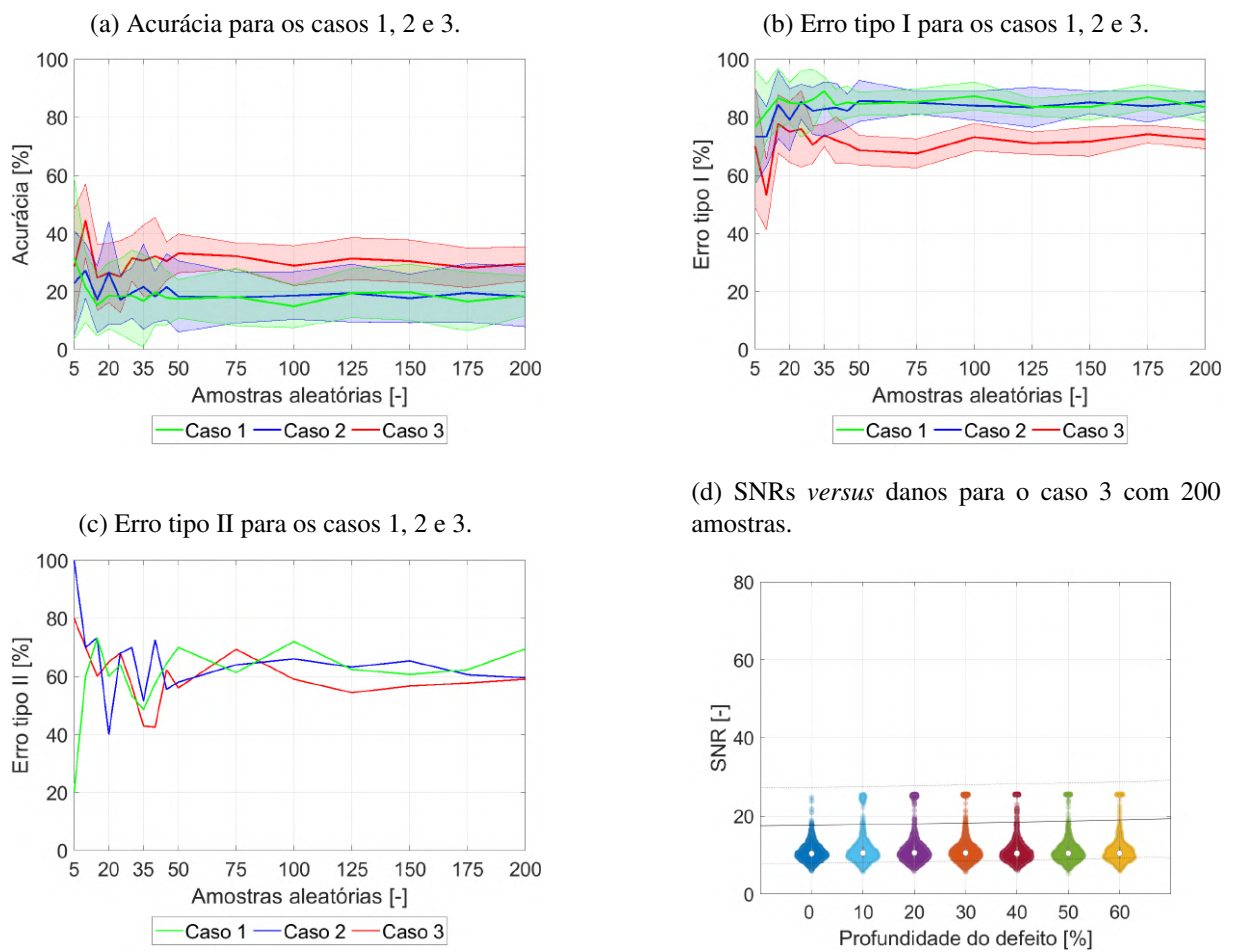
Fonte: Próprio Autor.

Figura 83: Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs *versus* danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 50 sinais aleatórios de *baseline* e 30 componentes independentes.



Fonte: Próprio Autor.

Figura 84: Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs *versus* danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 50 sinais aleatórios de *baseline* e 35 componentes independentes.



Fonte: Próprio Autor.

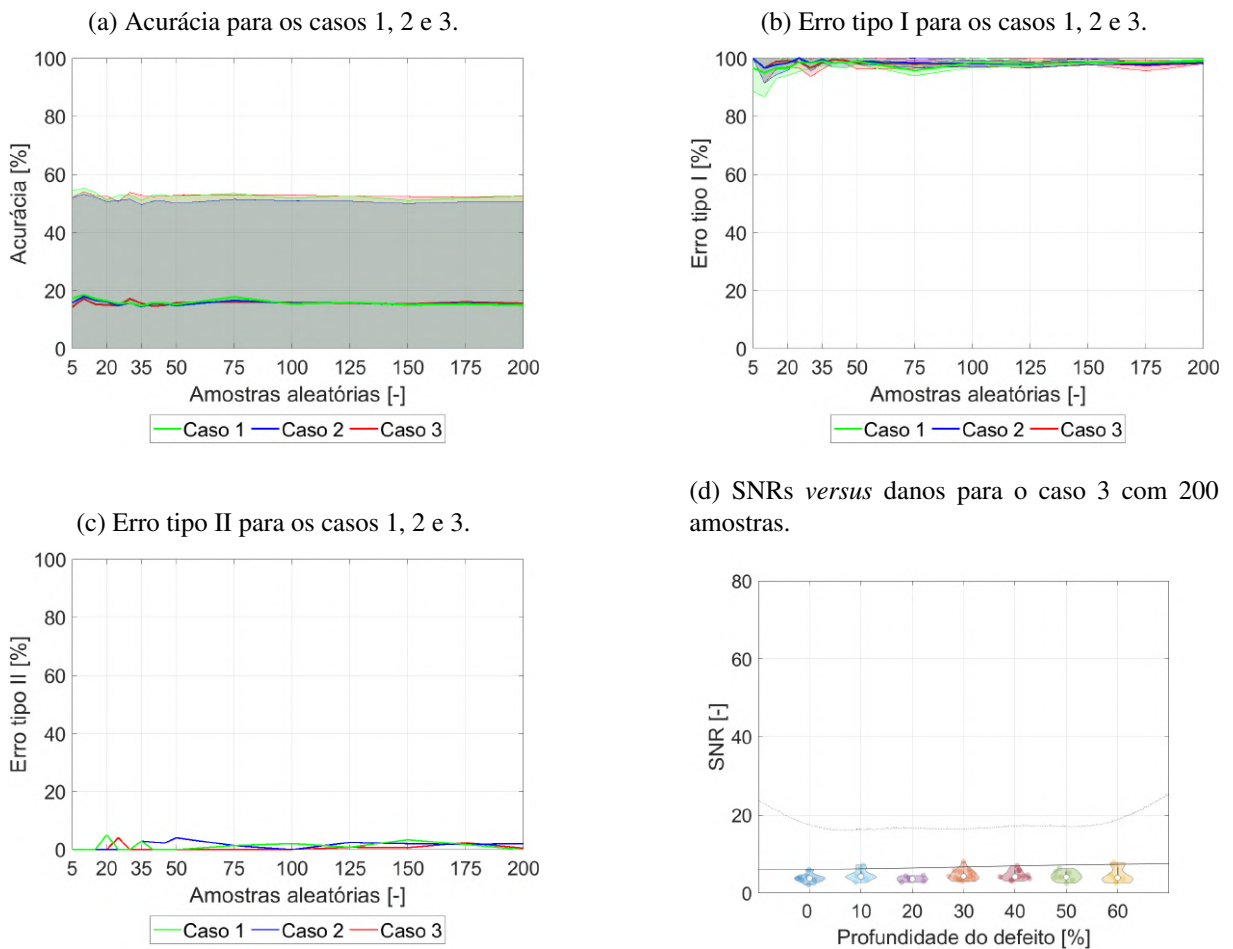
B.2 100 sinais aleatórios de *baseline*

Tabela 20: Valores obtidos na regressão usando a função sigmóide nos *outliers* do par de sensores e2r3 para o caso 3 com 200 realizações aleatórias, dano I, frequência central de 45 kHz, 100 sinais aleatórios de *baseline* e 5, 10, 15, 25, 30 e 35 componentes independentes.

	5 comp.	10 comp.	15 comp.	25 comp.	30 comp.	35 comp.
a	45.22	-795.2	-7.009e+04	-620.4	1.749e+04	1.921
b	15.14	-13.04	-8.169e+04	-1972	5.434e+04	34.25
c	5.787	5.65	4.077	7.9	9.625	2.039
d	-0.5715	-1.83	-1.037	-1.148	-1.408	-1.124
e	8.205	-0.5554	-1742	-46.38	1357	0.7252
r^2	0.1660	0.7828	0.9655	0.9860	0.9670	0.9117

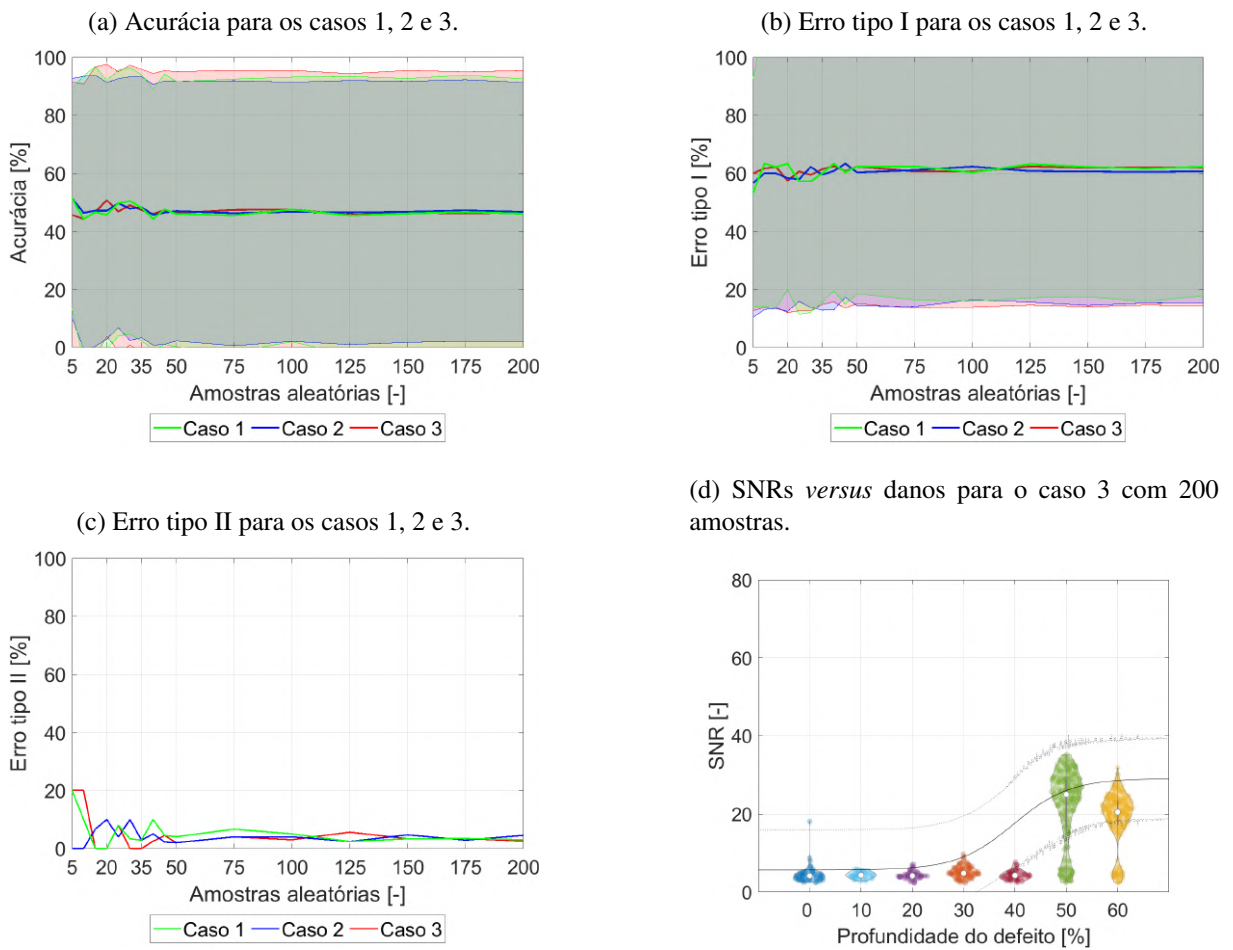
Fonte: Próprio Autor.

Figura 85: Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs *versus* danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 100 sinais aleatórios de *baseline* e 5 componentes independentes.



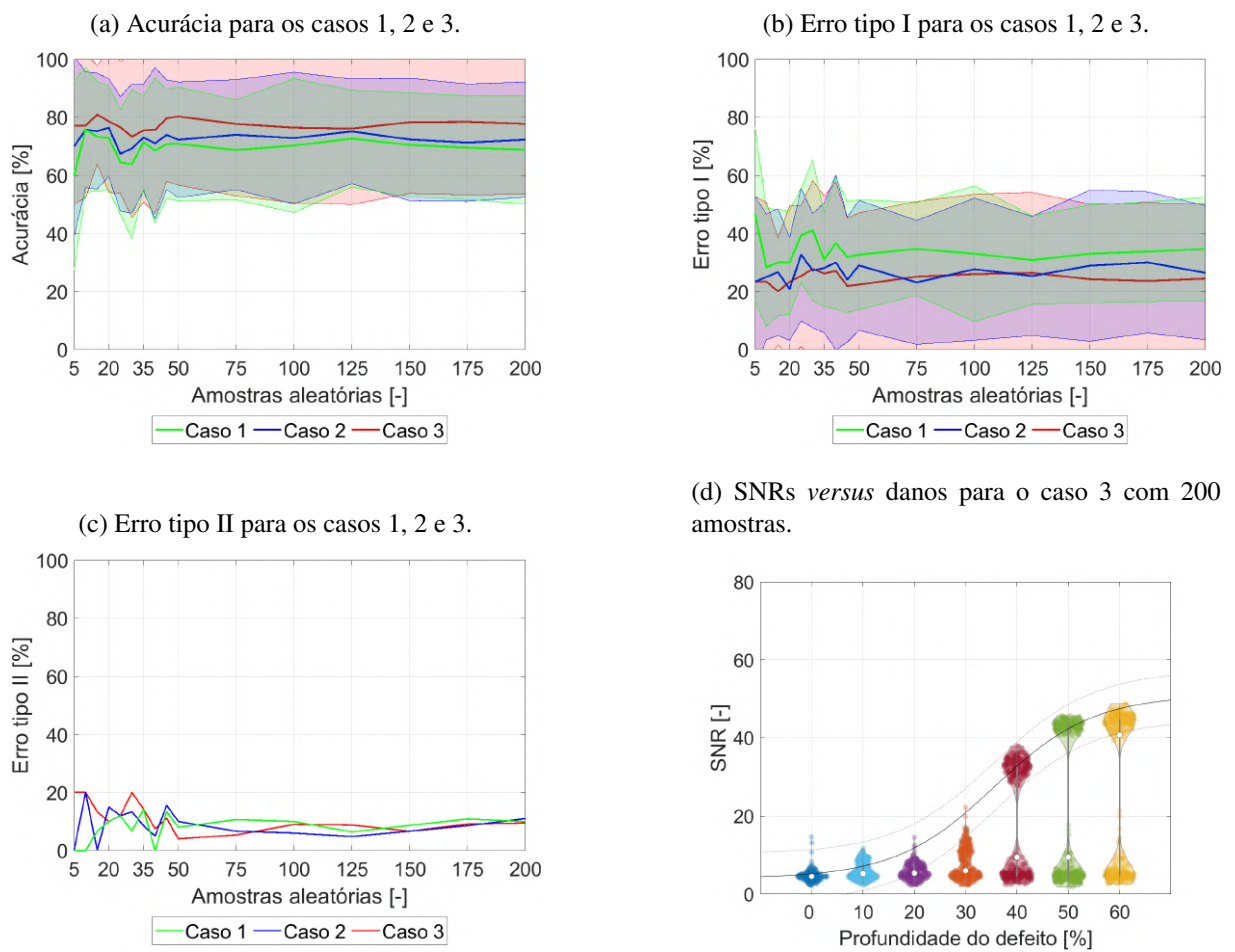
Fonte: Próprio Autor.

Figura 86: Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs *versus* danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 100 sinais aleatórios de *baseline* e 10 componentes independentes.



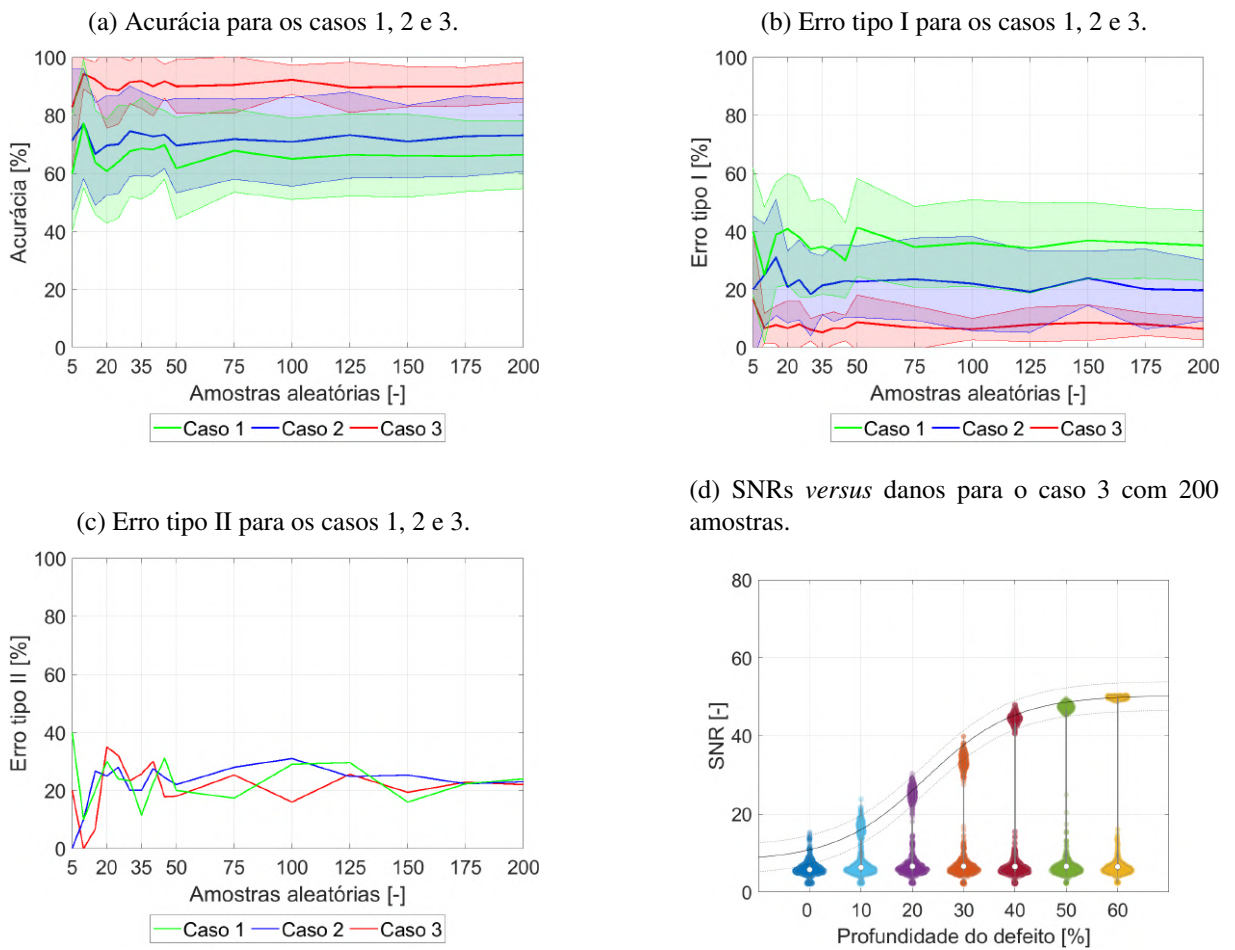
Fonte: Próprio Autor.

Figura 87: Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs *versus* danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 100 sinais aleatórios de *baseline* e 15 componentes independentes.



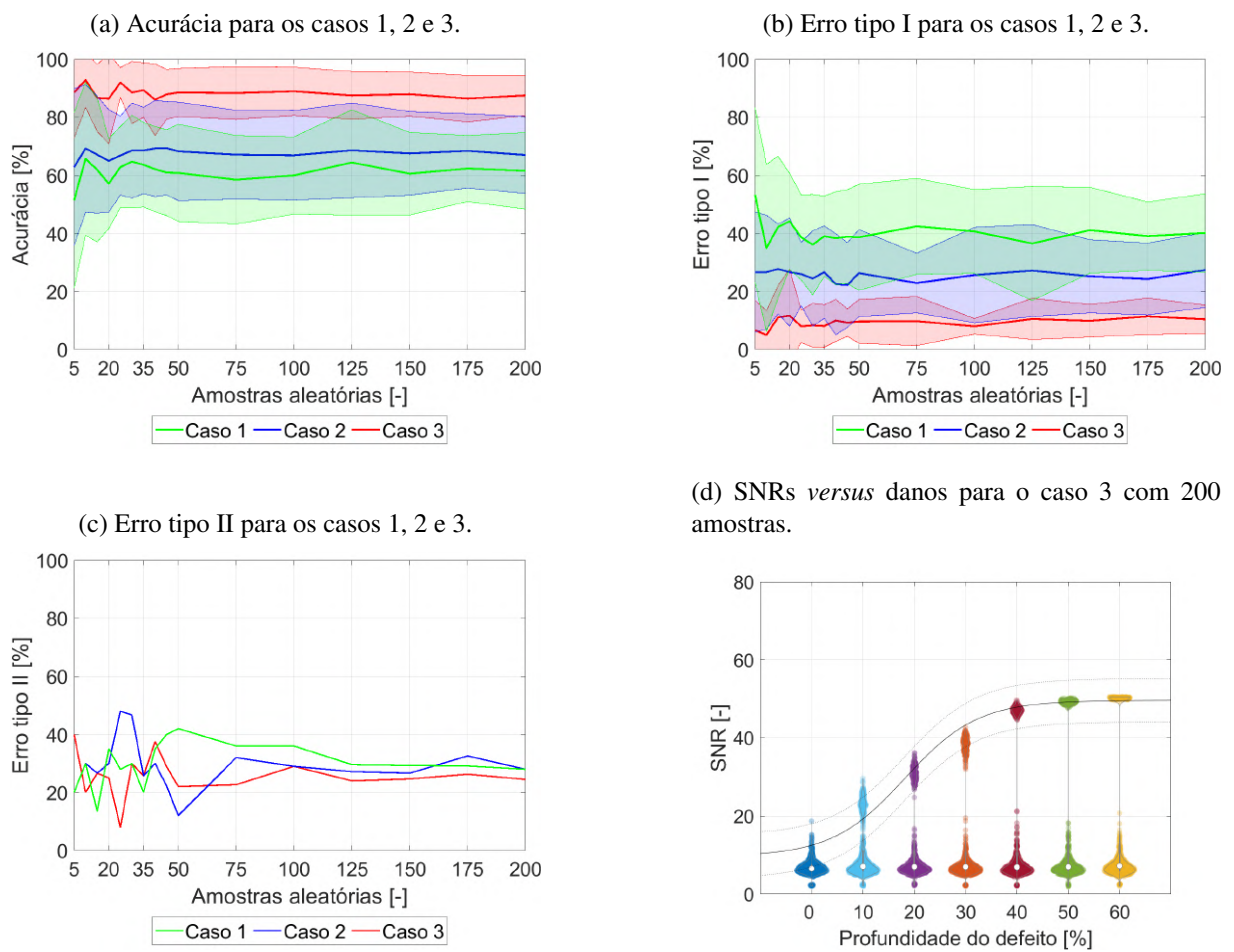
Fonte: Próprio Autor.

Figura 88: Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs *versus* danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 100 sinais aleatórios de *baseline* e 25 componentes independentes.



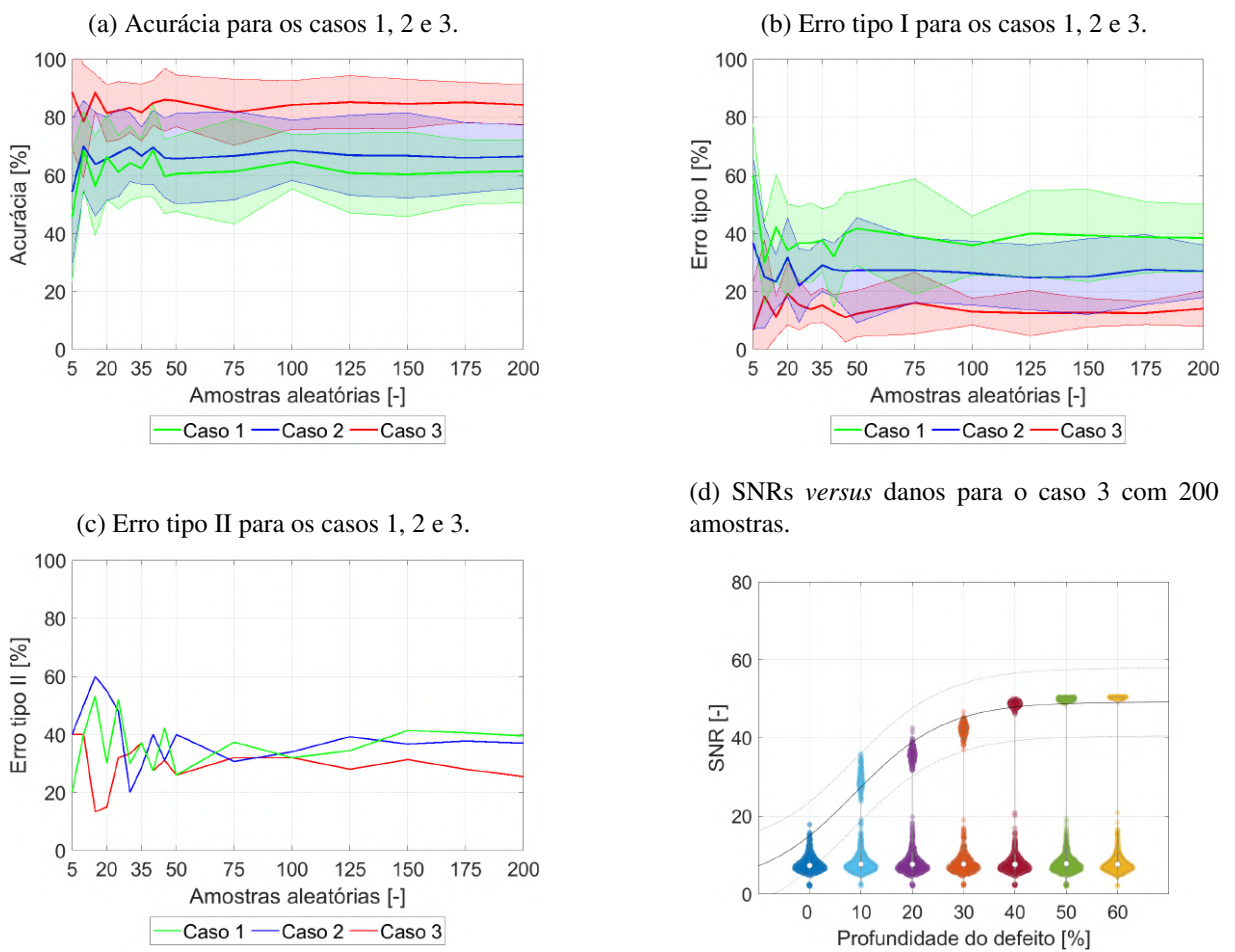
Fonte: Próprio Autor.

Figura 89: Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs *versus* danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 100 sinais aleatórios de *baseline* e 30 componentes independentes.



Fonte: Próprio Autor.

Figura 90: Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs *versus* danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 100 sinais aleatórios de *baseline* e 35 componentes independentes.



Fonte: Próprio Autor.

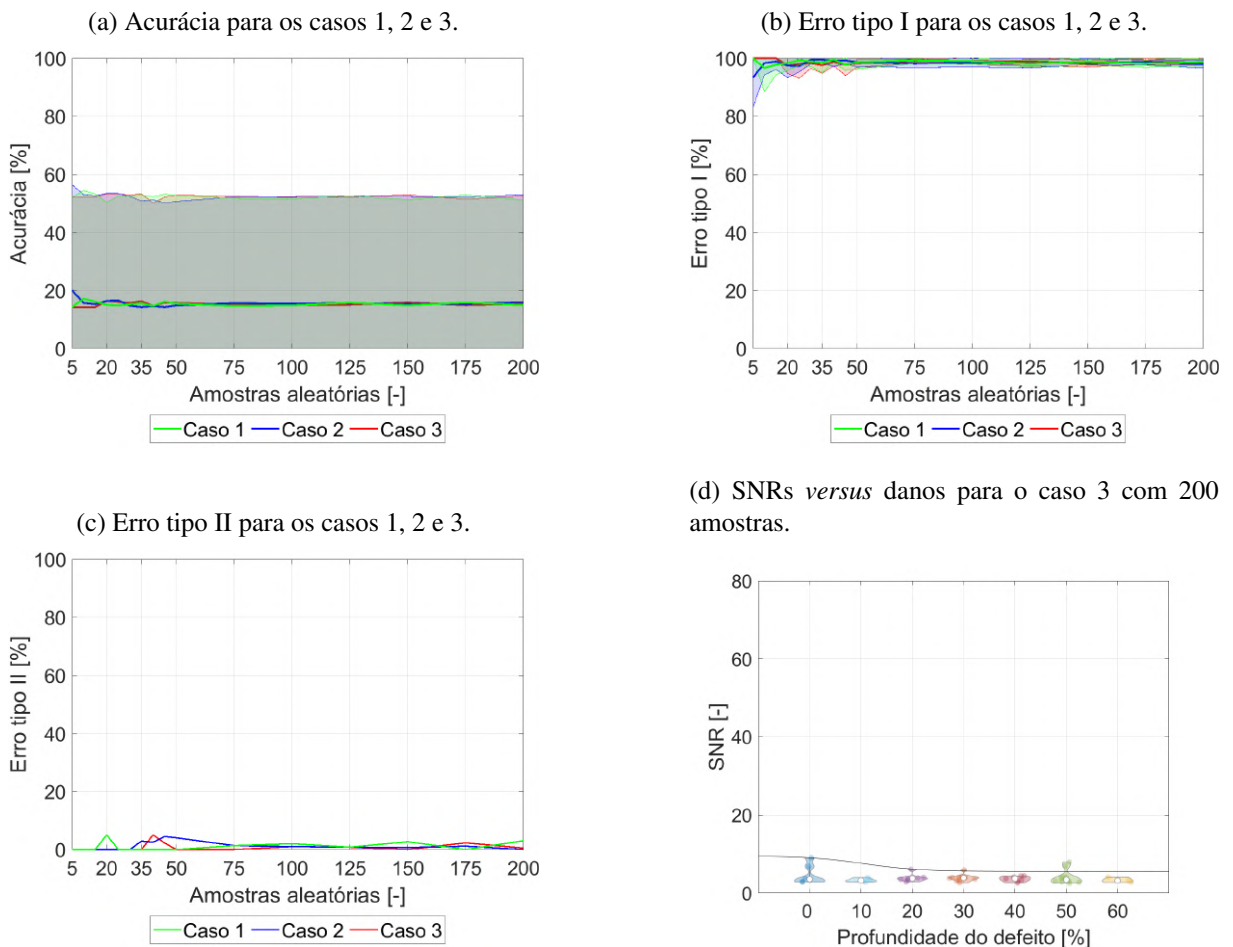
B.3 150 sinais aleatórios de *baseline*

Tabela 21: Valores obtidos na regressão usando a função sigmóide nos *outliers* do par de sensores e2r3 para o caso 3 com 200 realizações aleatórias, dano I, frequência central de 45 kHz, 150 sinais aleatórios de *baseline* e 5, 10, 15, 20, 30 e 35 componentes independentes.

	5 comp.	10 comp.	15 comp.	20 comp.	30 comp.	35 comp.
a	1.202	-19.27	-2.786	5.454e+04	-1.454e+04	5707
b	33.4	-2.739	-0.0005022	5.73e+04	-2.256e+05	3.675e+04
c	5.568	5.726	6.81	6.185	-4.217	10.1
d	1.86	-0.9439	-3.178	1.166	-0.7069	-1.085
e	8.464	-0.2193	-9.948e-06	874.9	-2740	619.1
r^2	0.5058	0.8734	0.9966	0.9948	0.9819	0.8358

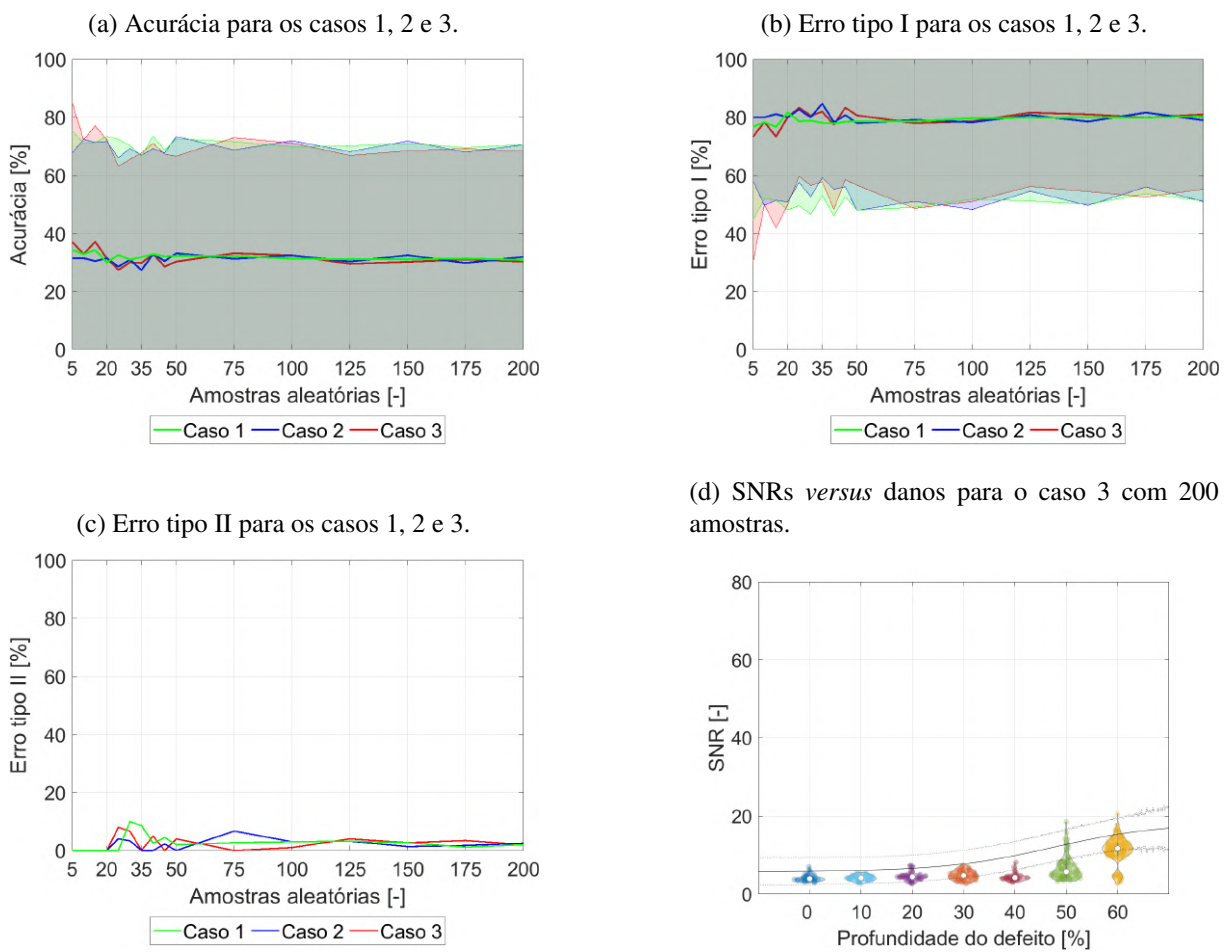
Fonte: Próprio Autor.

Figura 91: Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs *versus* danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 150 sinais aleatórios de *baseline* e 5 componentes independentes.



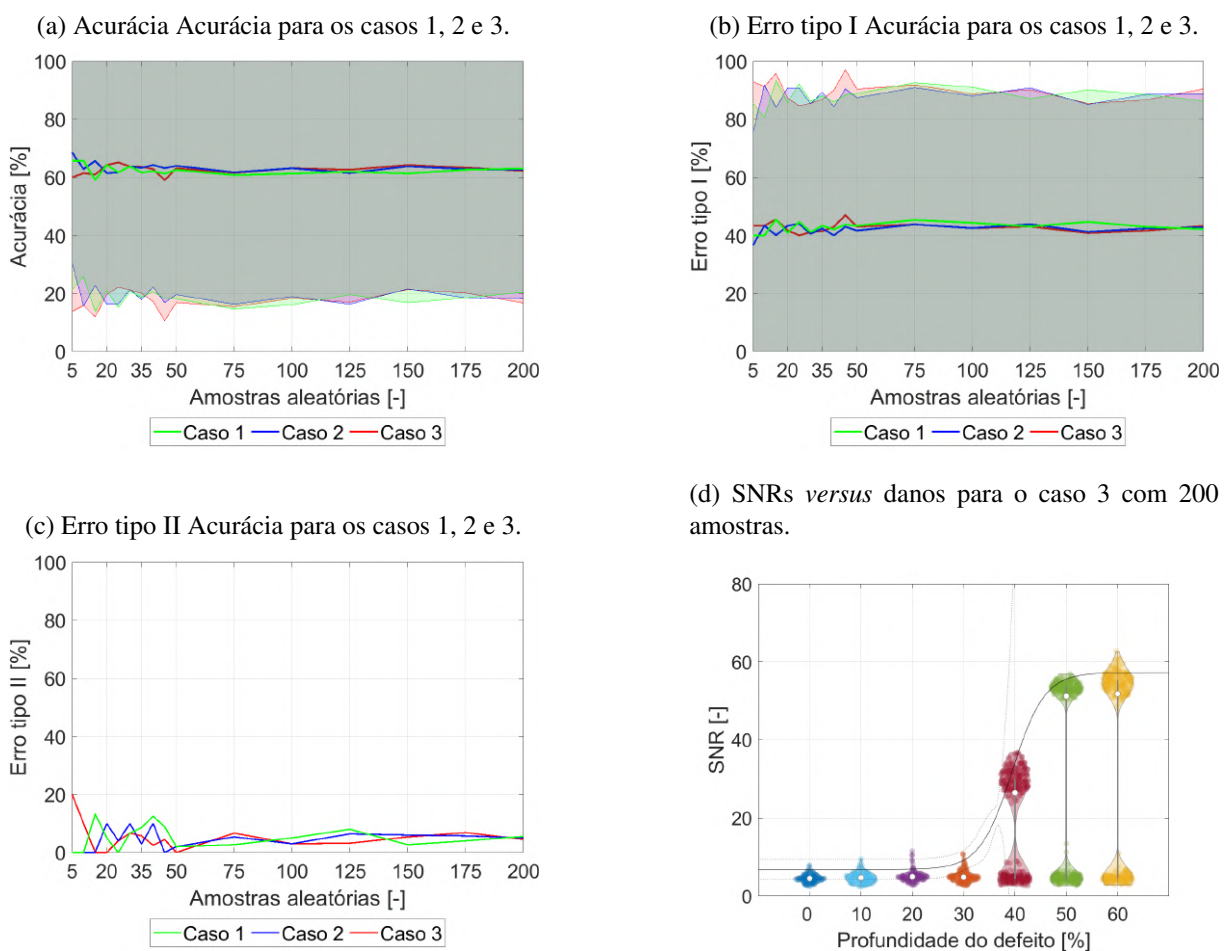
Fonte: Próprio Autor.

Figura 92: Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs *versus* danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 150 sinais aleatórios de *baseline* e 10 componentes independentes.



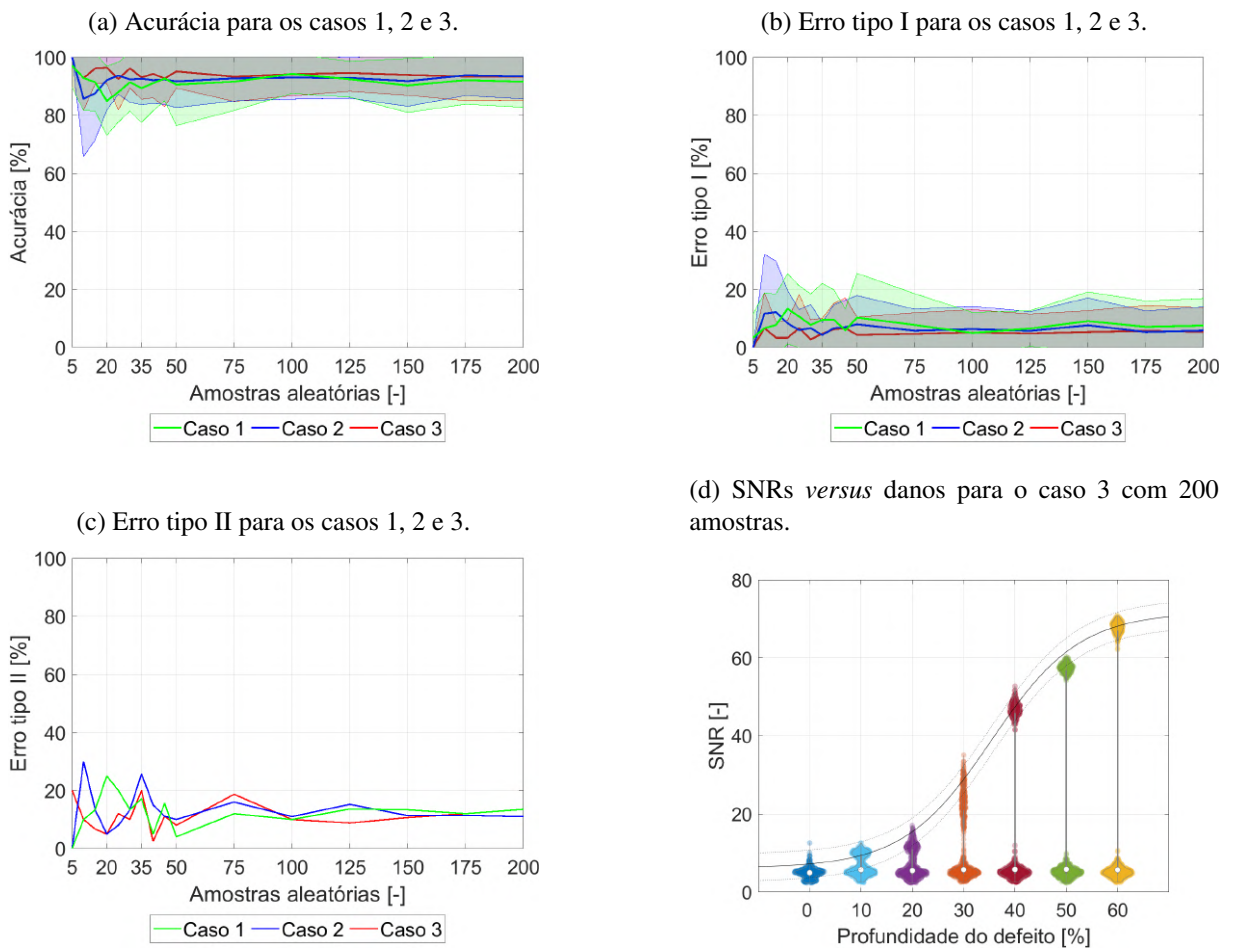
Fonte: Próprio Autor.

Figura 93: Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs *versus* danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 150 sinais aleatórios de *baseline* e 15 componentes independentes.



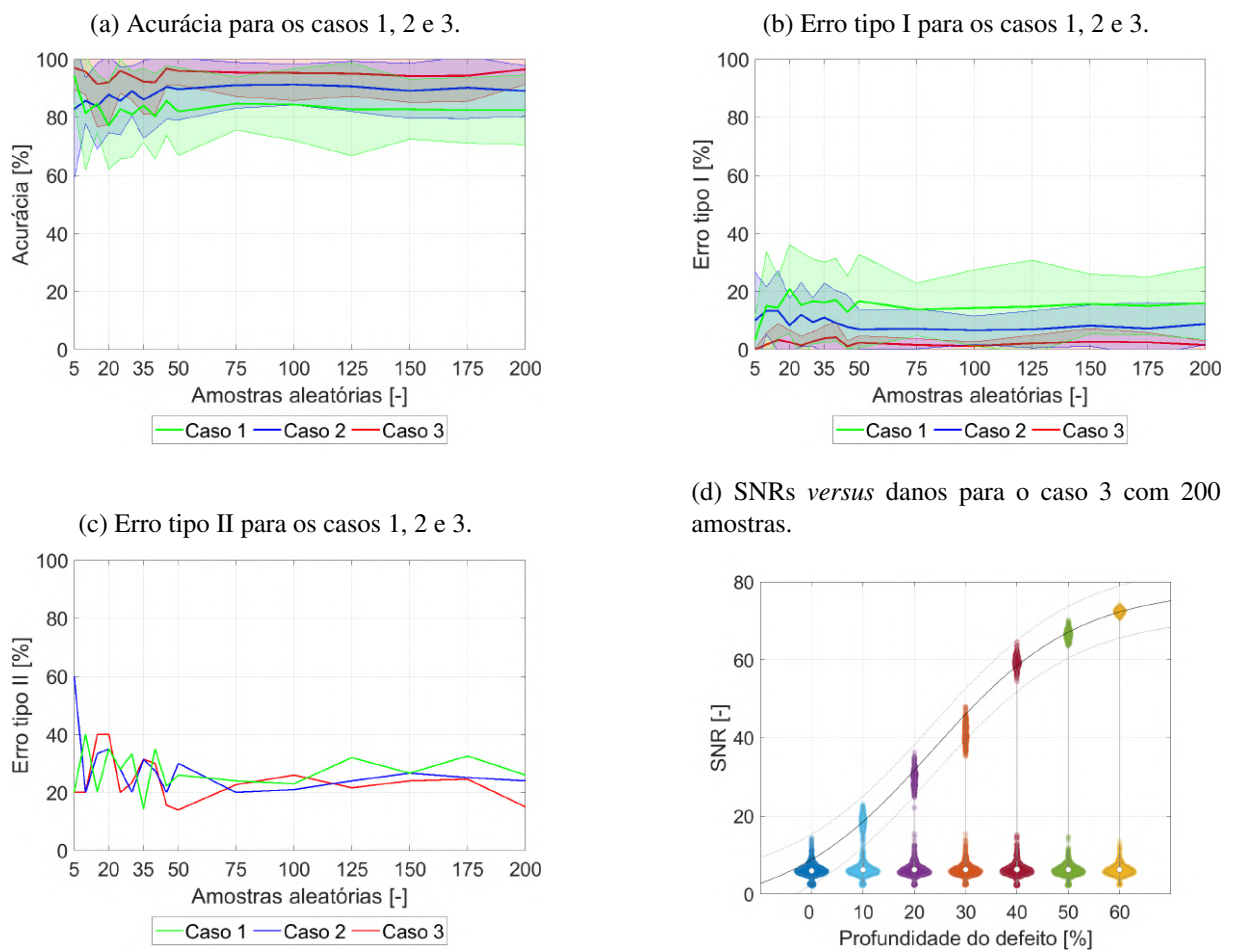
Fonte: Próprio Autor.

Figura 94: Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs *versus* danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 150 sinais aleatórios de *baseline* e 20 componentes independentes.



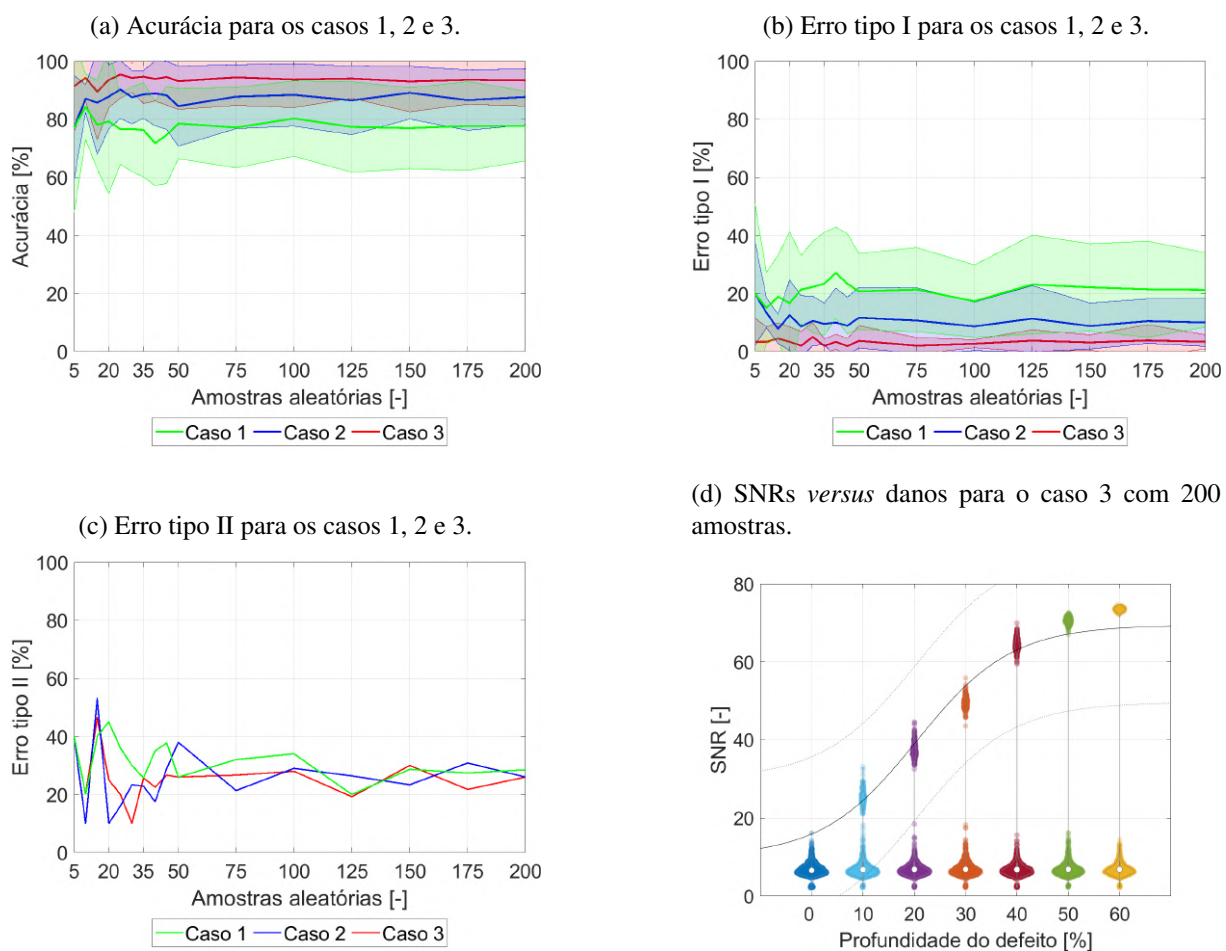
Fonte: Próprio Autor.

Figura 95: Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs *versus* danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 150 sinais aleatórios de *baseline* e 30 componentes independentes.



Fonte: Próprio Autor.

Figura 96: Influência do número de realizações aleatórias na acurácia e nos erros tipo I e II para os casos 1, 2 e 3 e SNRs *versus* danos para o caso 3 com 200 amostras para o par de sensores e2r3, dano I, frequência central de 45 kHz, 150 sinais aleatórios de *baseline* e 35 componentes independentes.



Fonte: Próprio Autor.