



**Hugo Daniel Lino Rações**

Licenciado em Ciência e Engenharia Informática

## **Aprendizagem Automática para Detecção de Avarias em Rolamentos de Motores de Indução**

Dissertação para obtenção do Grau de Mestre em  
**Engenharia Informática**

Orientador: João Moura Pires, Professor Auxiliar,  
Universidade Nova de Lisboa

Co-orientador: Carlos Viegas Damásio, Professor Associado,  
Universidade Nova de Lisboa

Júri

Presidente: João Magalhães, Professor Associado,  
Universidade Nova de Lisboa

Arguente: Paulo Cortez, Professor Associado c/ Agregação,  
Universidade do Minho



FACULDADE DE  
CIÊNCIAS E TECNOLOGIA  
UNIVERSIDADE NOVA DE LISBOA

**Dezembro, 2018**



## **Aprendizagem Automática para Detecção de Avarias em Rolamentos de Motores de Indução**

Copyright © Hugo Daniel Lino Rações, Faculdade de Ciências e Tecnologia, Universidade NOVA de Lisboa.

A Faculdade de Ciências e Tecnologia e a Universidade NOVA de Lisboa têm o direito, perpétuo e sem limites geográficos, de arquivar e publicar esta dissertação através de exemplares impressos reproduzidos em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, e de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objetivos educacionais ou de investigação, não comerciais, desde que seja dado crédito ao autor e editor.



*Aos meus pais.*



## AGRADECIMENTOS

Primeiramente, o meu agradecimento aos professores João Moura Pires e Carlos Damásio cuja orientação dada ao longo da realização desta dissertação foi chave para o sucesso da mesma. Obrigado pela partilha de conhecimento e experiência, competência, rigor, colaboração e confiança no meu trabalho.

Ao professor Fernando Ferreira um muito obrigado pela sua contribuição no trabalho desenvolvido e constante disponibilidade para me transmitir fundamentos de uma área que me era desconhecida.

Um obrigado à Altran Portugal pela oportunidade de trabalhar neste projeto, assim como a todos os que passaram pela equipa ao longo deste percurso.

Aos meus pais agradeço os valores transmitidos, a confiança, o apoio incondicional e o facto de diariamente colocarem as suas aspirações em segundo plano para me concederem oportunidades que não tiveram.



## RESUMO

---

Os motores elétricos e sistemas que derivam dos mesmos, segundo a agência internacional de energia, representam mais de 50% do consumo de eletricidade global, sendo que a nível industrial, o consumo de energia elétrica dos motores elétricos corresponde a cerca de 2/3 do consumo do sector. Dentro dos diversos tipos de motores elétricos, o mercado apresenta os motores de indução como os mais bem sucedidos, sendo estes reparados tipicamente 2 a 4 vezes ao longo do seu tempo de vida de 12 a 20 anos.

Apesar da baixa probabilidade de avaria, existe um grande interesse em evitar que uma aconteça inesperadamente, especialmente para motores de grande importância. Este interesse deve-se ao facto de que é estimado que uma paragem não programada possa custar dez vezes mais que uma paragem programada, pelo que de uma perspectiva técnico-económica, o investimento no melhoramento do rendimento e fiabilidade dos motores elétricos é, em geral, muito atrativo para a grande maioria das indústrias.

Neste contexto, decorre na Altran Portugal o projecto REARM II (pRedictivE mAintenance of electRic Motors II), cujos objetivos passam por desenvolver uma plataforma de manutenção preditiva para motores elétricos de onde se pretende obter uma avaliação do estado do motor e fazer a deteção de avarias ainda num estado inicial, fornecendo atempadamente sinais de alarme acerca do estado de funcionamento do motor e minimizando dessa forma a probabilidade da ocorrência súbita e intempestiva de uma avaria catastrófica que implique a paragem imediata ou não programada de um motor. Fazendo esta dissertação parte do projeto mencionado, a mesma foca-se no desenvolvimento de um classificador para deteção de avarias nos rolamentos de um motor de indução trifásico com base na análise da sua vibração e correntes elétricas, sendo que foram avaliados diversos conjuntos de *features* resultantes de ambas as análises, assim como a frequência de amostragem e período de análise mínimos para uma classificação bem sucedida, tendo sido atingidos excelentes resultados.

**Palavras-chave:** Motor de Indução, Aprendizagem Automática, Deteção de avarias nos rolamentos

---



## ABSTRACT

---

Electric motors systems, according to the international energy agency, represent more than 50% of the global electrical consumption while, in the industrial sector, the energy consumed by electric motors corresponds to about 2/3 of the overall consumption. There are various types of electric motors with the market presenting the induction motor as the most successful, and these are typically repaired 2 to 4 times in their 12 to 20 year lifetimes.

Despite the low breakdown probability, there is great interest in avoiding an unexpected breakdown happens, especially for motors of great importance. This interest is due to the fact that it is estimated that an unscheduled stop of the motor might cost up to ten times more than a scheduled one meaning that, from a technical and economical perspective, investment in the improvement of the efficiency and reliability of electric motors is, in general, very attractive for the vast majority of the industries.

In this context there is a project in Altran Portugal, REARM II (pRedictivE mAintenance of electRic Motors II), whose objectives consist in developing a predictive maintenance platform for electric motors with the intent of evaluating the motor state and detecting faults in its initial state, offering alarm signs about the motor state timely and minimizing the probability of a sudden and untimely catastrophic breakdown that forces an unscheduled stop of the motor. As this dissertation is part of the mentioned project, its aim is to develop a classifier that detects bearing faults in a three-phase induction motor based on vibration and electrical current analysis and, for that purpose, several feature sets resulting from both analyzes were evaluated, as well as the minimum sampling frequency and analysis period needed for a successful classification, achieving excellent results.

**Keywords:** Induction Motor, Machine Learning, Bearing fault detection

---



# ÍNDICE

<b>Lista de Figuras</b>	<b>xvii</b>
<b>Lista de Tabelas</b>	<b>xxv</b>
<b>Siglas</b>	<b>xxix</b>
<b>1 Introdução</b>	<b>1</b>
1.1 Contexto e Motivação . . . . .	1
1.2 Problema . . . . .	4
1.3 Contribuições . . . . .	6
1.4 Abordagem Metodológica . . . . .	7
1.4.1 Fases de Desenvolvimento . . . . .	7
1.4.2 Critérios de Pesquisa e Referências Bibliográficas . . . . .	7
1.4.3 Metodologia CRISP-DM . . . . .	8
1.5 Ferramentas Utilizadas . . . . .	9
1.6 Estrutura do Documento . . . . .	10
<b>2 Noções Fundamentais de Motores de Indução Trifásicos</b>	<b>11</b>
2.1 Motores de Indução Trifásicos . . . . .	11
2.2 Sistema Trifásico . . . . .	12
2.3 Principais Componentes do MIT . . . . .	15
2.3.1 Estator . . . . .	15
2.3.2 Rotor . . . . .	16
2.3.3 Rolamentos . . . . .	17
2.4 Princípio de Funcionamento . . . . .	18
2.5 Propriedades . . . . .	18
2.5.1 Velocidade de Sincronismo . . . . .	18
2.5.2 Deslizamento . . . . .	19
2.5.3 Rendimento . . . . .	19
2.5.4 Binário . . . . .	20
2.5.5 Carga . . . . .	20
2.6 Principais Falhas e Causas . . . . .	20

<b>3</b>	<b>Conceitos de Aprendizagem Automática</b>	<b>23</b>
3.1	Aprendizagem Supervisionada . . . . .	23
3.1.1	Classificação . . . . .	24
3.1.2	Regressão . . . . .	24
3.2	<i>Overfitting</i> e Divisão dos Dados . . . . .	25
3.3	Amostragem Estratificada . . . . .	26
3.4	Normalização de Dados . . . . .	27
3.4.1	Min-Max . . . . .	27
3.5	Métodos de Reamostragem . . . . .	27
3.5.1	Bootstrap . . . . .	27
3.5.2	Cross-validation . . . . .	28
3.6	Métricas de Avaliação . . . . .	28
3.6.1	Exatidão . . . . .	29
3.6.2	Precisão . . . . .	29
3.6.3	Abrangência . . . . .	29
3.6.4	Especificidade . . . . .	30
3.6.5	F1 Score . . . . .	30
3.6.6	Cohen's Kappa e Fleiss' Kappa . . . . .	30
3.7	Técnicas de <i>Ensemble</i> . . . . .	31
3.8	Algoritmos de Classificação . . . . .	32
3.8.1	Support Vector Machine . . . . .	32
3.8.2	Artificial Neural Network . . . . .	32
3.8.3	Random Forests . . . . .	33
3.8.4	Extreme Gradient Boosting . . . . .	33
<b>4</b>	<b>Estado da Arte</b>	<b>35</b>
4.1	Frequências Características da Vibração e Correntes Elétricas na Presença de Avarias no Rolamento . . . . .	35
4.2	Processamento de Sinais . . . . .	37
4.2.1	Transformada Rápida de Fourier . . . . .	37
4.2.2	Transformada de Hilbert . . . . .	38
4.2.3	Transformada de Wavelet Contínua . . . . .	38
4.2.4	Transformada de Park . . . . .	39
4.2.5	Transformada de Park Estendida . . . . .	40
4.3	Métodos para Detecção de Avarias em Rolamentos . . . . .	41
4.3.1	Análise Estatística da Vibração no Domínio Temporal com SVM e ANN . . . . .	41
4.3.2	Análise do Espectro Vibracional Resultante da Transformada Rápida de Fourier com ANN . . . . .	42
4.3.3	Análise do Espectro da Amplitude Instantânea da Transformada de Hilbert com SVM . . . . .	42

4.3.4	Análise Estatística da Transformada de Wavelet Contínua da Vibração e das Correntes Elétricas com ANN e SVM . . . . .	43
4.3.5	Análise da Transformada de Park das Correntes Elétricas com ANN	44
4.3.6	Estudo da Transformada de Park Estendida das Correntes Elétricas	45
4.4	Conclusões . . . . .	46
<b>5</b>	<b>Compreensão e Preparação dos Dados</b>	<b>47</b>
5.1	Compreensão dos Dados . . . . .	47
5.1.1	Descrição dos <i>Datasets</i> Utilizados . . . . .	47
5.1.2	Observação das Correntes e Tensões Elétricas, e da Vibração no Domínio Temporal . . . . .	53
5.1.3	Estudo da Assinatura Espectral das Correntes Elétricas e da Vibração	61
5.1.4	Avaliação do Impacto da Frequência de Amostragem no Sinal das Correntes Elétricas e da Vibração . . . . .	66
5.2	Preparação dos Dados . . . . .	69
5.2.1	Análise Estatística da Vibração e da Amplitude Instantânea da Transformada de Hilbert da Vibração no Domínio Temporal . . . . .	70
5.2.2	Análise do Espectro Vibracional Resultante da Transformada Rápida de Fourier . . . . .	75
5.2.3	Análise do Desvio das Correntes Elétricas a uma Sinusoide Perfeita no Domínio Temporal . . . . .	77
5.2.4	Análise da Excentricidade da Elipse Resultante da Transformada de Park das Correntes Elétricas . . . . .	78
5.2.5	Análise Estatística e Espectral da Transformada de Park Estendida das Correntes Elétricas . . . . .	80
5.3	Conclusões . . . . .	85
<b>6</b>	<b>Modelação e Avaliação</b>	<b>87</b>
6.1	Definições e Nomenclaturas . . . . .	87
6.2	Procedimento . . . . .	88
6.2.1	Pré-processamento, Divisão de Dados e Validação do Modelo . . . . .	88
6.2.2	Algoritmos de Classificação . . . . .	88
6.2.3	Métricas de Avaliação . . . . .	89
6.3	Deteção da Avaria através da Análise da Vibração . . . . .	89
6.3.1	Calibração da Análise Espectral da Vibração . . . . .	90
6.3.2	Descrição dos <i>Feature Sets</i> . . . . .	91
6.3.3	Distinção entre Estado Avariado e Saudável . . . . .	95
6.3.4	Identificação da Localização da Avaria no Rolamento . . . . .	104
6.4	Deteção de Avaria através da Análise das Correntes . . . . .	108
6.4.1	Calibração da Análise Espectral da Transformada de Park Estendida	109
6.4.2	Descrição dos <i>Feature Sets</i> . . . . .	110

6.4.3	Distinção entre Estado Avariado e Saudável . . . . .	113
<b>7</b>	<b>Conclusão e Trabalho Futuro</b>	<b>121</b>
7.1	Conclusão . . . . .	121
7.2	Trabalho Futuro . . . . .	123
	<b>Bibliografia</b>	<b>125</b>
<b>A</b>	<b>Comparação de Desempenhos de Diferentes Parametrizações dos Algoritmos Utilizados</b>	<b>129</b>
<b>B</b>	<b>Resultados da Calibração da Análise Espectral da Transformada de Park Estendida</b>	<b>135</b>
<b>C</b>	<b>Resultados da Recursive Feature Elimination da Análise da Vibração e das Correntes Elétricas</b>	<b>137</b>
C.1	Recursive Feature Elimination da Análise da Vibração . . . . .	137
C.2	Recursive Feature Elimination da Análise das Correntes . . . . .	140
<b>D</b>	<b>Matrizes de Confusão Resultantes da Identificação da Localização da Avaria no Rolamento</b>	<b>141</b>

## LISTA DE FIGURAS

1.1	Componentes do custo do ciclo de vida dos MEs [5] . . . . .	2
1.2	Aplicação dos vários tipos de manutenção de motores em função da potência e valor do motor [6] . . . . .	3
1.3	Comparação entre o custo de reparação e o custo de um novo motor [8] . . . . .	5
1.4	Métodos de diagnóstico recomendados para avarias nos rolamentos de MIs [6] . . . . .	6
1.5	Escopo temporal das referências bibliográficas . . . . .	8
1.6	Diagrama do ciclo de vida da metodologia CRISP-DM . . . . .	9
2.1	Motor de Indução Trifásico com Rotor em Gaiola de Esquilo . . . . .	11
2.2	Representação no domínio temporal da tensão no sistema monofásico e ST . . . . .	12
2.3	Representação de uma onda sinusoidal num fasor . . . . .	13
2.4	Representação de uma tensão trifásica equilibrada num fasor [7] . . . . .	14
2.5	Representação de tensões compostas (entre fases) num fasor [7] . . . . .	14
2.6	Principais componentes de um MITGE . . . . .	15
2.7	Constituição e enrolamentos do estator . . . . .	16
2.8	Rotor em Gaiola de Esquilo . . . . .	16
2.9	Esquema dos componentes de rolamentos de esferas e de rolos cilíndricos . . . . .	17
2.10	Rotação do campo magnético de 6 bobinas e 2 polos [7] . . . . .	18
2.11	Tipos de excentricidades da <i>air gap</i> entre o estator e o rotor [17] . . . . .	21
3.1	Exemplo de definição de uma fronteira de classificação entre duas classes . . . . .	24
3.2	Exemplo de um modelo de regressão . . . . .	24
3.3	Exemplo de <i>overfitting</i> e de uma adaptação apropriada aos dados [15] . . . . .	25
3.4	Exemplo de amostragem estratificada entre conjunto de treino e conjunto de teste . . . . .	26
3.5	Exemplo de combinação de três modelos num classificador . . . . .	31
3.6	Exemplo de definição da fronteira entre classes com o algoritmo SVM . . . . .	32
3.7	Exemplo de uma ANN . . . . .	33
3.8	Exemplo de um esquema de classificação com três árvores de decisão resultantes do algoritmo RF . . . . .	33
4.1	Esquema das dimensões de um rolamento de esferas . . . . .	36
4.2	Exemplos da aplicação da transformada rápida de Fourier . . . . .	37

---

4.3	Exemplos da aplicação da Transformada de Hilbert . . . . .	38
4.4	Visualização da TWC [28] . . . . .	39
4.5	Passagem de um ciclo de correntes elétricas do domínio temporal para o domínio DQ, através da TP [7] . . . . .	39
4.6	TP de um motor em condições ideais e avariado [7] . . . . .	40
4.7	Princípio teórico da TPE [29] . . . . .	41
4.8	Processamento de sinal da vibração de um rolamento com uma avaria no anel interior [32] . . . . .	42
4.9	Esquema de classificação multi-classe com cadeia de modelos SVM [33] . . . . .	43
4.10	Domínio DQ da TP da corrente de um motor com rolamentos em condições ideais e avariados [35] . . . . .	44
4.11	Análise de componentes principais da elipse resultante da TP [7] . . . . .	44
4.12	Variação da magnitude de determinadas frequências consoante o aumento do diâmetro do defeito da avaria na pista externa do rolamento [36] . . . . .	45
4.13	Variação da magnitude de determinadas frequências consoante o aumento do diâmetro do defeito da avaria na pista interna do rolamento [37] . . . . .	45
5.1	MITGE utilizado e <i>setup</i> experimental da recolha de dados da Optisigma . . . . .	48
5.2	Dimensões e características do rolamento dos dados Optisigma . . . . .	48
5.3	Rolamentos com defeitos de 2mm e 4mm utilizados pela Optisigma . . . . .	49
5.4	<i>Setup</i> experimental da recolha de dados da CWRU . . . . .	51
5.5	Dimensões e características do rolamento dos dados CWRU . . . . .	51
5.6	Tensões elétricas do motor com todas as cargas com um rolamento saudável . . . . .	54
5.7	Tensões elétricas do motor com todas as cargas com um rolamento avariado (defeito de 1 mm) . . . . .	54
5.8	Tensões elétricas do motor com todas as cargas com um rolamento avariado (defeito de 2 mm) . . . . .	54
5.9	Tensões elétricas do motor com todas as cargas com um rolamento avariado (defeito de 4 mm) . . . . .	55
5.10	Correntes elétricas do motor com todas as cargas com um rolamento saudável . . . . .	55
5.11	Correntes elétricas do motor com todas as cargas com um rolamento avariado (defeito de 1 mm) . . . . .	55
5.12	Comparação entre as correntes elétricas do motor sem carga com um rolamento saudável e com um rolamento avariado (defeito de 1 mm) . . . . .	56
5.13	Correntes elétricas do motor com todas as cargas com um rolamento avariado (defeito de 2 mm) . . . . .	56
5.14	Correntes elétricas do motor com todas as cargas com um rolamento avariado (defeito de 4 mm) . . . . .	56
5.15	Distribuição da magnitude das correntes elétricas do <i>dataset</i> optisigma . . . . .	57
5.16	Vibração do motor com todas as cargas com o rolamento saudável e avariado com defeito de 1 mm ( <i>dataset</i> optisigma) . . . . .	57

---

5.17	Vibração do motor com todas as cargas com os rolamentos avariados com defeitos de 2 mm e 4 mm ( <i>dataset optisigma</i> ) . . . . .	58
5.18	Visualização aproximada da vibração do motor com todas as cargas com os rolamentos avariados com defeitos de 2 mm e 4 mm ( <i>dataset optisigma</i> ) . . .	58
5.19	Análise estatística (média do módulo e desvio padrão) dos registos de vibração do <i>dataset optisigma</i> com uma frequência de amostragem de 10 kHz . . . . .	59
5.20	Vibração do motor com todas as cargas com um rolamento saudável ( <i>dataset CWRU</i> ) . . . . .	59
5.21	Visualização aproximada da vibração do motor com todas as cargas com um rolamento saudável ( <i>dataset CWRU</i> ) . . . . .	59
5.22	Vibração do motor com todas as cargas com rolamentos com defeitos na pista externa ( <i>dataset CWRU</i> ) . . . . .	60
5.23	Vibração do motor com todas as cargas com rolamentos com defeitos na pista interna ( <i>dataset CWRU</i> ) . . . . .	60
5.24	Vibração do motor com todas as cargas com rolamentos com defeitos na esfera ( <i>dataset CWRU</i> ) . . . . .	61
5.25	Espectro de frequências das correntes elétricas do motor com todas as cargas com um rolamento saudável . . . . .	62
5.26	Espectro de frequências das correntes elétricas do motor com todas as cargas com um rolamento avariado (defeito de 1 mm) . . . . .	62
5.27	Espectro de frequências das correntes elétricas do motor com todas as cargas com um rolamento avariado (defeito de 2 mm) . . . . .	63
5.28	Espectro de frequências das correntes elétricas do motor com todas as cargas com um rolamento avariado (defeito de 4 mm) . . . . .	63
5.29	Espectro de frequências da vibração do rolamento saudável e do rolamento com avaria de 1 mm de diâmetro na pista externa do <i>dataset optisigma</i> . . . . .	64
5.30	Espectro de frequências da vibração dos rolamentos com avarias de 2 mm e 4 mm de diâmetro na pista externa do <i>dataset optisigma</i> . . . . .	64
5.31	Espectro de frequências da vibração do rolamento saudável do <i>dataset CWRU</i> . . . . .	65
5.32	Espectro de frequências da vibração dos rolamentos com avarias na pista externa do <i>dataset CWRU</i> . . . . .	65
5.33	Espectro de frequências da vibração dos rolamentos com avarias na pista interna do <i>dataset CWRU</i> . . . . .	66
5.34	Espectro de frequências da vibração dos rolamentos com avarias na esfera do <i>dataset CWRU</i> . . . . .	66
5.35	Registos de ciclos das correntes de um MITGE com diferentes frequências de amostragem . . . . .	67
5.36	Observação aproximada de uma corrente de um MITGE com diferentes frequências de amostragem . . . . .	67
5.37	Registos da vibração de um MITGE com diferentes frequências de amostragem . . . . .	68

5.38	Porcentagem do sinal presente no intervalo Nyquist de cada frequência de amostragem . . . . .	69
5.39	Exemplo de particionamento de um registo da vibração . . . . .	70
5.40	Exemplo de um registo de 20 ms de correntes elétricas e vibração . . . . .	70
5.41	Exemplo de visualização da vibração, módulo da vibração e amplitude instantânea da Transformada de Hilbert da vibração . . . . .	71
5.42	Distribuição do cálculo estatístico do RMS, média do módulo e mediana do módulo sobre a vibração para os estados saudável e avariado do rolamento . . . . .	71
5.43	Distribuição do cálculo estatístico do valor máximo, valor mínimo e amplitude sobre a vibração para os estados saudável e avariado do rolamento . . . . .	72
5.44	Distribuição do cálculo estatístico do desvio padrão e variância sobre a vibração para os estados saudável e avariado do rolamento . . . . .	72
5.45	Distribuição do cálculo estatístico da curtose e assimetria sobre a vibração para os estados saudável e avariado do rolamento . . . . .	73
5.46	Distribuição do cálculo estatístico do fator <i>crest</i> e valor máximo do módulo sobre a vibração para os estados saudável e avariado do rolamento . . . . .	73
5.47	Distribuição do cálculo estatístico do RMS, média e mediana sobre a amplitude instantânea da Transformada de Hilbert da vibração para os estados saudável e avariado do rolamento . . . . .	73
5.48	Distribuição do cálculo estatístico do valor máximo, valor mínimo e amplitude sobre a amplitude instantânea da Transformada de Hilbert da vibração para os estados saudável e avariado do rolamento . . . . .	74
5.49	Distribuição do cálculo estatístico do desvio padrão e variância sobre a amplitude instantânea da Transformada de Hilbert da vibração para os estados saudável e avariado do rolamento . . . . .	74
5.50	Distribuição do cálculo estatístico da curtose e assimetria sobre a amplitude instantânea da Transformada de Hilbert da vibração para os estados saudável e avariado do rolamento . . . . .	74
5.51	Exemplo de visualização de um espectro de frequências resultante da análise de um período de 20 ms de vibração de um rolamento saudável e avariado . . . . .	75
5.52	Distribuição dos quatro maiores picos de frequência e magnitude dos picos de frequência observados no domínio espectral da vibração para os estados saudável e avariado do rolamento . . . . .	76
5.53	Distribuição da densidade espectral dos quatro maiores picos de frequência observados no domínio espectral da vibração para os estados saudável e avariado do rolamento . . . . .	76
5.54	Exemplo de visualização da aproximação de uma senoide perfeita às correntes elétricas A, B e C . . . . .	77
5.55	Distribuição dos desvios das correntes a uma senoide perfeita observados para os estados saudável e avariado do rolamento . . . . .	78

5.56	Comparação entre a elipse resultante da TP das correntes elétricas de um motor saudável e avariado . . . . .	79
5.57	Exemplo de visualização da TP de um período de 20 ms de vibração de um rolamento saudável e avariado . . . . .	79
5.58	Distribuição da excentricidade da elipse observada nos estados saudável e avariado do rolamento . . . . .	80
5.59	Exemplo de visualização da TPE de um período de 20 ms de vibração de um rolamento saudável e avariado . . . . .	81
5.60	Distribuição do cálculo estatístico do RMS e média sobre o resultado da TPE para os estados saudável e avariado do rolamento . . . . .	81
5.61	Distribuição do cálculo estatístico da mediana, valor máximo e mínimo sobre o resultado da TPE para os estados saudável e avariado do rolamento . . . . .	82
5.62	Distribuição do cálculo estatístico da assimetria e amplitude sobre o resultado da TPE para os estados saudável e avariado do rolamento . . . . .	82
5.63	Distribuição do cálculo estatístico da variância e curtose sobre o resultado da TPE para os estados saudável e avariado do rolamento . . . . .	82
5.64	Exemplo de visualização do domínio espectral da TPE de um período de 20 ms de vibração de um rolamento saudável . . . . .	83
5.65	Exemplo de visualização do domínio espectral da TPE de um período de 20 ms de vibração de um rolamento avariado . . . . .	83
5.66	Distribuição da magnitude dos picos de frequência da TPE para os estados saudável e avariado do rolamento . . . . .	84
5.67	Distribuição da densidade espectral dos picos de frequência da TPE para os estados saudável e avariado do rolamento . . . . .	84
6.1	Variação do kappa obtido segundo o número de picos de frequência avaliados na análise espectral da vibração para a classificação entre duas e quatro classes . . . . .	90
6.2	Esquema da constituição dos <i>feature sets</i> resultantes da análise da vibração . . . . .	92
6.3	Variação do kappa obtido com a Recursive Feature Elimination (RFE) para a classificação entre duas e quatro classes . . . . .	94
6.4	Comparação entre o kappa obtido para os diferentes <i>feature sets</i> com um período de análise de 20 ms para a classificação entre duas classes . . . . .	95
6.5	Variação do kappa e do kappa médio segundo o período de análise para todos os <i>feature sets</i> com os datasets CWRU e optisigma . . . . .	96
6.6	Variação média do kappa obtido com todos os <i>feature sets</i> a cada aumento do período de análise em 10 ms para cada uma das frequências de amostragem utilizadas com o <i>dataset</i> optisigma . . . . .	96
6.7	Variação do kappa obtido consoante o período de análise e a frequência de amostragem para os <i>feature sets</i> 1 e 2 . . . . .	97
6.8	Variação do kappa obtido consoante o período de análise e a frequência de amostragem para os <i>feature sets</i> 3 e 4 . . . . .	98

---

6.9	Variação do kappa obtido consoante o período de análise e a frequência de amostragem para os feature sets 5 e 6 . . . . .	98
6.10	Variação do kappa obtido consoante o período de análise e a frequência de amostragem para os feature sets 7 e 8 . . . . .	99
6.11	Comparação do kappa obtido com os diferentes algoritmos nas classificações com todos os feature sets com um período de análise de 20 ms com os dados CWRU . . . . .	101
6.12	Comparação do kappa obtido com os diferentes algoritmos nas classificações com todos os <i>feature sets</i> excepto o FS 8, em todas as frequências de amostragem e com um período de análise entre 20 ms e 50 ms com os dados optisigma	104
6.13	Comparação entre o kappa obtido com o algoritmo RF para os diferentes feature sets com um período de análise de 20 ms para a classificação entre quatro classes . . . . .	105
6.14	Variação do kappa obtido com o algoritmo RF segundo o período de análise para todos os <i>feature sets</i> . . . . .	106
6.15	Comparação do kappa obtido com os 4 algoritmos nas classificações com os feature sets 7 e 8 e com um período de análise entre 20 ms e 100 ms com os dados CWRU . . . . .	108
6.16	Variação do kappa obtido segundo o número de picos de frequência avaliados na análise espectral da TPE para diferentes frequências de amostragem . . .	109
6.17	Variação do Kappa médio segundo o número de picos resultantes da análise espectral da TPE . . . . .	110
6.18	Esquema da constituição dos <i>feature sets</i> resultantes da análise das correntes	111
6.19	Variação do kappa obtido com a RFE . . . . .	112
6.20	Comparação entre o kappa médio obtido para os diferentes feature sets com um período de análise de 20 ms . . . . .	113
6.21	Variação do kappa médio de todos os <i>feature sets</i> segundo o período de análise	114
6.22	Variação média do kappa obtido com todos os <i>feature sets</i> a cada aumento do período de análise em 10 ms para cada uma das frequências de amostragem utilizadas com o <i>dataset</i> optisigma . . . . .	114
6.23	Variação do kappa obtido consoante o período de análise e a frequência de amostragem para os feature sets 1 e 2 . . . . .	115
6.24	Variação do kappa obtido consoante o período de análise e a frequência de amostragem para os feature sets 3 e 4 . . . . .	116
6.25	Variação do kappa obtido consoante o período de análise e a frequência de amostragem para os feature sets 5 e 6 . . . . .	116
6.26	Variação do kappa obtido consoante o período de análise e a frequência de amostragem para o feature set 7 . . . . .	117
6.27	Comparação do kappa médio para os features sets com maior poder preditivo com diferentes períodos de análise . . . . .	117

6.28	Comparação do kappa obtido com os 4 algoritmos nas classificações com os feature sets 3, 4, 5, 6 e 7 com um período de análise entre 20 ms e 60 ms com os dados optisigma . . . . .	120
7.1	Comparação entre a classificação através da análise das correntes elétricas e da vibração . . . . .	122
A.1	Comparação da média do kappa obtido para cada parametrização de cada algoritmo utilizado . . . . .	130



## LISTA DE TABELAS

1.1	Percentagens de consumo de energia dos MEs no setor industrial (por país) [3]	1
1.2	Incidência das avarias nos MITs [7]	4
2.1	Valores típicos de rendimento para MITGEs [11]	20
3.1	Matriz de confusão da classificação binária	28
3.2	Matriz de confusão da classificação multi-classe	29
4.1	Frequências características das vibrações causadas nos rolamentos, segundo o tipo de defeito	36
5.1	Estrutura final do conjunto de dados da Optisigma	49
5.2	Nº de períodos de 20 ms (ciclos) para cada diâmetro de avaria do rolamento, carga do motor e frequência de amostragem da recolha de dados da Optisigma	50
5.3	Nº de períodos de 20 ms (ciclos) e equilíbrio entre classes consoante o estado do motor e frequência de amostragem para os dados Optisigma	50
5.4	Estrutura do conjunto de dados da CWRU	51
5.5	Nº de períodos de 20 ms para cada diâmetro de avaria do rolamento e carga do motor da recolha de dados da CWRU	52
5.6	Nº de períodos de 20 ms com um rolamento saudável para cada carga do motor da recolha de dados da CWRU	52
5.7	Nº de períodos de 20 ms e equilíbrio entre classes consoante o estado do motor para os dados CWRU	52
5.8	Nº de períodos de 20 ms e equilíbrio entre classes consoante o estado do motor para os dados CWRU	53
5.9	Análise estatística (média do módulo e desvio padrão) dos registos de vibração do <i>dataset</i> CWRU	61
5.10	Intervalos de frequência avaliados por cada frequência de amostragem segundo o teorema de Nyquist	68
6.1	Variação do kappa segundo o número de picos resultantes da análise espectral da vibração para a classificação entre duas e quatro classes	91
6.2	Kappa obtido com os <i>feature sets</i> 3, 5, 6, 7 e 8 e um período de análise de 20 ms	100

---

6.3	Matriz de confusão da melhor classificação obtida para um período de análise de 20 ms com o <i>dataset</i> CWRU . . . . .	101
6.4	Melhores resultados obtidos com uma frequência de amostragem de 0.8 kHz e diferentes períodos de análise . . . . .	101
6.5	Melhores resultados obtidos com uma frequência de amostragem de 1 kHz e diferentes períodos de análise . . . . .	102
6.6	Melhores resultados obtidos com uma frequência de amostragem de 2 kHz e diferentes períodos de análise . . . . .	102
6.7	Melhores resultados obtidos com uma frequência de amostragem de 5 kHz e diferentes períodos de análise . . . . .	103
6.8	Melhores resultados obtidos com uma frequência de amostragem de 10 kHz e diferentes períodos de análise . . . . .	103
6.9	Período de análise mínimo (ms) por frequência de amostragem (kHz) para atingir uma classificação perfeita para cada <i>feature set</i> . . . . .	103
6.10	Melhores resultados obtidos para cada período de análise e respectivo <i>feature set</i> com Random Forest . . . . .	106
6.11	Melhores resultados obtidos para cada período de análise e respectivo <i>feature set</i> (excluindo resultados obtidos com o <i>feature set</i> 8) com Random Forest . . . . .	107
6.12	Melhores resultados obtidos para cada período de análise e respectivo <i>feature set</i> com todos os algoritmos . . . . .	107
6.13	Matriz de confusão da classificação obtida com o <i>feature set</i> 7 e um período de análise de 70 ms com o algoritmo XGBOOST . . . . .	107
6.14	Variação do Kappa médio segundo o número de picos resultantes da análise espectral da TPE . . . . .	110
6.15	Melhores resultados obtidos com os feature sets com maior poder preditivo para cada frequência de amostragem e período de análise de 20 ms . . . . .	118
6.16	Melhores resultados obtidos com os feature sets com maior poder preditivo para cada frequência de amostragem e período de análise de 40 ms . . . . .	119
6.17	Período de análise mínimo (ms) para atingir uma classificação perfeita para cada <i>feature set</i> por frequência de amostragem (kHz) . . . . .	120
A.1	Média do kappa obtido para cada parametrização de cada algoritmo utilizado	130
A.2	Resultados completos da comparação de desempenhos de diferentes parametrizações dos algoritmos utilizados . . . . .	130
B.1	Resultados obtidos segundo a variação do número de picos de frequência analisados no espectro da TPE e da frequência de amostragem . . . . .	135
C.1	Resultados RFE da análise da vibração (2 Classes) . . . . .	137
C.2	Resultados RFE da análise da vibração (4 Classes) . . . . .	138
C.3	Resultados RFE da análise das correntes elétricas . . . . .	140

---

D.1	Melhor resultado obtido com um período de análise de 20 ms ( <i>feature set 8</i> com algoritmo XGBOOST) . . . . .	141
D.2	Melhor resultado obtido com um período de análise de 30 ms ( <i>feature set 8</i> com algoritmo XGBOOST) . . . . .	141
D.3	Melhor resultado obtido com um período de análise de 40 ms ( <i>feature set 8</i> com algoritmo XGBOOST) . . . . .	142
D.4	Melhor resultado obtido com um período de análise de 50 ms ( <i>feature set 8</i> com algoritmo XGBOOST) . . . . .	142
D.5	Melhor resultado obtido com um período de análise de 60 ms ( <i>feature set 8</i> com algoritmo XGBOOST) . . . . .	142
D.6	Melhor resultado obtido com um período de análise de 80 ms ( <i>feature set 7</i> com algoritmo SVM e <i>feature set 8</i> com algoritmo RF) . . . . .	142
D.7	Melhor resultado obtido com um período de análise de 90 ms ( <i>feature set 8</i> com algoritmo RF) . . . . .	142
D.8	Melhor resultado obtido com um período de análise de 100 ms ( <i>feature set 8</i> com algoritmo RF) . . . . .	143



## SIGLAS

AA	Aprendizagem Automática.
ACP	Análise de Componentes Principais.
ANN	Artificial Neural Network.
CRISP-DM	Cross Industry Standard Process for Data Mining.
CWRU	Case Western Reserve University.
ME	Motor Elétrico.
MI	Motor de Indução.
MIT	Motor de Indução Trifásico.
MITGE	Motor de Indução Trifásico com Rotor em Gaiola de Esquilo.
RF	Random Forests.
RFE	Recursive Feature Elimination.
RMS	Root Mean Square.
ST	Sistema Trifásico.
SVM	Support Vector Machine.
TF	Transformada de Fourier.
TFD	Transformada de Fourier Discreta.
TH	Transformada de Hilbert.
TP	Transformada de Park.
TPE	Transformada de Park Estendida.
TRF	Transformada Rápida de Fourier.
TWC	Transformada de Wavelet Contínua.
XGBOOST	eXtreme Gradient Boosting.



## INTRODUÇÃO

Neste capítulo são apresentados o contexto e motivação do desenvolvimento da dissertação na secção 1.1, sendo posteriormente abordado o problema na secção 1.2 e as contribuições do documento na secção 1.3. A secção 1.4 apresenta a abordagem metodológica seguida na dissertação, a secção 1.5 as ferramentas utilizadas e a secção 1.6 a estrutura do documento.

### 1.1 Contexto e Motivação

Os **Motores Eléctricos (MEs)** e sistemas que derivam dos mesmos, segundo a agência internacional de energia, representam mais de 50% do consumo de eletricidade global [1], correspondendo a um consumo anual de cerca de 10700 TWh, sendo previsto que este atinja 13360 TWh em 2030 [2]. A nível industrial, o consumo de energia eléctrica dos **MEs** corresponde a cerca de 2/3 do consumo do sector [2], sendo que países industrializados normalmente apresentam percentagens de consumo superiores, como é possível observar na Tabela 1.1 que mostra as percentagens de consumo de energia dentro do setor, por país.

Tabela 1.1: Percentagens de consumo de energia dos **MEs** no setor industrial (por país) [3]

País	Eletricidade gasta por <b>MEs</b> (%)
Canadá	80
Estados Unidos	75
União Europeia	65
China	60
Reino Unido	50

Dentro dos diversos tipos de **MEs**, o mercado apresenta os **Motores de Indução (MIs)** como os mais bem sucedidos quando comparados com outras tecnologias de motores [4].

Grande parte deste sucesso deve-se ao seu relativo baixo custo (custo mais baixo por kW), simplicidade de construção, alta fiabilidade e robustez, e eficiência média-alta para motores pequenos (cerca de 70%) e alta para grandes motores (acima de 95%), dependendo do *design* do motor [4]. Devido a estes fatores, os **Motores de Indução Trifásicos com Rotor em Gaiola de Esquilo (MITGEs)**, fechados (blindados) e auto-ventilados dominam o atual mercado de **MEs** industriais (com potência nominal igual ou superior a 0,75 kW), representando mais de 90% dos motores vendidos e 85-90% dos motores instalados na indústria [5].

Na indústria, ao longo do seu tempo de vida de 12 a 20 anos, os **MI**s são reparados tipicamente 2 a 4 vezes e consomem uma energia que pode representar 60 a 200 vezes o seu custo inicial (dependendo esta relação, em grande parte, do seu rendimento médio ao longo do ciclo de funcionamento) [5], sendo que o seu custo do ciclo de vida engloba também outros factores. Normalmente, esse custo é definido pela soma do custo inicial ou de compra (incluindo instalação e comissionamento) com o custo de exploração/utilização (custo da energia ativa e, eventualmente, reativa), o custo da manutenção (supervisão, lubrificação, substituição de rolamentos, rebobinagem, manutenção preditiva, etc.), e custo de abate ou de desativação do motor [5], como é possível observar na Figura 1.1.

O custo do ciclo de vida, de uma forma mais completa, pode ainda incluir os custos envolvidos numa paragem inesperada ou programada do processo, que levam a perdas de produção e eventual inatividade da mão-de-obra remunerada [5].



Figura 1.1: Componentes do custo do ciclo de vida dos **MEs** [5]

Na maioria dos casos, em contexto industrial, cerca de 90% do custo do ciclo de vida dos **MI**s é atribuído ao seu custo de exploração, sendo o seu rendimento e fiabilidade fatores determinantes neste custo. Ambos fatores podem ser maximizados através de práticas corretas de seleção, controlo e manutenção, sendo que a manutenção pode ser efetuada seguindo diferentes abordagens [6]:

- **Manutenção curativa (ou corretiva):** Este tipo de manutenção pressupõe uma atuação após a avaria ou impossibilidade de operação do motor, obrigando à sua paragem e reparação. A manutenção curativa engloba ainda o próprio processo de reparação que, a menos que se substitua o motor, se aplica em conjunção com todos os outros tipos de manutenção. À manutenção curativa poderá ainda estar associada uma manutenção indexada de substituição de peças, por forma a evitar o tempo e custo associados a uma nova paragem, desmontagem, reparação e remontagem do motor a curto prazo;

- **Manutenção periódica de base:** Na manutenção periódica pode-se incluir a lubrificação e/ou substituição dos rolamentos, a limpeza da superfície externa da carcaça e, eventualmente, a verificação dos contactos elétricos, considerando-se esta a manutenção de base. A periodicidade ou frequência deste tipo de manutenção e/ou inspeção deve depender do tipo e importância do motor na instalação industrial, bem como das suas condições de funcionamento, particularmente no que respeita ao ambiente envolvente (nível da humidade, poeiras, temperatura, etc.).
- **Manutenção periódica de substituição (ou preventiva sistemática):** A manutenção periódica de substituição pressupõe a substituição de peças periodicamente (em função do tempo de funcionamento ou de outro parâmetro relacionado com o desgaste/degradação do motor), independentemente do seu estado de degradação real. Tem, normalmente, por base uma análise estatística do tempo de vida dos diversos componentes a substituir.
- **Manutenção preditiva (ou preventiva condicionada):** Este tipo de manutenção é baseada num plano que possa fornecer atempadamente sinais de alarme acerca do estado de funcionamento do motor, minimizando dessa forma a probabilidade da ocorrência súbita e intempestiva de uma avaria catastrófica que implique a paragem imediata ou não programada do motor. Estas técnicas deverão ser, preferencialmente, fáceis de aplicar e com o motor em serviço, não perturbando dessa forma o seu funcionamento normal.

O tipo de manutenção varia consoante o tipo do motor. Por norma, quanto maior a potência, o valor, a importância e os prejuízos associados a uma avaria inesperada do motor, melhor deverá ser o plano de manutenção, como ilustrado no gráfico da Figura 1.2.

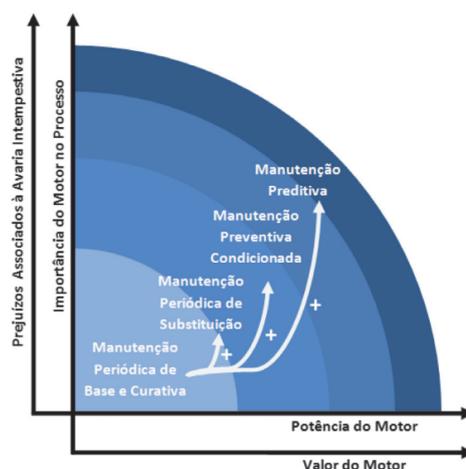


Figura 1.2: Aplicação dos vários tipos de manutenção de motores em função da potência e valor do motor [6]

Um plano de manutenção adequado de um ME consiste habitualmente na conjugação de uma componente de manutenção periódica com uma componente de manutenção

preditiva [6]. A componente de manutenção preditiva mostra-se especialmente relevante pois estima-se que uma paragem não programada possa custar dez vezes mais que uma paragem programada devido ao surgimento de custos significativos associados à paragem não programada dos sistemas por ele acionados (tais como a perdas de produção, mão-de-obra remunerada inativa, incapacidade de entrega de encomendas e eventual perda de clientes, etc.) [6]. Esta componente deve ser enquadrada em todos os motores que desempenham funções críticas na instalação industrial (independentemente das características do motor tais como potência nominal ou nível de tensão de alimentação), em motores cujo custo de inspeção/reparação é elevado (independentemente da função que o motor desempenha), assim como em motores acoplados a cargas pulsantes ou de forte impacto e em todos os motores alimentados em média tensão que desempenhem funções de alguma importância na instalação industrial [6].

De uma perspectiva técnico-económica, o investimento no melhoramento do rendimento e fiabilidade dos **MEs** é, em geral, muito atrativo para a grande maioria das indústrias [6], sendo a qualidade da manutenção fator chave no rendimento de um motor. Neste contexto, decorre na Altran Portugal o desenvolvimento do projecto REARM II (pRedictivE mAintenance of electRic Motors II), que vem no seguimento do projeto REARM e onde o principal objetivo é comum e consiste em desenvolver uma plataforma de manutenção preditiva para **MEs**, de onde se pretende obter uma avaliação do estado do motor e fazer a deteção de avarias ainda num estado inicial, sendo a principal diferença entre os dois projetos o tipo de avaria a ser detetada. Este projeto da Altran Portugal decorre em parceria com a Optisigma, entidade esta que detém um dispositivo onde, através de múltiplos sensores, é feita a recolha de diversos dados de um **ME** e respetivo envio via Wi-Fi.

## 1.2 Problema

Diversos estudos demonstram que a avaria com maior incidência nos **Motores de Indução Trifásicos (MITs)** é a avaria a nível dos rolamentos (representando cerca de 50% das falhas registadas), existindo também uma grande incidência de avarias a nível do estator, como é possível observar na Tabela 1.2. No rotor incidem cerca de 10% das avarias, sendo que as restantes falhas ocorrem em variados outros componentes.

Tabela 1.2: Incidência das avarias nos **MITs** [7]

Ano	Rolamentos (%)	Estator (%)	Rotor (%)	Outros (%)
2010	51	16	7	26
1995	51	16	7	26
1992	41	37	10	12
1986	41	36	9	14

É também conhecido que, do ponto de vista económico, para a grande maioria dos motores a reparação do mesmo compensa largamente em relação à sua substituição por

um novo motor, como é possível observar na Figura 1.3. Quanto maior a potência (kW) do motor, maior a vantagem económica.

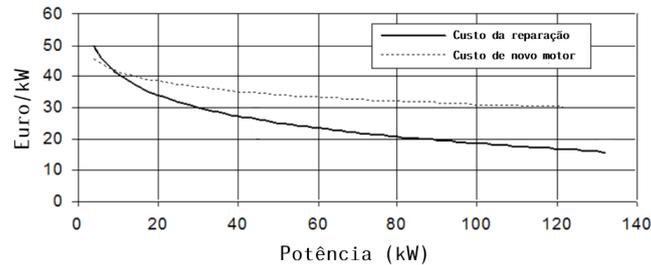


Figura 1.3: Comparação entre o custo de reparação e o custo de um novo motor [8]

A maior parte das avarias dos MITs desenvolvem-se de forma gradual, evoluindo de um defeito inicial a um defeito real (dependendo o tempo de propagação da falha de diversos fatores) [9]. Se as avarias forem detetadas de forma atempada, ou seja, ainda no seu estágio inicial de desenvolvimento, os custos das reparações tendem a ser mais baixos. Isto verifica-se não só por se poder planear atempadamente a reparação, como também pelo facto de nesses casos, a avaria tender a ficar confinada à sua localização inicial, não alastrando para outras zonas do motor [5].

A maior parte destas avarias apresentam os mencionados sinais iniciais da sua presença, e é sobre esses sinais que a manutenção preditiva deve funcionar [9]. Seguindo esse princípio, foi previamente desenvolvida uma solução para deteção de avarias de curto-circuito entre espiras para MITs - que representam cerca de 30% das avarias registadas nestes tipos de motores - no âmbito do projecto REARM, da Altran Portugal. Pretende-se, com a realização desta tese de mestrado em ambiente empresarial (no âmbito do projeto REARM II da Altran Portugal), contribuir para o desenvolvimento de uma solução para a deteção de avarias nos rolamentos do mesmo tipo de motor. Como previamente mencionado, esta solução irá permitir a deteção de cerca de metade das avarias nestes motores, procurando a Altran Portugal o alargamento do escopo de deteção de 30% para cerca de 80% das avarias de um MIT.

O principal método de diagnóstico de avarias nos rolamentos baseia-se na análise vibracional do motor, sendo que a análise dos ultra-sons e das correntes também é utilizada apesar de tendencialmente menos eficaz, como é possível observar na Figura 1.4 onde, quanto maior o reconhecimento da eficácia do método de diagnóstico, maior o número de indicadores na respetiva célula. Neste sentido e considerando os dados recolhidos pelos sensores do dispositivo da optisigma, a solução obtida foca-se na análise e processamento da vibração e das correntes do motor.

O estudo da deteção da avaria através de duas grandezas físicas distintas mostra-se especialmente importante dados os diferentes desafios colocados na monitorização de cada uma: a vibração exige a colocação de um sensor em cada ME, sendo que as correntes elétricas de vários MEs podem ser monitorizadas a partir do mesmo local. O impacto da

Métodos de Diagnóstico	Vibração	Ultra-sons	Análise Espectral da Corrente	Vector de Park da Corrente	EPVA	Descargas Parciais	Termografia
Localização ou Origem da Avaria							
Rolamentos	•••	••	•		•		

Figura 1.4: Métodos de diagnóstico recomendados para avarias nos rolamentos de MIs [6]

frequência de amostragem de ambas as grandezas físicas também é alvo de estudo dado que, idealmente, quanto menor a frequência de amostragem necessária, maior o benefício a nível económico pois passa a ser necessário recolher uma quantidade inferior de dados e, para o fazer, é utilizado um sensor de menor custo. A variação do período de análise é estudada de forma a analisar o efeito que este tem na qualidade da classificação com as diferentes frequências de amostragem.

A abordagem proposta é promissora dada a demonstração, no estado da arte do Capítulo 4, das manifestações das avarias nos rolamentos em ambas as grandezas físicas a ser analisadas (correntes elétricas e vibração). Este tipo de deteção mostra-se especialmente desafiante devido às inúmeras fontes de vibração do motor (além de rolamentos defeituosos), podendo estas ter tanto origem mecânica como elétrica. Uma base do motor imprópria, um motor desequilibrado, curtos-circuitos entre espiras, defeitos noutros componentes e até mesmo um ambiente barulhento em torno do motor são algumas de outras causas comuns de vibração [10].

### 1.3 Contribuições

Esta dissertação contém diversas contribuições, passando principalmente por:

- Revisão de literatura sobre abordagens para deteção de avarias nos rolamentos envolvendo análise das vibrações e análise das correntes elétricas;
- Estudo e comparação da deteção de avaria nos rolamentos através de duas grandezas físicas distintas (correntes elétricas e vibração) com comparação de diferentes análises sobre cada grandeza física;
- Estudo do impacto da frequência de amostragem e do intervalo de tempo analisado na deteção de avarias nos rolamentos através de ambas as grandezas físicas;
- Proposta de uma abordagem de **Aprendizagem Automática (AA)** para a deteção de avarias nos rolamentos de **Motor de Indução Trifásicos** com base na análise da vibração e das correntes elétricas;

- Avaliação experimental e construção de modelos com dados gerados em laboratório, incluindo uma análise da robustez e possível generalização.

## 1.4 Abordagem Metodológica

### 1.4.1 Fases de Desenvolvimento

Ao longo do desenvolvimento desta dissertação existiram diversas fases de desenvolvimento, podendo estas ser enumeradas segundo:

1. Identificação do escopo do problema e motivação;
2. Leitura e estudo de bibliografia relevante, nomeadamente em relação a conceitos de [MITs](#), [AA](#) e estado da arte;
3. Enquadramento da dissertação com os objetivos do projeto REARM II da Altran Portugal, e consequente identificação do problema;
4. Definição dos objetivos da dissertação;
5. Avaliação da qualidade dos *datasets* enviados pela optisigma e pesquisa por *datasets online*;
6. Preparação dos dados, modelação e avaliação;
7. Escrita do documento e revisão do mesmo.

### 1.4.2 Critérios de Pesquisa e Referências Bibliográficas

A pesquisa de referências bibliográficas foi realizada com recurso a bases de dados como a biblioteca do conhecimento online (b-on) e o google académico (Google Scholar), tendo sido utilizadas combinações de palavras-chave como "induction motor", "fault detection", "bearing fault", e "bearing fault machine learning", não limitando à partida o escopo temporal da pesquisa. A seleção inicial foi feita com base no título, *abstract* e assuntos apresentados, sendo posteriormente feita uma segunda seleção após leitura do conteúdo.

Estes critérios de pesquisa resultaram num conjunto de referências cuja datas de publicação variam entre 1994 e 2018, onde a maioria tem datas de publicação relativamente recentes (publicadas ao longo dos últimos 10 anos), e onde cada secção das referências bibliográficas apresenta um escopo temporal característico, como se verifica na Figura 1.5. Isto verifica-se pois não existe a necessidade de procura de publicações recentes para algumas das áreas estudadas dados os fundamentos bem estabelecidos, como se verifica em relação às principais referências bibliográficas utilizadas na secção dos [MIs](#) (Capítulo 2), [11], [12] e [13], cujas datas de publicação variam entre 2001 e 2003. Confirma-se a mesma situação para uma minoria dos tópicos do estado da arte da deteção de avarias

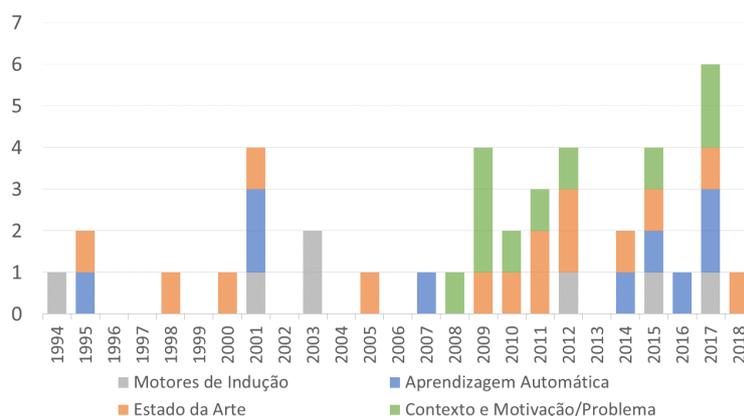


Figura 1.5: Escopo temporal das referências bibliográficas

nos rolamentos (Capítulo 4), especialmente os que não envolvem técnicas de AA, estando mais relacionados com técnicas de processamento de sinais.

O Capítulo 3, referente aos diversos conceitos de AA necessários para a resolução do problema da forma proposta, teve como principais referências [14] e [15], sendo que estas fazem parte da bibliografia utilizada na unidade curricular de AA do Mestrado Integrado em Engenharia Informática (da Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa). Referências, nesta secção, a publicações anteriores a 2002, são referentes às primeiras publicações de algoritmos de AA mencionados.

Em relação às referências bibliográficas utilizadas para o contexto e motivação/problema da dissertação (secções 1.1 e 1.2) houve um critério mais apertado em relação às datas de publicação, dada a importância das datas dos dados mencionados, resultando num conjunto de referências apenas presente na metade mais recente da Figura 1.5.

De toda esta pesquisa resultaram não só a bibliografia diretamente consequente da mesma, mas também referências retiradas de referências de documentos pesquisados.

Além da bibliografia resultante da pesquisa, uma referência bibliográfica fundamental desta dissertação foi fornecida pelos orientadores, tendo esta sido a tese de mestrado [7] sobre a deteção de avarias de curto-circuito entre espiras em MITs (realizada no âmbito do projeto REARM da Altran Portugal). Houve também fornecimento de referências por parte do professor Fernando Ferreira (Professor Auxiliar na Universidade de Coimbra), principalmente para a secção referente aos conceitos dos MIs e estado da arte, e pela equipa do projeto REARM II da Altran Portugal para o estado da arte. Foram aplicados os mesmos critérios de seleção mencionados anteriormente a todas as referências bibliográficas fornecidas.

### 1.4.3 Metodologia CRISP-DM

A abordagem a esta dissertação foi feita seguindo a metodologia **Cross Industry Standard Process for Data Mining (CRISP-DM)**, que traduzida significa **Processo Padrão Interprofissional para Prospeção de Dados**. Esta descreve as fases típicas de um projeto, as

tarefas envolvidas em cada fase e as relações existentes entre fases. Esta contém 6 fases chave, sendo elas o entendimento do negócio/investigação, a compreensão dos dados, a preparação dos dados, a modelação, a avaliação e o *deployment*, estando o seu ciclo de vida ilustrado na Figura 1.6.

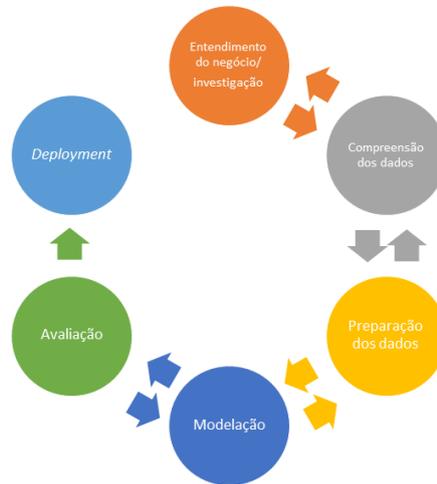


Figura 1.6: Diagrama do ciclo de vida da metodologia CRISP-DM

- **Entendimento do negócio/investigação:** Consiste em compreender os objetivos e requisitos do negócio/investigação, definindo um problema;
- **Compreensão dos dados:** Passa pela análise e familiarização com o conjunto de dados, avaliando a qualidade do mesmo.
- **Preparação dos dados:** Seleção das variáveis a ser utilizadas e, eventualmente, respetivo processamento necessário (preparando o conjunto de dados para a modelação).
- **Modelação:** Consiste em selecionar e usar diferentes algoritmos de **AA** para construir diversos modelos, onde um será posteriormente selecionado.
- **Avaliação:** Avaliação dos modelos construídos, determinando se os mesmos atingem os objetivos definidos na fase de entendimento do negócio/investigação;
- **Deployment:** Organização e apresentação (de diversas formas, dependendo do objetivo) do conhecimento adquirido pelo modelo.

## 1.5 Ferramentas Utilizadas

Considerando o ambiente empresarial em que esta dissertação foi desenvolvida, foi efetuada a escolha de prosseguir com o desenvolvimento da mesma com as ferramentas utilizadas na empresa e previamente utilizadas no projeto REARM. Neste sentido, a linguagem de programação R e o *package* caret (Classification And Regression Training)

foram ferramentas utilizadas no desenvolvimento do classificador, sendo que para análise e visualização dos resultados foram utilizados o *package* plotly. Para o tratamento dos dados foi utilizado o *package* dplyr e para documentação do trabalho realizado foi utilizado Rmarkdown.

O gitlab foi utilizado para controlo de versões, sendo que a parte pública (resultados) do trabalho desenvolvido se encontra disponível no repositório <https://gitlab.com/hdlr/imbfd-full-results>.

### 1.6 Estrutura do Documento

O documento apresenta a seguinte estrutura:

- Capítulo 2 (Noções Fundamentais de **MITs**): apresenta um resumo dos conceitos relacionados com **MITs** recomendados para a compreensão deste documento;
- Capítulo 3 (Conceitos de **AA**): apresenta um resumo dos conceitos relacionados com **AA** recomendados para a compreensão deste documento;
- Capítulo 4 (Estado da Arte): apresenta o estado da arte das técnicas atualmente utilizadas para resolver o problema identificado com base na análise da vibração e das correntes elétricas;
- Capítulo 5 (Compreensão e Preparação dos Dados): descreve as fases de compreensão e preparação dos dados segundo a metodologia **CRISP-DM**, apresentando os conjuntos de dados utilizados e descrevendo as análises feitas aos mesmos, assim como os processos utilizados.
- Capítulo 6 (Modelação e Avaliação): descreve a fase de modelação e avaliação da metodologia **CRISP-DM**, sendo que é apresentado o procedimento aplicado a nível de pré-processamento e divisão de dados, algoritmos de classificação e métricas de avaliação, assim como descritos os resultados obtidos a nível da deteção da avaria através da análise da vibração e através da análise da corrente.
- Capítulo 7 (Conclusão e Trabalho Futuro): apresenta a conclusão da dissertação, fazendo uma comparação entre os resultados obtidos com as diferentes grandezas físicas estudadas, assim como propostas de trabalho futuro.

Esta estrutura permite uma leitura iterativa do documento na medida em que o leitor é primeiramente contextualizado no problema, em seguida apresentado com conceitos necessários para a compreensão do estado da arte e do trabalho efetuado nesta dissertação, sendo posteriormente mostrados os resultados e, finalmente, a conclusão e propostas de trabalho futuro.

## NOÇÕES FUNDAMENTAIS DE MOTORES DE INDUÇÃO TRIFÁSICOS

Este capítulo apresenta um resumo das noções fundamentais de **MITs** necessárias para a compreensão deste documento. Primeiramente, na secção 2.1, o **MIT** e o seu funcionamento são brevemente resumidos, sendo posteriormente explicado, em detalhe, o **Sistema Trifásico (ST)** na secção 2.2, os principais componentes do motor na secção 2.3, o seu princípio de funcionamento na secção 2.4, as suas propriedades na secção 2.5 e as suas principais falhas e causas na secção 2.6.

### 2.1 Motores de Indução Trifásicos

O **ME** mais utilizado em termos globais é, sem dúvida, o **MIT** (também conhecido como motor assíncrono trifásico) [11]. O termo assíncrono utiliza-se pois a velocidade de rotação do rotor não é igual à velocidade de rotação do campo girante criado pelo estator, isto é, o movimento do rotor não é síncrono com o movimento do campo girante do estator, sendo o termo indução utilizado pois o movimento de rotação do rotor é o resultado do aparecimento de forças eletromotrizes induzidas no rotor [11].



Figura 2.1: Motor de Indução Trifásico com Rotor em Gaiola de Esquilo

A geração, transmissão e utilização de grande potência de energia elétrica de corrente alternada envolve um tipo de sistema ou circuito conhecido como sistema polifásico [12], pelo que este é utilizado nos MITs e conhecido como ST.

De entre os MITs, a extrema simplicidade e robustez de um MITGE (visível na Figura 2.1<sup>1</sup>) são excepcionais vantagens para este tipo de MIs [12]. Comparativamente ao motor de rotor bobinado e aos motores de corrente contínua, o facto de não ter anéis coletores nem escovas contribui igualmente para os tornar nos motores mais comuns na indústria [11].

## 2.2 Sistema Trifásico

Num sistema monofásico de corrente alternada existe uma fonte de tensão única, onde a sua diferença de potencial é descrita ao longo do tempo segundo

$$V(t) = V_{max} \sqrt{2} \cos \omega t \quad (2.1)$$

e cuja variação ao longo do tempo se encontra exemplificada abaixo, na Figura 2.2a.

Num sistema polifásico, cada fonte de tensão consiste num grupo de  $n$  tensões ( $n > 1$ ) com (idealmente) a mesma amplitude e com o mesmo ângulo entre fases. Por outras palavras, um sistema com  $n$ -fases distribui  $n$  fontes de tensão, tipicamente com a mesma amplitude, e com um ângulo entre fases de  $\frac{360^\circ}{n}$  [12].

Por princípio, no ST existem três fontes de tensão com a mesma amplitude e separadas por  $120^\circ$  (Figura 2.2b).

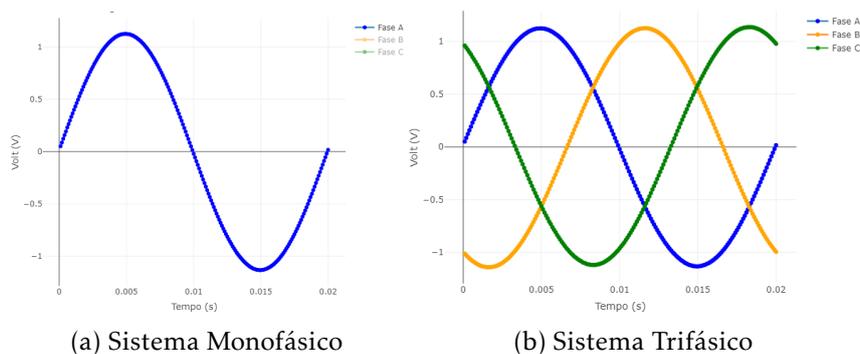


Figura 2.2: Representação no domínio temporal da tensão no sistema monofásico e ST

Estas três fases são tipicamente designadas de fase A, fase B e fase C, sendo respetivamente descritas segundo as funções 2.2, 2.3 e 2.4:

$$V_{an}(t) = V_{max} \sqrt{2} \cos \omega t \quad (2.2)$$

$$V_{bn}(t) = V_{max} \sqrt{2} \cos(\omega t - 120^\circ) \quad (2.3)$$

<sup>1</sup>Fonte: potencialetrica.com/motor-de-inducao-trifasico+235298

$$V_{cn}(t) = V_{max} \sqrt{2} \cos(\omega t - 240^\circ) \quad (2.4)$$

onde  $V_{xn}(t)$  representa a diferença de potencial entre a fase X e o neutro (ponto em que a tensão é nula [16]) no instante t.  $V_{max}$  representa a diferença de potencial máxima (ou magnitude), e  $\omega$  denota a velocidade angular - sendo esta igual a  $2\pi f$ , onde  $f$  é a frequência da fase.

A magnitude de cada fase é tipicamente medida com o **Root Mean Square (RMS)** [7] calculado, para um conjunto de  $N$  valores, segundo

$$X_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (2.5)$$

onde  $x_i$  representa o valor da onda na posição  $i$ .

Uma forma alternativa, e comum, de fazer a representação destas fases é através de fasores. Um fasor é um número complexo, representado como um vetor, que permite fazer a representação de uma função sinusoidal com amplitude  $A$  e fase inicial  $\phi$  num domínio intemporal, como é possível observar na Figura 2.3<sup>2</sup>.

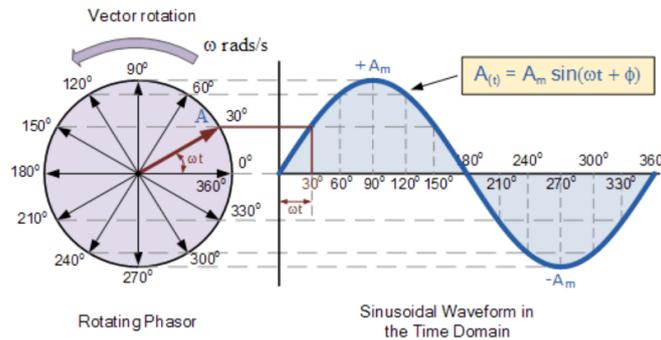


Figura 2.3: Representação de uma onda sinusoidal num fasor

Num ST, as fases A, B e C são então respetivamente representadas por

$$V_{an} = V_{max} \angle \phi \quad (2.6)$$

$$V_{bn} = V_{max} \angle \phi - 120^\circ \quad (2.7)$$

$$V_{cn} = V_{max} \angle \phi - 240^\circ \quad (2.8)$$

onde  $V^m \angle \phi$  representa um sinal sinusoidal com uma amplitude de  $V^m$  e a fase tem um ângulo inicial de  $\angle$ . Este cenário é ilustrado na Figura 2.4, onde se assume que  $V_{an}$  tem um ângulo de  $0^\circ$ , sendo que os vetores têm um ângulo de  $120^\circ$  entre eles e a denominação dos vetores é dada segundo a ordem com que passam pela fase inicial, dado que a rotação dos vetores é feita no sentido contrário ao do relógio.

<sup>2</sup>Fonte: electronics-tutorials.ws/accircuits/phasors.html

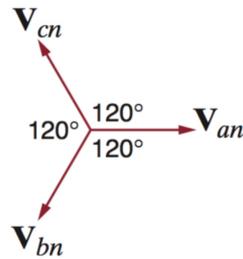


Figura 2.4: Representação de uma tensão trifásica equilibrada num fasor [7]

A diferença de potencial entre um dado ponto (a,b ou c) e o neutro é chamada de tensão simples [16], sendo que uma propriedade importante de um conjunto de *phasors* com tensões equilibradas é que a soma das fases em qualquer instante é 0 [7]:

$$V_{an} + V_{bn} + V_{cn} = 0 \quad (2.9)$$

Num sistema trifásico de tensões existe também a tensão entre duas fases, sendo esta uma tensão composta [16]. Num diagrama de fasores, esta pode ser vista como a diferença entre dois fasores que representam as fases, como ilustrado na Figura 2.5 [7].

As tensões compostas (entre fases) podem ser obtidas segundo:

$$V_{ab} = \sqrt{3}V_{max}\angle\phi+30^\circ \quad (2.10)$$

$$V_{bc} = \sqrt{3}V_{max}\angle\phi-120^\circ+30^\circ = \sqrt{3}V_{max}\angle\phi-90^\circ \quad (2.11)$$

$$V_{ca} = \sqrt{3}V_{max}\angle\phi-240^\circ+30^\circ = \sqrt{3}V_{max}\angle\phi-210^\circ \quad (2.12)$$

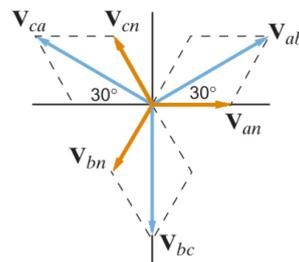


Figura 2.5: Representação de tensões compostas (entre fases) num fasor [7]

O ST apresenta diversas vantagens em relação ao sistema monofásico. Com um ST é possível obter um rácio potência/peso superior a nível de alternadores, dado que um alternador trifásico é mais pequeno e leve que um alternador monofásico com a mesma potência [7]. O ST requer também menos cobre/alumínio para transmitir a mesma quantidade de potência numa dada distância [7].

Como é possível observar nas Figuras 2.2<sup>3</sup>, as correntes alternadas apresentam um comportamento sinusoidal pelo que, no caso do sistema monofásico, a potência instantânea é sinusoidal e, por consequência, inconstante, resultando em vibrações de potência [7]. Num ST equilibrado a potência instantânea é sempre a mesma [7].

## 2.3 Principais componentes do MIT

Um MIT apresenta, de forma geral, uma construção como a ilustrada na Figura 2.6.

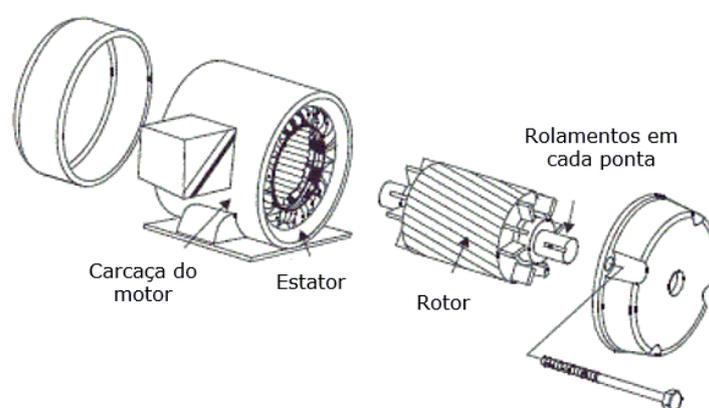


Figura 2.6: Principais componentes de um MITGE

Como é possível observar na Figura 2.6<sup>4</sup>, os principais componentes de um MI são o estator e o rotor, que são detalhadamente descritos nas secções 2.3.1 e 2.3.2, respetivamente. Tendo em conta o âmbito desta dissertação, é também feita uma descrição detalhada dos rolamentos na secção 2.3.3.

### 2.3.1 Estator

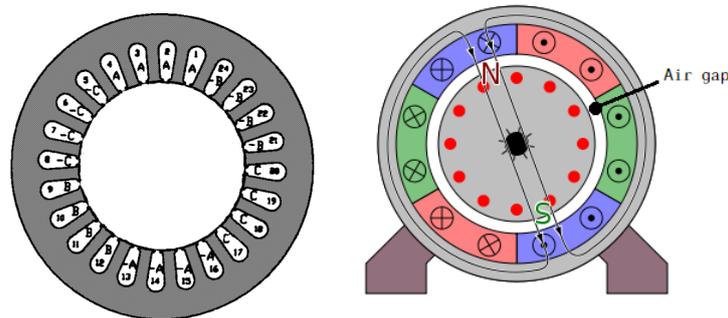
O estator é a parte estacionária do motor, sendo este constituído por um empacotamento de chapa de ferro magnético silicioso [16]. As chapas têm uma forma de coroa circular ranhurada (Figura 2.7a), sendo as ranhuras semi-fechadas com o objetivo de conter as espiras [16].

As espiras são colocadas no estator e ligadas de modo a formar enrolamentos trifásicos equilibrados [13] como é possível observar na Figura 2.7b<sup>5</sup> (em que cada cor representa uma das fases e cujo princípio de funcionamento é explicado no sub-capítulo 2.4). É possível arranjar os enrolamentos do estator de modo a obter motores de 2, 4, 6, 8, 10, 12 polos, etc., sendo que motores de mais de 12 polos não são normalmente utilizados [11].

<sup>3</sup>Fonte: [criticalpower.com/single-phase-vs-three-phase-generators-whats-the-difference/](https://criticalpower.com/single-phase-vs-three-phase-generators-whats-the-difference/)

<sup>4</sup>Fonte: [globalspec.com/RefArticleImages/5A7ADF06AC71D37FCF06D7AB0A3DDEDF\\_figure\\_36.gif](https://globalspec.com/RefArticleImages/5A7ADF06AC71D37FCF06D7AB0A3DDEDF_figure_36.gif)

<sup>5</sup>Fonte: [commons.wikimedia.org/wiki/File:Polpaar/\\_zahl/\\_1.svg](https://commons.wikimedia.org/wiki/File:Polpaar/_zahl/_1.svg)



(a) Chapa do estator [16] (b) Enrolamentos de um estator de um MIT de 2 polos

Figura 2.7: Constituição e enrolamentos do estator

A carcaça do motor fornece o suporte mecânico ao motor e, apesar de ser feita de um material magnético, não é projetada para transportar fluxo magnético [13].

No centro do estator encontra-se o rotor, estando estes separados por uma pequena *air gap* (visível na Figura 2.7).

### 2.3.2 Rotor

O rotor consiste na parte rotacional do motor e, para os MIs, existem dois principais tipos de rotor: o rotor em gaiola de esquilo e o rotor bobinado.

Para este documento, o interesse reside no rotor em gaiola de esquilo, visto ser o rotor presente nos MIs estudados, pelo que será o especificado.

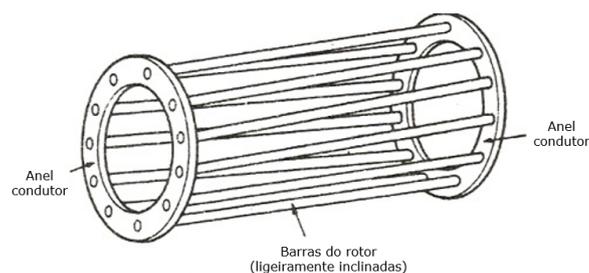


Figura 2.8: Rotor em Gaiola de Esquilo

Os enrolamentos do rotor em gaiola de esquilo (utiliza-se o termo gaiola de esquilo pois o rotor assemelha-se às gaiolas em que os esquilos brincam, quando em cativeiro [11]), para pequenos motores, são moldados recorrendo à utilização de um material condutor derretido (habitualmente, alumínio) [13], sendo que para grandes motores, consistem em barras condutoras (estas barras são geralmente de alumínio mas podem também ser de cobre ou outro condutor) dispostas ao longo do rotor e em todo o seu perímetro, curto-circuitadas nas extremidades por anéis condutores [11, 13].

É comum as barras estarem ligeiramente inclinadas, como é possível observar na Figura 2.8<sup>6</sup>, para reduzir o engrenamento e o ruído elétrico [13].

### 2.3.3 Rolamentos

Os rolamentos são responsáveis por fazer o contacto entre o estator e o rotor. A sua função é restringir o movimento relativo entre ambos os componentes, procurando minimizar a fricção existente.

Existem diversos tipos de rolamentos, sendo que os mais comuns são os rolamentos de esferas ilustrados na Figura 2.9a e os rolamentos de rolos cilíndricos presentes na Figura 2.9b. Ambos os tipos de rolamentos podem ser desconstruídos em quatro componentes distintos:

1. Anel interior (ou pista interior);
2. Anel exterior (ou pista exterior);
3. Elemento de rolamento (tipicamente esfera ou rolo cilíndrico);
4. Gaiola.

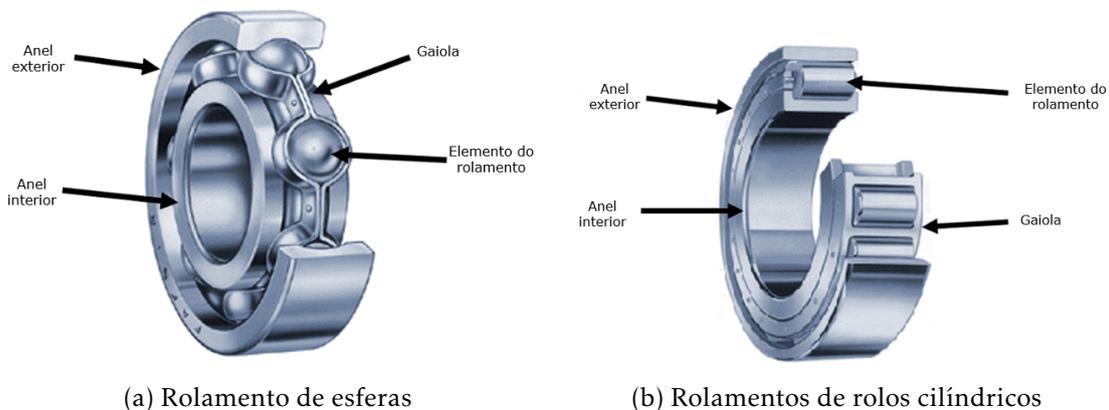


Figura 2.9: Esquema dos componentes de rolamentos de esferas e de rolos cilíndricos

Como é possível observar na Figura 2.9<sup>7</sup>, o elemento de rolamento fica compreendido entre o anel interior e exterior. O anel exterior permanece constantemente imóvel quando existe movimento relativo entre o estator e o rotor, sendo que o anel interior e o elemento de rolamento são móveis.

A gaiola pode estar, ou não, presente num rolamento, sendo que normalmente fazem parte da constituição de rolamentos de alta precisão. Esta tem como principais funções separar os elementos rolantes para reduzir o momento de atrito e o calor do atrito no rolamento, manter o espaço regular entre os elementos rolantes para otimizar a distribuição

<sup>6</sup>Fonte: [etrical.blogspot.pt/2016/05/rotor-conductors-induction-machine.html](http://etrical.blogspot.pt/2016/05/rotor-conductors-induction-machine.html)

<sup>7</sup>Fonte: [nptel.ac.in/courses/112103024/module3/lec1/1.html](http://nptel.ac.in/courses/112103024/module3/lec1/1.html)

de carga e permitir uma operação silenciosa e uniforme, e guiar os elementos rolantes na zona sem carga para melhorar as condições de rolagem e ajudar a evitar danos aos movimentos deslizantes.

## 2.4 Princípio de Funcionamento

Os MIs são motores que baseiam o seu princípio de funcionamento na criação de um campo magnético rotativo.

Dada a disposição dos enrolamentos do estator observada na secção 2.3.1, a ligação de a uma fonte de alimentação trifásica aos mesmos resulta na produção de um campo magnético rotativo (também conhecido como campo girante), como é possível observar na Figura 2.10. Este é constante em magnitude e gira ao longo do estator e à volta do rotor a uma velocidade constante, atravessando os condutores do rotor [11, 13].

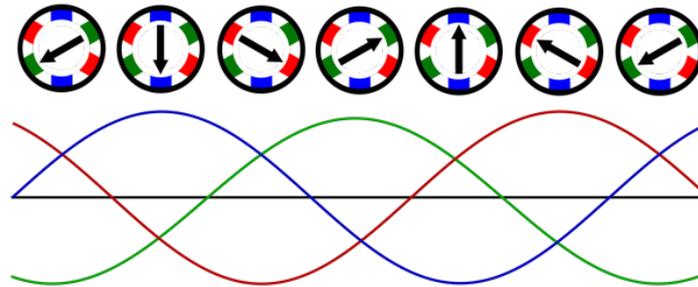


Figura 2.10: Rotação do campo magnético de 6 bobinas e 2 polos [7]

O facto de existirem componentes condutores no rotor, e a existência do campo girante à volta do mesmo previamente mencionada, faz com que sejam criadas alterações do fluxo magnético no rotor, sendo que estas alterações criam uma corrente no rotor de tal forma que é criado um campo magnético na direção oposta à alteração do fluxo magnético (Lei de Faraday-Lenz) [7]. Este campo magnético girante criado pelo rotor, ao tender a alinhar-se com o campo girante do estator, produz um movimento de rotação no rotor [11].

Este movimento de rotação do rotor baseia-se, portanto, na diferença de velocidade entre a velocidade de rotação do campo magnético produzido pelo estator e o rotor. Caso estas velocidades se iguallassem, deixaria de existir força eletromotriz induzida no rotor e, na ausência dessa força, o rotor tenderia a diminuir a sua velocidade, fazendo com que o processo de indução recomeçasse [13].

## 2.5 Propriedades

### 2.5.1 Velocidade de Sincronismo

A velocidade de rotação do campo girante é constante e é denominada velocidade de sincronismo [11]. Se o rotor girasse síncrono com o campo, a sua velocidade seria:

$$n = \frac{120f}{p} (rpm) \quad (2.13)$$

em que  $f$  é a frequência da tensão de alimentação e  $p$  é o número de polos magnéticos do motor.

Como mencionado em 2.3.1, o número de polos magnéticos é sempre dado em número par, e é possível observar pela fórmula dada em 2.13 que quanto maior for o número de polos magnéticos, menor será a frequência do campo girante.

### 2.5.2 Deslizamento

Num **MI**, a velocidade de rotação do rotor é diferente da velocidade de sincronismo. Isto deve-se ao facto de que tem de existir uma diferença de velocidades entre o rotor e o campo girante do estator para criar uma força eletromotriz induzida no rotor. Se o rotor girar à mesma velocidade do campo girante, deixaria de existir movimento relativo, deixando de existir correntes induzidas no rotor, o que implicaria a não existência de força (binário) induzida no rotor [11].

A esta diferença de velocidades dá-se o nome de deslizamento ( $s$ ) (ou escorregamento) e pode ser calculado por:

$$s = \frac{n_s - n}{n_s} \cdot 100 \quad (2.14)$$

em que  $n_s$  é a velocidade de sincronismo e  $n$  é a velocidade de rotação do rotor.

Num **MITGE**, é habitual o deslizamento registar valores baixos (na ordem dos 2 a 10 por cento em plena carga) [12].

### 2.5.3 Rendimento

O rendimento do motor está intimamente relacionado com o deslizamento pois quanto maior o deslizamento, maiores as perdas, sendo consequentemente menor o rendimento do motor [11]. O deslizamento em plena carga dá uma ideia do rendimento do motor, sendo esse rendimento dado pela expressão:

$$(\eta \leq 100\% - s) \quad (2.15)$$

onde  $s$  é o deslizamento.

Valores típicos de rendimento para um **MITGE** são os registados na Tabela 2.1, onde é possível observar que o rendimento de um motor aumenta com a sua potência (o deslizamento diminui com o aumento da potência), e que se registam níveis de rendimento de mais de 98% para motores de grandes potências.

Obviamente que quanto mais a velocidade de rotação se aproximar da velocidade de sincronismo, melhor será o rendimento do motor (menor é o deslizamento) [11].

Tabela 2.1: Valores típicos de rendimento para MITGEs [11]

Potência do motor	Rendimento
0.75 kW	80%
100 kW	95%
>100 kW (grandes potências)	98%

#### 2.5.4 Binário

O binário do motor à plena carga pode ser obtido dada a potência e a velocidade à plena carga. Este é dado pela expressão:

$$T = \frac{P}{n} \cdot 9550 \quad (2.16)$$

em que a unidade do binário  $T$  é o Newton.Metro ( $N.m$ ), a unidade da potência  $P$  é o kilowatt ( $kW$ ) e a unidade da velocidade de rotação  $n$  é rotações por minuto ( $rpm$ ).

Quando o motor está em plena carga, o binário desenvolvido pelo motor será igual ao binário necessário para manter a carga a rodar àquela velocidade [11]. Durante o arranque, contudo, o binário desenvolvido pelo motor terá de ser superior ao imposto pela carga, caso contrário o motor não acelera [11].

#### 2.5.5 Carga

A carga é, basicamente, um indicador da resistência colocada ao movimento de rotação do rotor comparada com a sua potência, sendo dada pela expressão

$$C = \frac{P_v}{P_n} \quad (2.17)$$

onde  $P_v$  representa a potência desenvolvida no veio e  $P_n$  a potência nominal.

Na indústria, os motores podem ter um nível de carga que varia entre 10% e 100% sendo que, na união europeia, o fator de carga médio é de 60%.

## 2.6 Principais Falhas e Causas

As falhas mais comuns nos MITs incidem sobre os rolamentos, estator e rotor, sendo que estas podem ter diversas causas. Muitas destas falhas derivam de especificações incorretas, no sentido em que a especificação de um motor deve considerar as suas condições mecânicas e elétricas, assim como o ambiente em que a máquina se encontra [9].

Em termos das condições mecânicas, as falhas resultam maioritariamente do comportamento da carga, estando os principais problemas relacionados com [9]:

- **Sobrecargas sucessivas:** que podem causar sobreaquecimento e/ou danos nos rolamentos;
- **Cargas pulsantes:** podem causar danos nos rolamentos;

- **Deslocações repetidas da máquina:** podem causar danos nos rolamentos;
- **Vibração transmitida para a máquina:** pode causar danos nos rolamentos.

A nível de danos provocados nos rolamentos, a severidade destes pode causar a existência de uma excentricidade dinâmica na *air gap*. Uma excentricidade dinâmica na *air gap* significa que a distância da *air gap* entre o rotor e o estator não é uniforme, sendo que existem dois tipos de excentricidades da *air gap*: estática e dinâmica. A primeira verifica-se quando o centro do rotor está estático, ou seja, o centro do rotor mantém-se no mesmo sítio, mas a largura da *air gap* não é uniforme devido ao seu mau posicionamento (Figura 2.11b). No caso de uma dinâmica, a posição do centro do rotor vai variando (Figura 2.11c) [17]. O posicionamento normal seria o observado na Figura 2.11a, onde a largura da *air gap* se mantém uniforme.

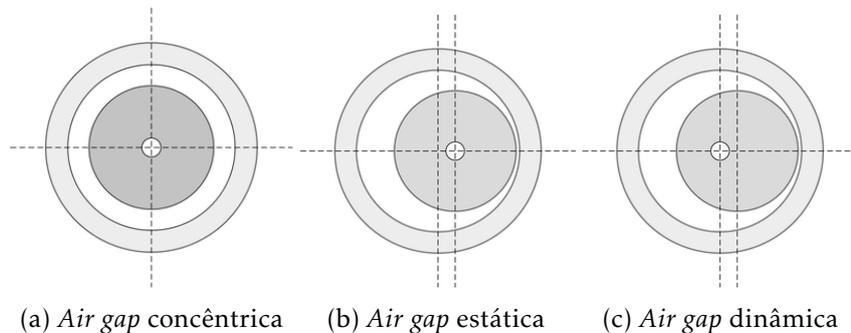


Figura 2.11: Tipos de excentricidades da *air gap* entre o estator e o rotor [17]

Em termos das condições elétricas, as falhas podem resultar de variações no nível de tensão de alimentação. Dentro dos principais problemas distinguem-se [9]:

- **Variações lentas na tensão:** que podem causar perda do poder de paragem e da máquina.
- **Variações bruscas na tensão:** podem causar a falha no isolamento.

Em termos das condições do ambiente, as falhas resultam principalmente de [9]:

- **Temperaturas altas:** que podem provocar a deterioração do isolamento.
- **Humidade:** pode causar imperfeições no isolamento;
- **Poluição:** pode levar à contaminação do isolamento.



## CONCEITOS DE APRENDIZAGEM AUTOMÁTICA

Este capítulo apresenta um resumo dos conceitos necessários à compreensão deste documento a nível de **AA**, sendo inicialmente descrita a aprendizagem supervisionada na secção 3.1, o conceito de *overfitting* e divisão de dados na secção 3.2, a amostragem estratificada na secção 3.3, técnicas de normalização de dados e a sua importância na secção 3.4, métodos de reamostragem na secção 3.5, as métricas de avaliação relevantes para o problema na secção 3.6, técnicas de *ensemble* na secção 3.7, e os algoritmos de classificação utilizados na dissertação na secção 3.8.

### 3.1 Aprendizagem Supervisionada

A aprendizagem supervisionada baseia-se na existência de um conjunto de dados (*dataset*) de *input* com respetivos *outputs* corretos (conjunto este denominado de dados de treino), para a criação de um modelo adaptado aos mesmos. O desafio prende-se em garantir que esta adaptação do modelo é a que mais corretamente generaliza *outputs* quando apresentado com novos e diferentes dados de *input* (não presentes nos dados de treino).

Com esta generalização pretende-se obter, conseqüentemente, a capacidade de lidar com a possível presença de ruído em futuros *inputs*, sendo a sua presença inerente a qualquer medida efetuada num processo do mundo real [15].

Mais concretamente, considerando um *dataset* como

$$\{(\vec{x}_1, y_1), \dots, (\vec{x}_n, y_n)\} \in \{X, Y\} \quad (3.1)$$

onde  $n$  representa o número de instâncias no *dataset*,  $\{\vec{x}_1, \dots, \vec{x}_n\}$  são observações (em formato vetorial) com um número arbitrário de valores pertencentes ao espaço de *input*  $X$  e  $\{y_1, \dots, y_n\}$  são observações pertencentes ao espaço objetivo  $Y$ . O objetivo consiste em aprender um conjunto de parâmetros  $w$  para inferir correctamente um valor de  $y \in Y$

para uma instância não antes vista de  $\vec{x} \in X$ , tal que  $y = f(\vec{x}, w)$  [7]. O processo de aprender tais parâmetros depende da natureza do espaço  $Y$ , onde o tipo de problema pode ser segmentado entre classificação e regressão que são apresentadas nas secções 3.1.1 e 3.1.2.

### 3.1.1 Classificação

No caso de o objetivo passar pela classificação de um dado *input*, o  $Y$  consiste num conjunto de classes finito ( $\geq 2$ ), pelo que o desafio é encontrar a função que melhor cria uma, ou mais, fronteiras entre valores de diferentes classes (como está ilustrado na Figura 3.1<sup>1</sup>, de forma a futuramente determinar a classe de uma observação nunca antes vista.

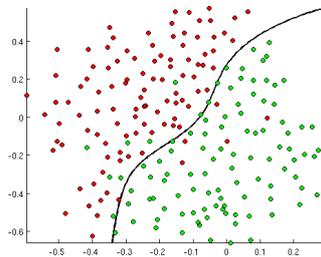


Figura 3.1: Exemplo de definição de uma fronteira de classificação entre duas classes

### 3.1.2 Regressão

No caso da regressão, o  $Y$  passa a consistir num intervalo de valores contínuo, pretendendo-se encontrar a função que melhor mapeia o comportamento destas variáveis. O objetivo é que, recorrendo a essa função, seja possível prever um  $Y$  a partir de  $X$ .

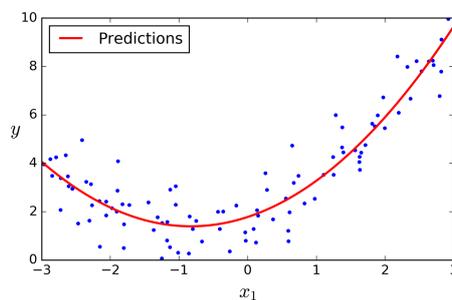


Figura 3.2: Exemplo de um modelo de regressão

Ou seja, o desafio da regressão passa por definir a função mais adequada para o conjunto de dados, como é possível observar na Figura 3.2<sup>2</sup>.

<sup>1</sup>Fonte: [wp.wvu.edu/blogwolf/2017/01/23/rosenblatts-perceptron/](http://wp.wvu.edu/blogwolf/2017/01/23/rosenblatts-perceptron/)

<sup>2</sup>Fonte: [faheart.com/1789031/fitting-degree-function-polynomialfeatures-linearregression](http://faheart.com/1789031/fitting-degree-function-polynomialfeatures-linearregression)

### 3.2 *Overfitting* e Divisão dos Dados

De forma a fazer a seleção do modelo que melhor se ajusta a um problema tem de ser feita uma avaliação, sendo que esta é realizada medindo o seu erro relativo a um conjunto de dados.

O problema surge quando a medição do erro do modelo, e consequente avaliação do seu desempenho, é feita recorrendo ao mesmo conjunto de dados utilizado para o treinar, resultando (no caso de se procurar obter o menor erro) no *overfitting* do modelo. Um modelo *overfitted* resulta num enfraquecimento da generalização pretendida, pois ao descrever o conjunto de dados utilizados para o treinar de forma tão precisa, a probabilidade de errar ao receber novos dados é superior (ou seja, o erro medido na avaliação do modelo recorrendo a novos dados será superior).

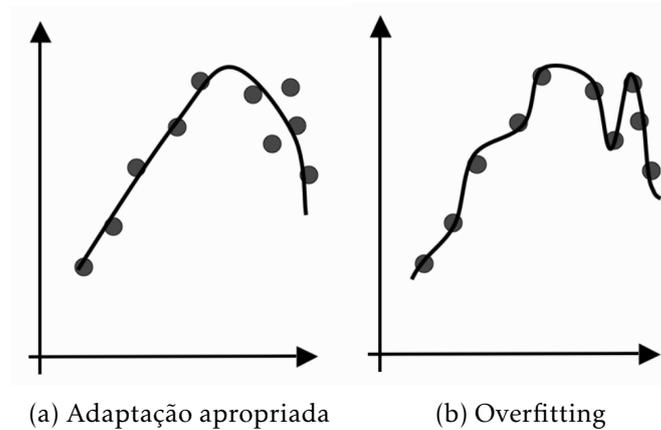


Figura 3.3: Exemplo de *overfitting* e de uma adaptação apropriada aos dados [15]

Pode-se então considerar fazer a divisão do *dataset* original em dois *datasets* diferentes, um conjunto de treino dedicado a ser usado apenas no treino do modelo e um conjunto de teste para ser usado na sua avaliação, e avaliar o modelo segundo a medição de erro do conjunto de teste. Isto, no entanto, não é a melhor escolha pois fará com que o modelo fique ajustado ao conjunto de teste pelo que surge a necessidade de uma terceira partição. Portanto, de forma a não adaptar demasiado um modelo a um *dataset* específico, o *dataset* inicial deve ser dividido em 3 sets distintos procurando tornar o modelo imparcial e prevenindo o *overfitting* ao fazer a avaliação fora do conjunto de treino. Um *dataset* é tipicamente dividido em:

- **Conjunto de treino:** para treino do algoritmo;
- **Conjunto de validação:** para avaliar o desempenho do modelo;
- **Conjunto de teste:** para produzir os resultados finais.

Surge então a necessidade de definir as quantidades de dados que cada set deve receber para se obterem os melhores resultados. Obviamente, pretende-se que o treino do

modelo seja feito com uma grande quantidade de dados pois quanto maior for a quantidade de dados vista pelo modelo na fase de treino, mais provável é que um possível *input* já tenha sido visto [15]. No entanto, pode ser usado o mesmo argumento em relação ao conjunto de validação e conjunto de teste na medida em que também é muito importante avaliar o desempenho do modelo com uma boa quantidade de dados. A divisão do *dataset* é, portanto, arbitrária, sendo uma proporção típica da divisão de dados entre conjunto de treino, conjunto de validação e conjunto de teste a de 50:25:25 (respectivamente) ou, para os casos em que a quantidade de dados é mais baixa, de 60:20:20 [15].

Em casos em que a quantidade de dados é muito limitada, na medida em que não é viável fazer a divisão do *dataset* inicial entre três sets distintos, é comum que seja feita uma divisão apenas entre conjunto de treino e conjunto de teste, onde cerca de dois terços dos dados são dedicados ao primeiro, sendo o restante terço dedicado ao conjunto de teste [7]. Posteriormente, e recorrendo a técnicas de reamostragem apresentadas em 3.5, a validação de o modelo poderá ser feita de forma diferente.

### 3.3 Amostragem Estratificada

A amostragem estratificada é uma técnica de amostragem de uma população habitualmente utilizada em estatística. A ideia consiste em dividir a população em sub-grupos dependendo das suas características (cada elemento da população apenas pode pertencer a um sub-grupo), sendo que as amostras da população contêm a mesma proporção de cada um dos sub-grupos.

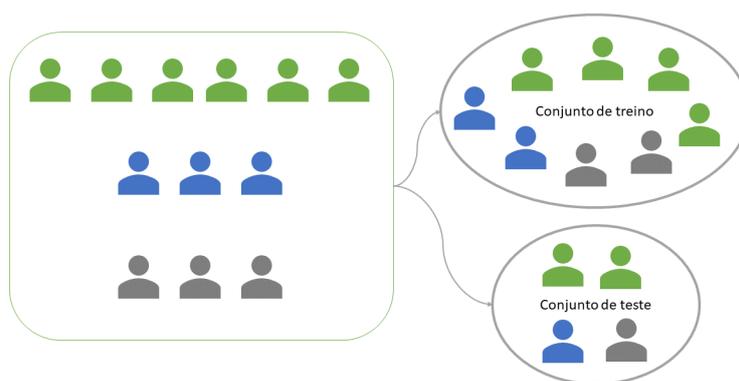


Figura 3.4: Exemplo de amostragem estratificada entre conjunto de treino e conjunto de teste

A Figura 3.4 ilustra o uso desta técnica em AA, sendo exemplificada a divisão do *dataset* original entre conjunto de treino e conjunto de teste com uma proporção de aproximadamente 70:30 e onde se observa a presença de elementos com diferentes características na mesma proporção em ambos os conjuntos. Esta é principalmente importante para situações em que existem diversos grupos com diferentes características pois garante que o modelo observa todos estes na sua fase de teste e de treino.

### 3.4 Normalização de Dados

Considerando o intervalo de valores que pode existir nos dados utilizados como *input*, é importante que exista uma normalização dos mesmos de forma a assegurar o melhor desempenho dos algoritmos, procurando garantir que todos os diferentes dados presentes numa dada observação contribuam aproximadamente da mesma forma.

Um exemplo de um problema causado por não existir normalização dos dados passa por algoritmos que calculam a distância entre dois pontos utilizando a distância euclidiana, onde caso exista um tipo de dados com um intervalo de valores muito superior a outros, o comportamento do algoritmo será altamente influenciado por esta.

#### 3.4.1 Min-Max

A normalização Min-Max transforma todos os valores de um conjunto de valores  $V$  para uma escala de 0 a 1. Considerando um conjunto de valores

$$\{v_1, \dots, v_n\} \in \{V\} \quad (3.2)$$

onde  $n$  representa o número de valores, um valor é normalizado segundo

$$v_i^{minmax} = \frac{v_i - \min(V)}{\max(V) - \min(V)} \quad (3.3)$$

Ao valor mais baixo do conjunto é atribuído o valor 0 e ao mais elevado é atribuído o valor 1, sendo que aos valores intermédios é atribuído um valor à escala da transformação efetuada.

### 3.5 Métodos de Reamostragem

As técnicas de reamostragem são usadas para casos em que a quantidade de dados do conjunto de treino é baixa a um nível que, retirando dados para um conjunto de validação, o modelo não será suficientemente treinado.

Estas permitem fazer a validação de modelos e ter informação sobre se o modelo está *overfitted* ou não, antes de ser usado o conjunto de teste, apresentando no entanto um acréscimo a nível de tempo de computação visto que vários modelos são treinados e validados, em vez de apenas um.

#### 3.5.1 Bootstrap

Bootstrapping é um dos métodos de reamostragem existentes, sendo considerada a melhor a nível de reamostragem de *datasets* muito pequenos [14]. Esta cria um *dataset* com repetição a partir de um *dataset* original, contendo o mesmo número de instâncias. Desta forma, este novo *dataset* (denominado de bootstrap dataset) substitui a presença de algumas das instâncias originais por instâncias repetidas, sendo que as instâncias não presentes no

novo *dataset* criam um novo *dataset*, denominado de *left-out dataset*. Em média, o bootstrap *dataset* contém cerca do  $\frac{2}{3}$  das instâncias presentes no *dataset* original, restando cerca de  $\frac{1}{3}$  para o *left-out dataset*.

O bootstrap *dataset* poder ser usado como conjunto de treino e o *left-out dataset* como conjunto de validação, estimando o erro com estes conjuntos de dados.

### 3.5.2 Cross-validation

Recorrendo a esta técnica, o *dataset* original é particionado de forma aleatória em  $K$  *subsets*, onde um deles é usado como conjunto de validação e os restantes usados para o conjunto de treino.

O  $K$  é tipicamente definido como 10 ou 30 [14] sendo que, à medida que o  $K$  aumenta, a percentagem de instâncias usadas para treino aumenta e é possível obter estimativas mais robustas (tornado-se o conjunto de validação mais pequeno) [14]. Existe, no entanto, o custo de treinar o classificador  $K$  vezes que aumenta à medida que  $K$  é aumentado [14].

## 3.6 Métricas de Avaliação

Dada a natureza de um problema de classificação, é importante o conhecimento de diversas métricas de avaliação do seu desempenho, pelo que aqui são principalmente apresentadas algumas das métricas de avaliação utilizadas na classificação binária, sendo que algumas são abordadas a nível de classificação multi-classe dada a sua relevância nesta dissertação.

Tabela 3.1: Matriz de confusão da classificação binária

		Verdadeira Classe	
		Positivo	Negativo
Classe Prevista	Positivo	VP	FP
	Negativo	FN	VN

Como é possível observar na Tabela 3.1, existem 4 possibilidades de classificação de um resultado na classificação binária, sendo que as mesmas são:

- **VP (Verdadeiro Positivo):** A classe prevista para a instância foi a positiva e a verdadeira classe era positiva;
- **FP (Falso Positivo):** A classe prevista para a instância foi a positiva e a verdadeira classe era negativa;
- **FN (Falso Negativo):** A classe prevista para a instância foi a negativa e a verdadeira classe era positiva;
- **VN (Verdadeiro Negativo):** A classe prevista para a instância foi a negativa e a verdadeira classe era negativa;

A soma do número de todos os resultados classificados como VP (Verdadeiro Positivo), FP (Falso Positivo), FN (Falso Negativo) e VN (Verdadeiro Negativo) é igual ao número total de resultados, sendo que esse conjunto foi definido em 3.4 como  $C$ .

$$C = \#VP + \#VN + \#FP + \#FN \quad (3.4)$$

Na classificação multi-classe as possibilidades de classificação aumentam. A Tabela 3.2 descreve uma matriz de confusão de 4 classes, onde existem  $4^2$  possibilidades de classificação.

Tabela 3.2: Matriz de confusão da classificação multi-classe

		Verdadeira Classe			
		A	B	C	D
Classe Prevista	A	AA	AB	AC	AD
	B	BA	BB	BC	BD
	C	CA	CB	CC	CD
	D	DA	DB	DC	DD

A soma do conjunto de todas as classificações possíveis em 3.2 foi definida como  $M$ .

### 3.6.1 Exatidão

A exatidão indica a porcentagem de instâncias cuja verdadeira classe foi corretamente identificada, considerando o conjunto total de instâncias. Para o caso da classificação binária é definida como

$$\text{Exatidão} = \frac{\#VP + \#VN}{C} \quad (3.5)$$

Para o caso da classificação multi-classe da matriz de confusão 3.2, é definida como

$$\text{Exatidão} = \frac{\#AA + \#BB + \#CC + \#DD}{M} \quad (3.6)$$

### 3.6.2 Precisão

A precisão indica a porcentagem de instâncias corretamente identificadas, dentro das que foram identificadas como pertencendo à classe positiva.

$$\text{Precisão} = \frac{\#VP}{\#VP + \#FP} \quad (3.7)$$

### 3.6.3 Abrangência

A abrangência indica a porcentagem de instâncias identificadas como pertencendo à classe positiva, considerando a totalidade de instâncias cuja verdadeira classe era positiva.

$$\text{Abrangência} = \frac{\#VP}{\#VP + \#FN} \quad (3.8)$$

É, basicamente, um indicador da quantidade de instâncias positivas que estão a ser corretamente identificadas, dentro de todas as instâncias positivas existentes.

### 3.6.4 Especificidade

A especificidade indica a percentagem de instâncias identificadas como pertencendo à classe negativa, considerando a totalidade de instâncias cuja verdadeira classe era negativa.

$$\text{Especificidade} = \frac{\#VN}{\#VN + \#FP} \quad (3.9)$$

É, basicamente, um indicador da quantidade de instâncias negativas que estão a ser corretamente identificadas, dentro de todas as instâncias negativas existentes.

### 3.6.5 F1 Score

O  $F_1$  Score apresenta a média harmónica da precisão e abrangência.

$$F_1 \text{ Score} = \frac{2}{\frac{1}{\text{Precisão}} + \frac{1}{\text{Abrangência}}} \quad (3.10)$$

### 3.6.6 Cohen's Kappa e Fleiss' Kappa

O Cohen's Kappa, ou coeficiente kappa, pode ser usado como métrica de avaliação para classificadores binários e é visto como uma exatidão normalizada pelo desequilíbrio entre classes dos dados, sendo definido como

$$\text{Kappa} = \frac{\text{Exatidão} - \text{Exatidão esperada}}{1 - \text{Exatidão esperada}} \quad (3.11)$$

onde a exatidão esperada é dada por

$$\text{Exatidão esperada} = \frac{(\#VP + \#FN) \times (\#VP + \#FP) + (\#FP + \#VN) \times (\#FN + \#VN)}{C^2} \quad (3.12)$$

Este compara a exatidão observada com a exatidão esperada (a exatidão que seria obtida com um classificador aleatório) e o seu resultado varia entre -1 e 1 apresentando, basicamente, um indicador do desempenho de um dado classificador comparativamente ao desempenho esperado por um classificador aleatório.

O Fleiss' Kappa é aplicável a casos em que existem mais que duas classes e segue o mesmo princípio do Cohen's Kappa definido na expressão 3.11, sendo a exatidão esperada dada para classificações multi-classe segundo

$$\text{Exatidão esperada} = \frac{(A_P) \times (A_V) + (B_P) \times (B_V) + (C_P) \times (C_V) + (D_P) \times (D_V)}{M^2} \quad (3.13)$$

Considerando, por exemplo, uma classe  $X$ ,  $X_V$  é definido como a soma do número de instâncias cuja verdadeira classe é  $X$ , e  $X_P$  como a soma do número de instâncias cuja classe prevista foi a  $X$ . Para o caso da classe  $A$ ,  $A_V = AA + BA + CA + DA$  e  $A_P = AA + AB + AC + AD$  (segundo a matriz de confusão da Tabela 3.2).

### 3.7 Técnicas de *Ensemble*

A ideia por detrás das técnicas de *ensemble* é que, tendo vários classificadores que obtêm resultados ligeiramente diferentes baseados num dado *dataset*, uns estarão a aprender coisas corretamente que outros não, pelo que se os combinarmos, os resultados gerados serão significativamente melhores do que seriam individualmente [15]. Existindo também outras alternativas, uma forma simples de combinar os resultados é utilizando o voto da maioria o que, para classificadores binários, significa que o resultado só será errado se mais de metade dos classificadores estiverem errados [15].

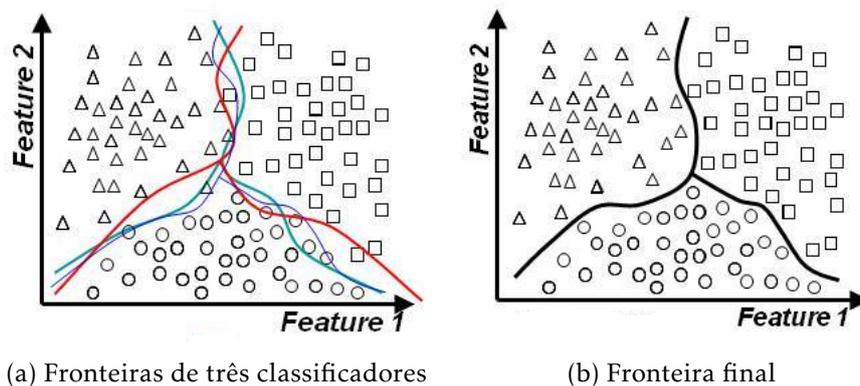


Figura 3.5: Exemplo de combinação de três modelos num classificador

O método mais simples de combinar classificadores é conhecido como bagging (*bootstrap aggregating*), sendo esta uma técnica que treina diversos classificadores baseados em amostras bootstrap (explicado em detalhe na secção 3.5.1) do *dataset* original [14].

Outra técnica muito usada é o boosting, sendo o seu principal algoritmo conhecido como AdaBoost (*adaptive boosting*) [15]. A ideia consiste em focar os dados que os classificadores não estão a conseguir classificar com facilidade, atribuindo pesos a cada um dos dados com base em quão difícil foi para o classificador anterior classificar esse dado corretamente (inicialmente todos têm o mesmo peso). Isto é feito para que, numa próxima iteração, a probabilidade de um dos dados com maior dificuldade em classificar aparecer no conjunto de treino seja maior e, dessa forma, ir melhorando o classificador.

Um exemplo da combinação de classificadores é mostrado na Figura 3.5<sup>3</sup>. Estas técnicas apresentam bons resultados tanto para *datasets* pequenos como grandes [15].

<sup>3</sup>Fonte: [datasciencecentral.com/profiles/blogs/want-to-win-at-kaggle-pay-attention-to-your-ensembles](https://datasciencecentral.com/profiles/blogs/want-to-win-at-kaggle-pay-attention-to-your-ensembles)

### 3.8 Algoritmos de Classificação

Esta secção descreve os algoritmos de AA utilizados nesta dissertação numa ótica de um problema de classificação, sendo que os mesmos também podem ser utilizado na definição de modelos de regressão.

#### 3.8.1 Support Vector Machine

O algoritmo **Support Vector Machine (SVM)** foi introduzido em [18] e, para um problema de classificação, baseia-se na ideia de maximizar a margem entre classes e definir a fronteira de classificação entre essa margem, dando-se o nome de *support vectors* aos vectores utilizados para definir essa margem (destacados no caso linearmente separável da Figura 3.6). Quando a separação perfeita não é possível, o algoritmo encontra a fronteira que maximiza a margem e minimiza as classificações erradas.

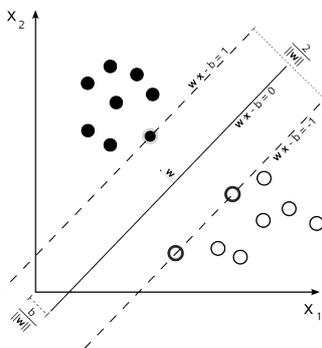


Figura 3.6: Exemplo de definição da fronteira entre classes com o algoritmo SVM

No caso em que as classes não são linearmente separáveis, o algoritmo utiliza funções *kernel* para mapear os dados em dimensões superiores procurando a separabilidade linear, sendo que as funções *kernel* mais utilizadas são a polinomial e a radial. O uso deste procedimento é motivado pelo teorema de Cover que indica que, dado um conjunto de dados não linear num espaço de entradas  $X$ , esse  $X$  pode ser transformado num espaço de características com alta probabilidade dos dados serem linearmente separáveis sendo que, para tal, duas condições devem ser satisfeitas: a transformação ser não linear e a dimensão do espaço de características ser suficientemente alta [19].

#### 3.8.2 Artificial Neural Network

O algoritmo **Artificial Neural Network (ANN)** é inspirado nas estruturas e funções das redes neuronais biológicas. A estrutura destas redes é semelhante à observada na Figura 3.7, sendo esta constituída por diversos neurónios agrupados por camadas (*input layer*, *hidden layers* e *output layer*) que interagem por ligações ponderadas (ou seja, com pesos atribuídos) e chegam a um resultado final.

Cada neurónio aplica uma função de ativação ao valor recebido, propagando o mesmo pelas suas ligações ponderadas a outros neurónios. Baseado no erro da classificação obtida,

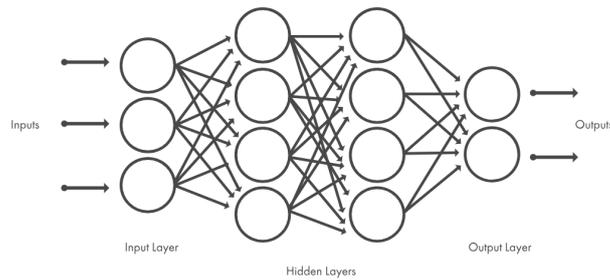


Figura 3.7: Exemplo de uma ANN

é feita a *backpropagation* ajustando diversos parâmetros da rede de forma a melhor a classificação, sendo esta realizada em múltiplas iterações.

### 3.8.3 Random Forests

O algoritmo **Random Forests (RF)**, introduzido em [20], aplica a técnica *bagging* mencionada na secção 3.7 a um conjunto de árvores de decisão onde, basicamente, cada uma é treinada com amostras *bootstrap* do conjunto de dados original. Como resultado, diversas árvores de decisão são treinadas de forma mais fraca e cada uma produz, possivelmente, uma previsão diferente (como é possível observar na Figura 3.8<sup>4</sup>), sendo esperado que a combinação de previsões seja mais precisa quando comparada com a utilização de uma única árvore de decisão treinada com o conjunto de dados total.

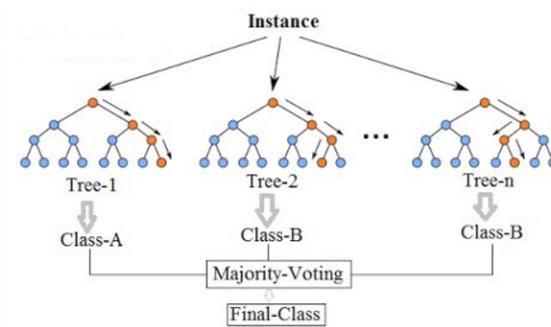


Figura 3.8: Exemplo de um esquema de classificação com três árvores de decisão resultantes do algoritmo RF

A forma mais comum de interpretar os resultados é baseada na maioria, ou seja, a classificação que obtiver mais votos é considerada a correta [21].

### 3.8.4 Extreme Gradient Boosting

O algoritmo **eXtreme Gradient Boosting (XGBOOST)**, introduzido em [22], é uma implementação eficiente do *gradient boosting* mencionado em [23]. Este utiliza um conjunto de árvores de decisão criadas com o uso da técnica *boosting*, mencionada na secção 3.7,

<sup>4</sup>Fonte: [sefiks.com/2017/11/19/how-random-forests-can-keep-you-from-decision-tree/](https://sefiks.com/2017/11/19/how-random-forests-can-keep-you-from-decision-tree/)

cuja ideia consiste em aumentar a probabilidade dos dados de classificação mais difícil fazerem parte do conjunto de treino da próxima árvore de regressão e, dessa forma, ir melhorando o classificador.

Os resultados são combinados com uma média ponderada das classificações, atribuindo um peso superior a árvores de decisão com uma percentagem inferior de classificações erradas.

## ESTADO DA ARTE

Este capítulo apresenta o estado da arte da resolução do problema da detecção de avarias nos rolamentos de um MIT. Para tal, é primeiramente abordado o comportamento esperado da vibração e das correntes elétricas na presença destas avarias na secção 4.1, sendo posteriormente abordadas as diferentes técnicas de processamento de sinais recorrentemente utilizadas na detecção deste tipo de avaria na secção 4.2 e, finalmente, apresentados trabalhos relacionados com exemplos de aplicação de diversas técnicas para a detecção destas avarias na secção 4.3. Na secção 4.4 é feita uma análise e comparação entre os trabalhos observados na secção 4.3.

### 4.1 Frequências Características da Vibração e Correntes Elétricas na Presença de Avarias no Rolamento

Como mencionado previamente, avarias nos rolamentos tipicamente envolvem a deterioração dos seus componentes, sendo que esta deterioração se manifesta com frequências específicas a nível vibracional dado o comportamento rotacional característico do MIT e, consequentemente, de alguns componentes dos rolamentos.

Diferentes tipos de defeitos nos rolamentos implicam vibrações com diferentes frequências sendo que (considerando um anel exterior imóvel), um defeito no anel exterior (DAE), no anel interior (DAI), numa esfera (DE), ou na gaiola (DG) apresenta as frequências descritas na Tabela 4.1, onde  $f_{rm}$  representa a velocidade do rotor (Hz),  $n$  o número de esferas,  $D_c$  o diâmetro primitivo e  $D_b$  o diâmetro de uma esfera (Figura 4.1). Para maior simplicidade, as frequências características de avarias no anel exterior e interior (para rolamentos em que  $6 \leq n \leq 12$ ) podem ser dadas pelas fórmulas simplificadas da Tabela 4.1 [24].

A utilização da análise do espectro das correntes elétricas para a detecção deste tipo de avarias baseia-se na existência de uma relação entre as vibrações provocadas e as

Tabela 4.1: Frequências características das vibrações causadas nos rolamentos, segundo o tipo de defeito

Defeito	Fórmula	Fórmula Simplificada
Anel Exterior	$f_{DAE} = \frac{n}{2} f_{rm} (1 - \frac{Db}{Dc} \cos \beta)$	$f_{DAE} = 0.4 \cdot n \cdot f_{rm}$
Anel Interior	$f_{DAI} = \frac{n}{2} f_{rm} (1 + \frac{Db}{Dc} \cos \beta)$	$f_{DAI} = 0.6 \cdot n \cdot f_{rm}$
Esfera	$f_{DE} = \frac{Dc}{2Db} f_{rm} (1 - (\frac{Db}{Dc})^2 \cos^2 \beta)$	
Gaiola	$f_{DG} = \frac{1}{2} f_{rm} (1 - \frac{Db}{Dc} \cos \beta)$	

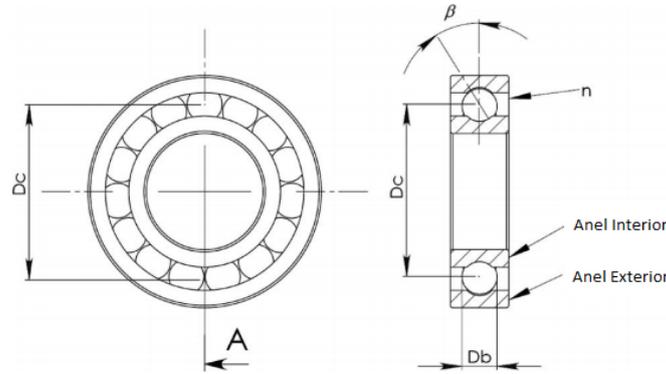


Figura 4.1: Esquema das dimensões de um rolamento de esferas

correntes elétricas. Esta relação, dado o facto de que os rolamentos suportam o rotor, deve-se a que qualquer defeito nos mesmos provoca um deslocamento mecânico ao longo do movimento rotacional do rotor. Este deslocamento mecânico leva à existência de uma excentricidade dinâmica que varia com a posição do rotor (previamente abordada na secção 2.6), sendo que a oscilação na largura da *air gap* provoca variações na densidade do fluxo da *air gap* [24]. Estas variações geram correntes a frequências previsíveis,  $f_{bng}$ , relacionadas com as frequências vibracionais e com a frequência da tensão de alimentação segundo [24]

$$f_{bng} = |f_e \pm k \cdot f_v|, k = 1, 2, 3, \dots \quad (4.1)$$

onde  $f_e$  é a frequência da tensão de alimentação e  $f_v$  representa uma das frequências vibracionais características mencionadas previamente.

Esta generalização permite definir intervalos de frequências onde as anomalias devem surgir sem necessitar de um conhecimento específico sobre a construção dos rolamentos [24], sendo que as variações a nível do espectro das correntes elétricas são comparativamente inferiores às do espectro vibracional.

## 4.2 Processamento de Sinais

### 4.2.1 Transformada Rápida de Fourier

A Transformada Rápida de Fourier (TRF) é um algoritmo eficiente que calcula a Transformada de Fourier Discreta (TFD) (versão da Transformada de Fourier (TF) para funções discretas). Matematicamente, a TFD transforma uma sequência de  $N$  números complexos  $x_0, x_1, \dots, x_{N-1}$  numa sequência de números complexos  $X_0, X_1, \dots, X_{N-1}$  definida por

$$X^k = \sum_{n=0}^{N-1} x_n \cdot e^{-i2\pi kn/N} = \sum_{n=0}^{N-1} x_n \cdot [\cos(2\pi kn/N) - i \cdot \sin(2\pi kn/N)] \quad (4.2)$$

A computação da TFD de  $N$  pontos, usando a definição, teria uma complexidade temporal de  $O(N^2)$ , enquanto a TRF consegue calcular o resultado com uma complexidade temporal de  $O(N \log N)$ , podendo significar uma diferença substancial na velocidade do cálculo especialmente para grandes *datasets*.

A TRF permite decompor uma função temporal oferecendo uma representação dessa função no domínio da frequência (Figura 4.2<sup>1</sup>). Considerando um sinal, por exemplo, como o presente na Figura 4.2a, a TRF permite a visualização destas frequências e respectivas amplitudes da forma apresentada na Figura 4.2b.

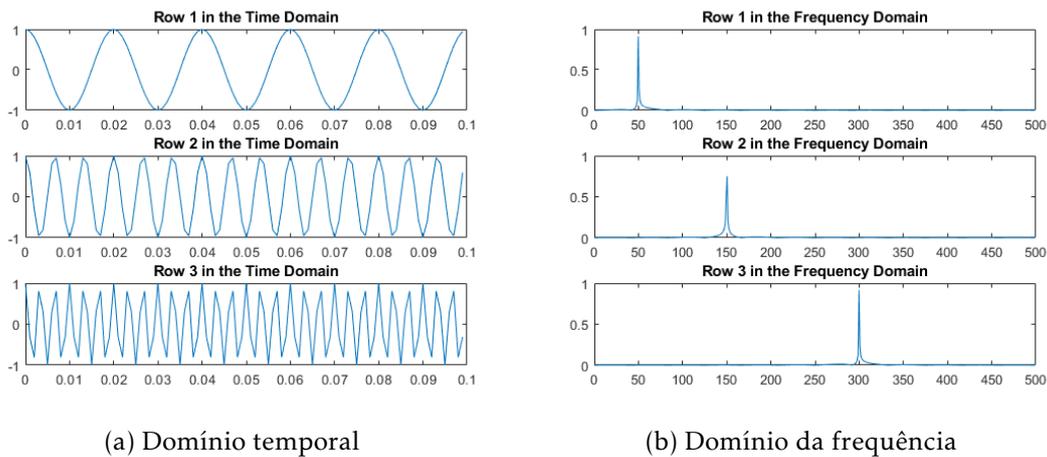


Figura 4.2: Exemplos da aplicação da transformada rápida de Fourier

O teorema de Nyquist é de extrema importância nas análises espectrais e indica que para qualquer sinal ser reconstruído sem perdas significativas, a frequência da amostragem deverá ser o dobro da frequência máxima apresentada no sinal. Se o objetivo passar, por exemplo, por analisar frequências num sinal até 500 Hz, a frequência da amostragem deverá ser de 1 kHz [7].

<sup>1</sup>Fonte: [mathworks.com/help/matlab/ref/fft.html](https://mathworks.com/help/matlab/ref/fft.html)

### 4.2.2 Transformada de Hilbert

A **Transformada de Hilbert (TH)** é uma transformação no domínio do tempo, sendo que a sua aplicação a um sinal corresponde a uma versão desse mesmo sinal deslocado  $90^\circ$ . Tendo como exemplo uma função trigonométrica, a **TH** transforma uma função cosseno numa função seno [25], como é possível observar na Figura 4.3a<sup>2</sup>.

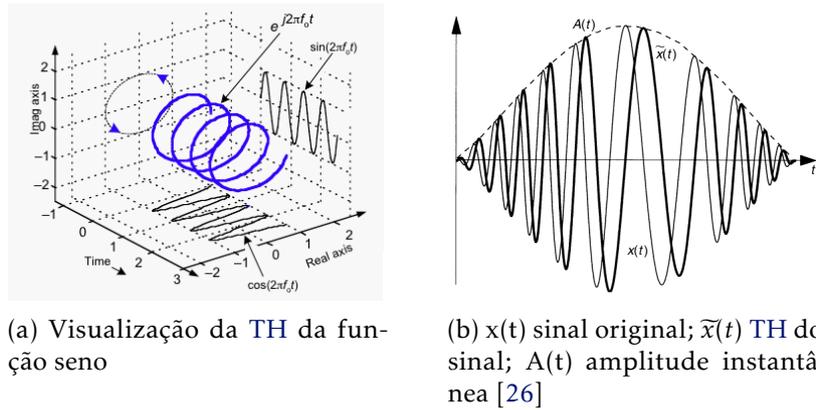


Figura 4.3: Exemplos da aplicação da Transformada de Hilbert

Relativamente ao conteúdo espectral do sinal, a amplitude e a frequência obtidas são iguais às alcançadas com o sinal original, com a diferença de que apenas a fase das componentes espectrais associadas a cada frequência sofre um deslocamento de  $90^\circ$  [25].

Matematicamente, a **TH** é definida como [27]

$$TH(x(t)) = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{x(\tau)}{t - \tau} d\tau = \frac{1}{\pi\tau} x(t) \quad (4.3)$$

podendo ser interpretada como uma convolução entre o sinal  $x(t)$  e  $\frac{1}{\pi\tau}$  [25]. O sinal analítico é definido como

$$\bar{x}(t) = x(t) + jTH(x(t)) = a(t)e^{j\theta(t)} \quad (4.4)$$

onde a sua amplitude instantânea (também referida como *envelope*) e fase são definidas, respetivamente, em 4.5 e 4.6.

$$a(t) = \sqrt{x^2(t) + TH^2(x(t))} \quad (4.5)$$

$$\theta(t) = \arctan \left[ \frac{x(t)}{TH(x(t))} \right] \quad (4.6)$$

### 4.2.3 Transformada de Wavelet Contínua

A **Transformada de Wavelet Contínua (TWC)** permite decompor uma função temporal oferecendo uma representação dessa função no domínio da frequência e tempo, como

<sup>2</sup>Fonte: eetimes.com/document.asp?doc\_id=1275580

é possível observar na Figura 4.4. Pode ser entendida como uma extensão à TF mencionada na secção 4.3.2, visto que acrescenta a noção de tempo às frequências e respectivas amplitudes.

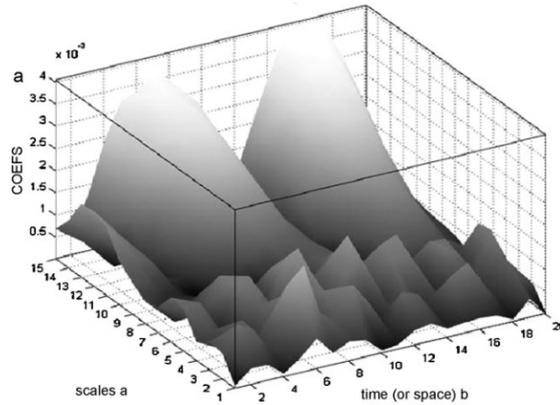


Figura 4.4: Visualização da TWC [28]

Considerando o sinal original  $f(x)$ , a TWC de  $f(x)$  é definida como

$$W_f(a, b) = \int_{-\infty}^{\infty} x(t) \psi_{ab}^*(t) dt \quad (4.7)$$

onde \* indica o conjugado complexo

$$\psi_{ab}^*(t) = \frac{1}{\sqrt{(|a|)}} \psi\left(\frac{t-b}{a}\right) a, b \in \mathbb{R}, a \neq 0 \quad (4.8)$$

#### 4.2.4 Transformada de Park

A Transformada de Park (TP) faz a transformação das correntes do estator de um ST para o domínio DQ, como é possível observar na Figura 4.5 onde é feita a transformação de 4.5a para 4.5b.

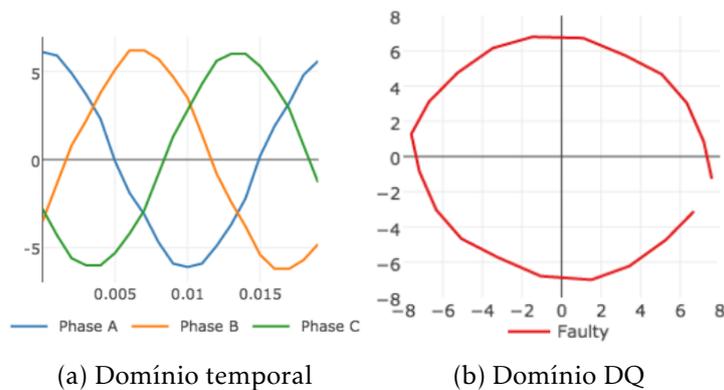


Figura 4.5: Passagem de um ciclo de correntes elétricas do domínio temporal para o domínio DQ, através da TP [7]

A decomposição das correntes A, B e C para as componentes D e Q é dada por

$$\begin{cases} i_d(t) = \sqrt{\frac{2}{3}}i_A(t) - \sqrt{\frac{1}{6}}i_B(t) - \sqrt{\frac{1}{6}}i_C(t) \\ i_q(t) = \sqrt{\frac{1}{2}}i_B(t) - \sqrt{\frac{1}{2}}i_C(t) \end{cases} \quad (4.9)$$

onde  $i_A(t)$  representa a intensidade da corrente da fase A no instante  $t$ ,  $i_B(t)$  representa a intensidade da corrente da fase B no instante  $t$  e  $i_C(t)$  representa a intensidade da corrente da fase C no instante  $t$ .

Em condições ideais, as componentes  $d$  e  $q$  podem ser representadas segundo

$$\begin{cases} i_d(t) = (\frac{\sqrt{6}}{2})i_M \sin(\omega t) \\ i_q(t) = (\frac{\sqrt{6}}{2})i_M \sin(\omega t - \frac{\pi}{2}) \end{cases} \quad (4.10)$$

onde  $i_M$  é o valor máximo da sequência positiva da corrente,  $\omega$  é a frequência de alimentação angular, e  $t$  a variável tempo (s). A representação das condições ideais no domínio DQ resultaria num círculo perfeito, como é possível observar na Figura 4.6a, verificando-se a tendência para a formação de uma elipse, como a observada na Figura 4.6b, quando o motor não se encontra nas condições ideais (indicando a presença de avarias).

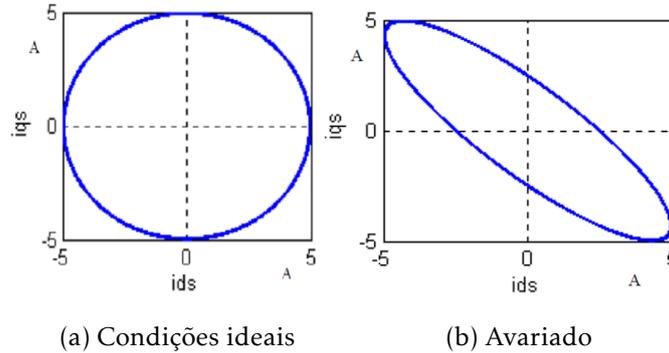


Figura 4.6: TP de um motor em condições ideais e avariado [7]

#### 4.2.5 Transformada de Park Estendida

A Transformada de Park Estendida (TPE) faz a transformação das correntes elétricas A, B e C para uma única componente, sendo esta dada pelo módulo do Vetor de Park segundo

$$i_{TPE}(t) = \sqrt{i_d(t)^2 + i_q(t)^2} \quad (4.11)$$

Esta é uma transformada habitualmente analisada a nível espectral e mencionada como *Extended Park's Vector Approach* (EPVA) sendo, portanto, frequentemente utilizada em conjunto com a TRF.

Em condições ideais, o espectro da TPE não contém qualquer componente, estando apenas presente o valor da corrente contínua na corrente da TPE ( $i_{TPE}$ ) [29], sendo isto

demonstrado na Figura 4.7. O exemplo da Figura mostra a presença de uma componente na corrente da TPE quando as correntes se encontram em desequilíbrio, tendo essa componente uma frequência duas vezes superior à das correntes em desequilíbrio.

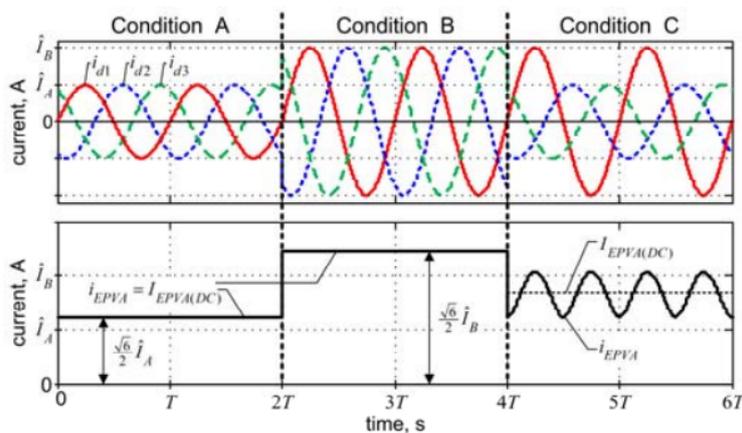


Figura 4.7: Princípio teórico da TPE [29]

### 4.3 Métodos para Detecção de Avarias em Rolamentos

Ao longo desta secção são detalhadamente descritos diversos métodos utilizados para a detecção de avarias em rolamentos, sendo que a maioria descreve uma detecção com base na utilização de técnicas de AA.

#### 4.3.1 Análise Estatística da Vibração no Domínio Temporal com SVM e ANN

Em [30] é utilizado um motor com características não especificadas, em ambiente laboratorial, e são colocados diversos sensores de aceleração em múltiplas localizações do mesmo fazendo os registos da vibração com uma frequência de amostragem de 10 kHz. São simulados os seguintes estados de avaria do rolamento (variando também a condição do rotor entre um funcionamento ideal e um funcionamento com o rotor rachado): rolamento saudável, com fratura na pista externa, com uma lasca na pista interior, com picadas na esfera (resultantes da corrosão) e com todos os defeitos combinados.

Neste caso, a velocidade do rotor foi uma das *features* escolhidas, sendo que as restantes resultam da análise estatística da vibração no domínio temporal e consistem na amplitude (diferença entre o valor máximo e mínimo do sinal), valor médio do sinal, desvio padrão, a assimetria e a curtose.

A extração de *features* foi efetuada sobre os registos de vibração vertical e horizontal, sendo comparados os desempenhos dos algoritmos SVM e ANN. Usando 360 instâncias para o processo de treino, os resultados foram positivos, apresentando exatidões na ordem dos 95% na classificação multi-classe de 359 instâncias. O intervalo de tempo utilizado para a extração de *features* não é especificado.

### 4.3.2 Análise do Espectro Vibracional Resultante da Transformada Rápida de Fourier com ANN

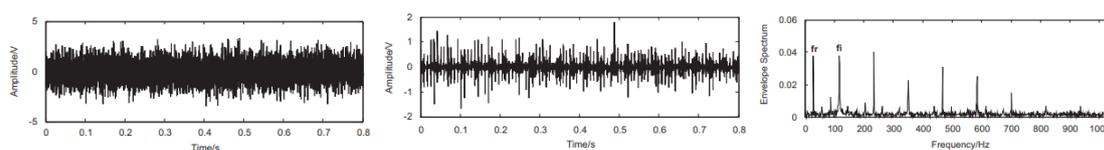
Em [31] foi utilizado um MIT do *Machinery Fault Simulator* da SpectraQuest para simular as avarias nos rolamentos, e feito um registo do sinal de vibração vertical e horizontal do motor com uma frequência de amostragem de 20 kHz.

Os rolamentos utilizados refletem diferentes estados de avaria: rolamento sem avarias, com avaria na esfera, com avaria na pista interior e com avaria na pista exterior. Os rolamentos defeituosos são disponibilizados pelo fabricante, de modo que as dimensões dos defeitos não são conhecidas.

Neste caso, foi aplicada a TRF sobre as vibrações e utilizada a densidade espectral (que indica quanto do sinal está numa dada frequência) de um intervalo de frequências próximo das frequências características como *features*, juntamente com dados resultantes da análise estatística da vibração no domínio temporal (amplitude máxima e média, e curtose). Utilizando um intervalo de tempo de 819.2 ms para a extração de *features*, a classificação multi-classe de 432 instâncias registou uma taxa de deteção (média da precisão obtida na classificação de cada classe) de cerca de 96% de avarias com a utilização do algoritmo ANN.

### 4.3.3 Análise do Espectro da Amplitude Instantânea da Transformada de Hilbert com SVM

Em [32] foi utilizado um MIT com 3 kW de potência e uma tensão de alimentação de 380 V com frequência de 50 Hz, tendo sido feito o registo da vibração do motor com uma frequência de amostragem de 25.6 kHz. O sinal original foi filtrado com o filtro cíclico de Wiener, sendo calculado o espectro da amplitude instantânea da TH através da TRF e demonstradas claras melhorias na visualização das frequências características, como é possível observar na Figura 4.8.



(a) Sinal original no domínio do tempo (b) Sinal filtrado no domínio do tempo (c) Espectro da amplitude instantânea do sinal filtrado

Figura 4.8: Processamento de sinal da vibração de um rolamento com uma avaria no anel interior [32]

Em [33] foi utilizado um MIT cujas características não são especificadas e feito o registo do sinal da vibração com uma frequência de amostragem de 25.6 kHz. O acelerómetro foi colocado diretamente acima do rolamento avariado. Neste caso, foram analisados os espectros da amplitude instantânea da TH de um período de 800 ms da vibração e utilizadas as magnitudes registadas em 4 frequências características como *features*. A

classificação foi realizada entre estado saudável, avaria na pista externa, avaria na pista interna e avaria no rolamento através de um sistema em cadeia de 3 *SVM* em que, dependendo do resultado obtido com o modelo *SVM* anterior, a classificação seria feita com os modelos *SVM* seguintes (como é possível observar na Figura 4.9). Foram utilizadas 180 instâncias para o treino dos modelos, tendo sido testadas apenas 20 instâncias mas obtida uma classificação perfeita.

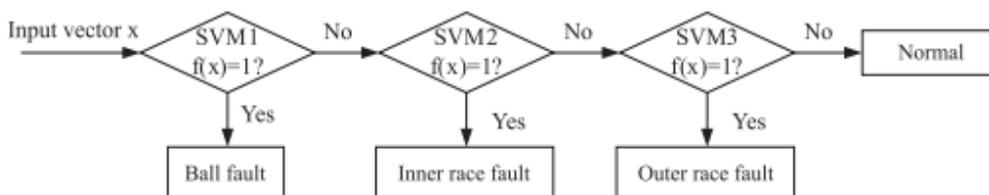


Figura 4.9: Esquema de classificação multi-classe com cadeia de modelos *SVM* [33]

#### 4.3.4 Análise Estatística da Transformada de Wavelet Contínua da Vibração e das Correntes Elétricas com ANN e SVM

Em [28] foi utilizado um MIT do *Machinery Fault Simulator* da SpectraQuest de 2 polos e 0.5 hp de potência, com uma frequência de alimentação de 60 Hz e o registo do sinal de vibração foi feito com uma frequência de amostragem de 7.68 kHz. Para as simulações foi utilizado um rolamento saudável e um avariado (a localização da avaria não foi especificada, fazendo parte do *Machinery Fault Simulator*) e variada a carga do motor. Foram alcançados resultados muito bons fazendo o processamento e análise da vibração através da *TWC*, registrando-se percentagens de sucesso de 100% usando *SVM*, e cerca de 97% usando *ANN* como classificador (120 instâncias foram usadas no treino do modelo e 30 no teste). Foram utilizados como *features* três tipos de dados estatísticos: *RMS*, *crest* e *curtose* dos coeficientes da *TWC* (a extração de *features* foi realizada de um intervalo de tempo não indicado).

Em [34] foi utilizado um MITGE de 4 polos e 2 hp de potência com uma tensão de alimentação de 415 V e uma frequência de 50 Hz, tendo sido feito o registo das correntes e tensões elétricas com uma frequência de amostragem ajustável até 1 GHz e variando a carga do motor. Neste caso foram simuladas avarias na pista externa e interna no rolamento, tendo também sido avaliadas avarias no rotor e avarias elétricas no estator (independentemente). Recorrendo à *TWC* para processamento da corrente, e usando uma *ANN* como classificador, foram usados como *input* para uma *ANN* os valores mínimos dos coeficientes da *TWC*, tendo o treino do algoritmo sido efetuado com base em 300 instâncias e o teste com 200 instâncias extraídas de um intervalo de tempo desconhecido, registrando uma exatidão de 100%.

### 4.3.5 Análise da Transformada de Park das Correntes Elétricas com ANN

Em [35] foi utilizado um MIT do *Machinery Fault Simulator* da SpectraQuest de 2 polos e 0.5 hp de potência, com uma frequência de alimentação de 60 Hz, tendo sido feito o registo das correntes elétricas com uma frequência de amostragem de 7.68 kHz. Neste caso, a TP mostrou excelentes resultados na demonstração de avarias no rolamento (como é possível observar na Figura 4.10) e os valores de  $i_d$  e  $i_q$  foram utilizados como *features* para treinar uma ANN, tendo sido registadas exatidões de 100% na classificação entre rolamento saudável, com avaria na pista interior, e avaria na pista exterior. O intervalo de tempo utilizado para a extração de *features* não é especificado.

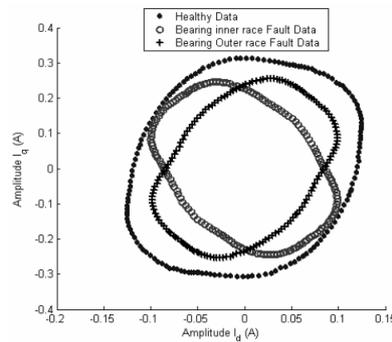


Figura 4.10: Domínio DQ da TP da corrente de um motor com rolamentos em condições ideais e avariados [35]

Em [7] foi observada uma alternativa ao procedimento utilizado em [35] para retirar informação em relação à elipse resultante da TP, tendo sido utilizada para a deteção de avarias de curto-circuito entre espiras de MIs. Esta abordagem procurou estudar a excentricidade da elipse através da *Análise de Componentes Principais* (ACP) da elipse criada no domínio DQ, como ilustrado na Figura 4.11, sendo posteriormente calculada a *excentricidade* $_{DQ}$  segundo a equação 4.12 que basicamente indica a diferença entre a magnitude de ambas as componentes resultantes da ACP.

$$imbalance_{DQ} = |PC_1| - |PC_2| \quad (4.12)$$

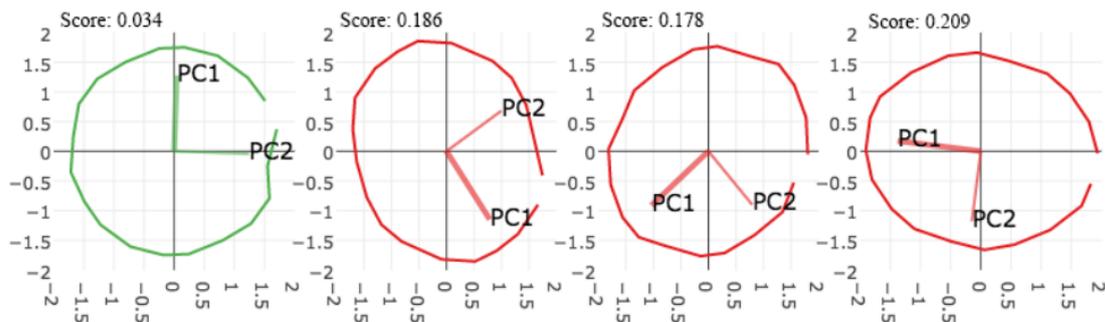


Figura 4.11: Análise de componentes principais da elipse resultante da TP [7]

#### 4.3.6 Estudo da Transformada de Park Estendida das Correntes Elétricas

Em [36] foi avaliado o espectro da TPE para avarias na pista externa do rolamento com diâmetros de 2 mm, 5 mm e 8 mm de um MITGE de 4 polos com 3 kW de potência e uma tensão de alimentação de 380 V com uma frequência de 50 Hz. Neste caso foi analisado um intervalo de tempo alargado e verificada a manifestação da avaria no mesmo ao existir um aumento na magnitude de diversas frequências consoante o aumento do diâmetro da avaria.

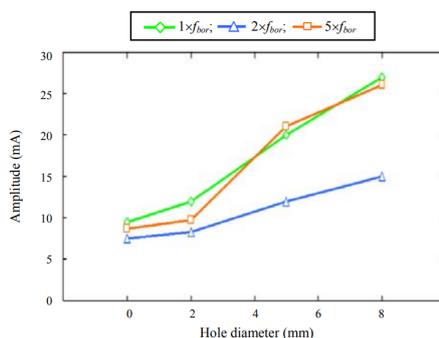


Figura 4.12: Variação da magnitude de determinadas frequências consoante o aumento do diâmetro do defeito da avaria na pista externa do rolamento [36]

Em [37] foi utilizado um MIT com 11 kW de potência e uma tensão de alimentação de 380 V com uma frequência de 50 Hz. Foram avaliadas avarias singulares na pista externa, pista interna e gaiola do rolamento onde se verificou a presença de claros indicadores de avaria nos espectros da TPE, como é possível observar para o caso da Figura 4.13 que mostra a variação da magnitude de algumas das frequências com o aumento do diâmetro de defeito na pista interna. Foi também observada uma maior manifestação no espectro da TPE de defeitos na pista interna, seguida dos defeitos da pista externa e, finalmente, de defeitos na gaiola.

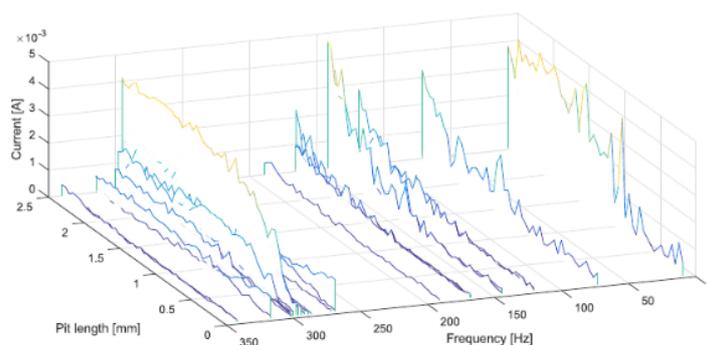


Figura 4.13: Variação da magnitude de determinadas frequências consoante o aumento do diâmetro do defeito da avaria na pista interna do rolamento [37]

## 4.4 Conclusões

Os diversos trabalhos analisados na secção 4.3 demonstram o potencial de deteção de avarias em rolamentos de **MITs** através da monitorização da vibração e das correntes eléctricas do motor, sendo este potencial validado com a utilização de motores com diferentes características (a nível de potência, tensão e frequência de alimentação, etc.).

As frequências de amostragem e os tempos de análise utilizados aparentam, no entanto, ser um ponto a avaliar dado que, quanto maior a frequência de amostragem dos sinais e o intervalo de tempo necessário para proceder à sua análise, maior será a quantidade de dados a ser enviados, o tempo de computação do processo de extração de *features* e, caso se pretenda guardar os registos, a capacidade de armazenamento necessária. Neste sentido, a frequência de amostragem mínima utilizada nos estudos descritos é de cerca de 8 kHz no processamento da vibração através da **TWC** e da corrente através da **TP** descritos em [28, 35] sendo que a norma ronda os 20 kHz. A nível do tempo de análise utilizado, os trabalhos que o mencionam utilizam cerca de 800 ms (análise espectral da vibração e análise espectral da amplitude instantânea da **TH** em [31, 33]), deixando em aberto a possibilidade de deteção com frequências de amostragem e intervalos de tempo de análise inferiores aos utilizados. Esta necessidade de utilização de intervalos de análise muito alargados é comum nas abordagens descritas em relação a análises espectrais, em [31–33, 36, 37], e resultantes da **TRF** da vibração, amplitude instantânea da **TH** e **TPE**, dada a observação de frequências características que exigem um detalhe elevadíssimo no espectro de frequências resultante da **TRF** (quanto maior o intervalo de tempo estudado, maior o detalhe disponível no intervalo de frequências oferecido pela frequência de amostragem utilizada).

A nível da monitorização da vibração, algumas abordagens (nomeadamente a análise estatística da vibração e a análise espectral da vibração descritas em [30, 31]) fazem uso de diversos registos da vibração resultantes da colocação de múltiplos acelerómetros no motor, sendo também utilizadas localizações do sensor não exequíveis em ambiente industrial (nomeadamente na análise espectral da amplitude instantânea da **TH**, descrita em [33], onde o acelerómetro é colocado diretamente acima do rolamento), pelo que não é claro o desempenho destas abordagens utilizando apenas um sensor colocado numa posição viável do motor.

É importante mencionar que a comparação entre a deteção da avaria através da análise das correntes e da vibração não é feita em nenhuma das referências estudadas, sendo que esta possibilitaria a comparação entre ambos os métodos de deteção utilizando o mesmo *setup* experimental.

O estudo da deteção da avaria através da análise do espectro da amplitude instantânea da **TH** e da **TWC** da vibração, descritos em [28, 33], destacam-se negativamente pela baixa quantidade de dados utilizada e os algoritmos **SVM** e **ANN** são evidenciados pela frequente utilização nas publicações mencionadas ao longo da secção 4.3, sendo que ambos registam excelentes desempenhos.

## COMPREENSÃO E PREPARAÇÃO DOS DADOS

Neste capítulo são apresentadas as fases de compreensão e preparação dos dados da metodologia [CRISP-DM](#). Primeiramente, na secção 5.1 correspondente à compreensão dos dados, são apresentados os *datasets* utilizados sendo posteriormente feita uma observação dos seus registos no domínio temporal, um estudo da sua assinatura espectral e uma avaliação do potencial impacto da frequência de amostragem. Na secção 5.2, correspondente à preparação dos dados, são descritas as análises feitas aos mesmos e os métodos utilizados, sendo avaliado o seu poder discriminativo em relação ao estado de avaria do rolamento. As conclusões retiradas são descritas na secção 5.3.

### 5.1 Compreensão dos Dados

#### 5.1.1 Descrição dos *Datasets* Utilizados

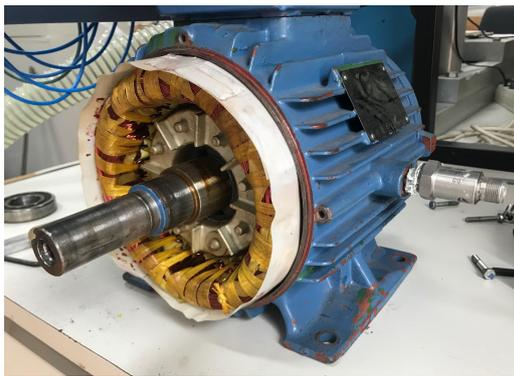
Os dados utilizados ao longo do desenvolvimento da dissertação tiveram duas fontes relevantes: o primeiro *dataset*, recolhido por um parceiro da Altran (Optisigma), oferece um registo paralelo das correntes e tensões elétricas, e vibração do motor com diferentes frequências de amostragem, estando descrito na sub-secção 5.1.1.1, sendo que o segundo é disponibilizado *online* pela [Case Western Reserve University \(CWRU\)](#) e oferece um registo da vibração do motor com diversos estados de avaria de intensidades muito baixas, estando descrito na sub-secção 5.1.1.2.

##### 5.1.1.1 Dados da Optisigma

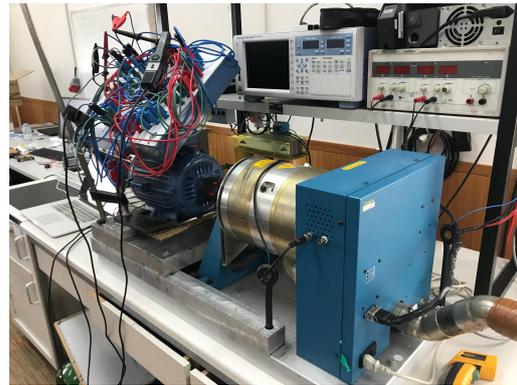
Este conjunto de dados, resultante de uma parceria entre a Altran e a Optisigma, foi recolhido através da simulação experimental de diferentes estados de avaria do rolamento num motor com 4 kW de potência, 4 polos magnéticos, uma tensão de alimentação de 400 V com uma frequência de 50 Hz e classe de eficiência IE3 (mostrado na Figura 5.1a)

com rolamentos FAG 6207-2RS de dimensões descritas na Figura 5.2. Considerando a frequência da tensão de alimentação e o número de polos magnéticos do motor, a velocidade de sincronismo do motor é de 1500 rpm.

A recolha de dados foi efetuada com diferentes frequências de amostragem (0.8 kHz, 1 kHz, 2 kHz, 5 kHz e 10 kHz) e com o *setup* experimental ilustrado na Figura 5.1b (o sensor de aceleração ficou posicionado na parte lateral da carcaça do motor), obtendo registos da fase A e B das correntes e tensões elétricas, e da vibração (aceleração radial) do motor.



(a) Motor Elétrico



(b) *Setup* Experimental

Figura 5.1: MITGE utilizado e *setup* experimental da recolha de dados da Optisigma

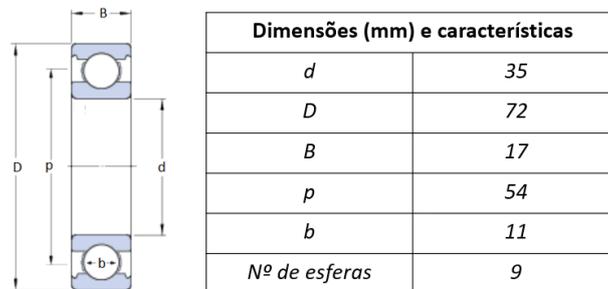


Figura 5.2: Dimensões e características do rolamento dos dados Optisigma

Tratando-se de um sistema trifásico alimentado com 3 condutores, a terceira corrente de linha e a terceira tensão composta foram determinadas por subtração, em cada instante, segundo as equações 5.1 e 5.2, pelo que os dados passaram a apresentar a estrutura resumida na Tabela 5.1.

$$I_C = -I_A - I_B \quad (5.1)$$

$$V_C = -V_A - V_B \quad (5.2)$$

Este *dataset* contém o registo de dados com 2 estados diferentes do rolamento: rolamento saudável e rolamento com uma avaria na pista externa, sendo que o último estado

Tabela 5.1: Estrutura final do conjunto de dados da Optisigma

<i>Feature</i>	<i>Unidade</i>	<i>Descrição</i>
Corrente A ( $I_A$ )	Ampere	Corrente do estator de fase A
Corrente B ( $I_B$ )	Ampere	Corrente do estator de fase B
Corrente C ( $I_C$ )	Ampere	Corrente do estator de fase C
Tensão A ( $V_A$ )	Volt	Tensão da fase A
Tensão B ( $V_B$ )	Volt	Tensão da fase B
Tensão C ( $V_C$ )	Volt	Tensão da fase C
Vibração	g	Vibração/aceleração radial

foi simulado através da realização de pequenos furos centrais na pista com intensidades de 1 mm, 2 mm e 4 mm (avarias ilustradas na Figura 5.3), tendo o defeito no rolamento sido colocado no motor na posição das 6h, ou seja, apontando para a base do motor (a pista externa do rolamento permanece sempre imóvel). Em termos de carga do motor esta foi imposta por um freio dinamométrico e a recolha foi feita com 3 cargas distintas: sem carga (0%), a meia carga (50%) e em plena carga (100%) para cada um dos estados de avaria.



Figura 5.3: Rolamentos com defeitos de 2mm e 4mm utilizados pela Optisigma

A recolha de dados foi realizada de forma sequencial entre frequências de amostragem, ou seja, dados recolhidos com as mesmas condições, mas com frequências de amostragem diferentes, foram recolhidos em alturas distintas, sendo que a única variação não é apenas a frequência de amostragem mas os próprios registos.

A Tabela 5.2, além de mostrar os diâmetros das avarias, as cargas utilizadas, e as velocidades de rotação do rotor registadas durante as simulações, descreve também a quantidade de dados disponíveis para cada uma das situações, em termos de períodos de 20 ms (ou seja, um ciclo de correntes/tensões elétricas). Podemos observar, por exemplo, que para a situação em que o rolamento se encontra com uma avaria com um diâmetro de 1mm, o motor com uma carga de 0%, e a recolha de dados foi feita com uma frequência de amostragem de 1 kHz, temos um registo de 1049 períodos de 20 ms (ou seja, 1049 ciclos de correntes/tensões elétricas), correspondente a um período de recolha de dados de cerca de 21 segundos. Esta tabela permite constatar uma diminuição da velocidade de rotação do rotor consoante o aumento da carga.

Tabela 5.2: N° de períodos de 20 ms (ciclos) para cada diâmetro de avaria do rolamento, carga do motor e frequência de amostragem da recolha de dados da Optisigma

Estado do rolamento	Diâm. (mm)	Carga (%)	Velocidade (RPM)	Frequência de amostragem (kHz)				
				0.8	1	2	5	10
Saudável	0	0	1499	562	549	499	599	999
		50	1482	562	549	499	499	999
		100	1460	562	549	499	599	999
Avariado (Anel Externo)	1	0	1499	1062	1049	874	1099	1499
		50	1480	1062	1049	874	999	1499
		100	1460	1062	1049	849	999	1499
	2	0	1499	562	549	499	599	999
		50	1482	562	549	499	599	999
		100	1460	562	549	499	599	999
	4	0	1499	874	949	899	999	1249
		50	1482	874	999	824	999	1249
		100	1460	937	999	874	999	1249

Analisando a quantidade de períodos de 20 ms disponíveis para os diferentes estados de avaria do rolamento, é possível constatar um desequilíbrio entre a quantidade de dados recolhida para os estados do rolamento saudável e avariado, sendo que este desequilíbrio se encontra resumido para as diferentes frequências de amostragem na Tabela 5.3.

Tabela 5.3: N° de períodos de 20 ms (ciclos) e equilíbrio entre classes consoante o estado do motor e frequência de amostragem para os dados Optisigma

	Frequência de amostragem (kHz)	N° de porções de 20 ms por estado do rolamento		Equilíbrio entre classes
		Saudável	Avariado	
	0.8	1686	7557	1 : 4.5
	1	1647	7741	1 : 4.7
	2	1497	6691	1 : 4.5
	5	1697	7891	1 : 4.6
	10	2997	11241	1 : 3.8

### 5.1.1.2 Dados da Case Western Reserve University

Este conjunto de dados encontra-se disponível *online* numa base de dados da [CWRU](#) e foi recolhido de um [MIT Reliance](#) de 1.49 kW com rolamentos 6205-2RS JEM SKF de dimensões descritas na Figura 5.5, sendo possível observar o *setup* experimental na Figura 5.4 que consiste no motor à esquerda, um sensor de binário/codificador no centro, um dinamométrico à direita e a eletrónica de controlo que não é mostrada na Figura. O sensor de aceleração foi preso ao motor magneticamente, tendo sido colocado na posição das 12h acima do rolamento que estava a ser testado.

Os dados foram registados com uma frequência de amostragem de 12 kHz e incluem

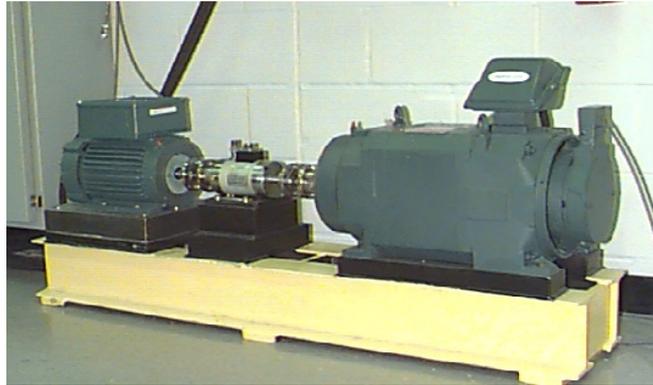


Figura 5.4: *Setup* experimental da recolha de dados da CWRU

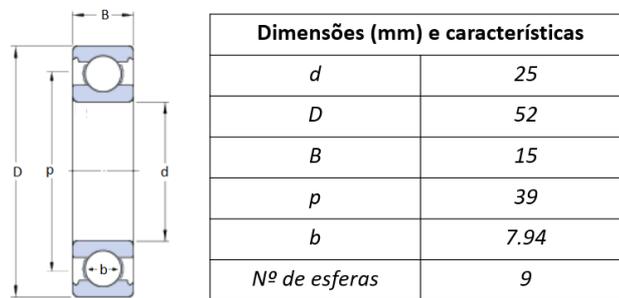


Figura 5.5: Dimensões e características do rolamento dos dados CWRU

registos relativos à vibração (aceleração radial) do motor com a estrutura ilustrada na Tabela 5.4.

Tabela 5.4: Estrutura do conjunto de dados da CWRU

<i>Feature</i>	<i>Unidade</i>	<i>Descrição</i>
Vibração	$ms^2$	Vibração/aceleração radial

Neste conjunto de dados o registo foi feito com 4 estados diferentes do rolamento: rolamento saudável, rolamento com uma avaria na pista interna, rolamento com uma avaria na pista externa e rolamento com uma avaria na esfera, sendo que a posição do defeito na pista externa do rolamento era a das 6h (apontando para a base do motor). Todas as avarias foram simuladas com intensidades distintas e, em termos de carga do motor, a recolha foi feita com 4 cargas diferentes: 0%, 50%, 100% e 150%.

As avarias foram provocadas nos rolamentos através de um processo denominado de eletroerosão, sendo que este possibilita a formação de avarias com diâmetros muito reduzidos, como é possível observar na Tabela 5.5. Esta tabela, além de mostrar os diâmetros das avarias, as cargas utilizadas, e as velocidades de rotação do rotor registadas durante as simulações, descreve também a quantidade de dados disponíveis para cada uma das situações, em termos de períodos de 20 ms. A quantidade de dados disponíveis para um estado do rolamento saudável encontra-se descrita na Tabela 5.6.

Tabela 5.5: N° de períodos de 20 ms para cada diâmetro de avaria do rolamento e carga do motor da recolha de dados da CWRU

Diâmetro (mm)	Carga (%)	Velocidade (RPM)	N° de porções de 20 ms por localização da avaria		
			Pista Interna	Pista Externa	Esfera
0.1778 (0.18)	0	1797	505	508	510
	50	1772	508	510	505
	100	1750	508	505	506
	150	1730	512	510	506
0.3556 (0.36)	0	1797	507	507	507
	50	1772	507	508	508
	100	1750	507	507	508
	150	1730	507	508	508
0.5334 (0.53)	0	1797	508	510	508
	50	1772	506	508	507
	100	1750	507	509	508
	150	1730	508	508	508

Tabela 5.6: N° de períodos de 20 ms com um rolamento saudável para cada carga do motor da recolha de dados da CWRU

Carga (%)	Velocidade (RPM)	N° de porções de 20 ms
0	1797	1016
50	1772	2016
100	1750	2021
150	1730	2023

Observando as velocidades de rotação do rotor registadas nas tabelas e, consequentemente, partindo do princípio que a velocidade de sincronismo deste motor é de 1800 rpm (não existe informação em relação à tensão de alimentação nem ao número de polos do motor), este MIT regista um aumento do deslizamento com o aumento da carga do motor sendo o mesmo na ordem dos 0.2% sem carga, 1.6% com uma carga de 50%, 2.8% com uma carga de 100% e 3.9% com uma carga de 150%.

Tabela 5.7: N° de períodos de 20 ms e equilíbrio entre classes consoante o estado do motor para os dados CWRU

N° de porções de 20 ms por estado do rolamento		Equilíbrio entre classes
Saudável	Avariado	
7076	18277	1 : 2.6

As Tabelas 5.7 e 5.8 oferecem, respetivamente, um resumo da quantidade de dados disponíveis para o estado do rolamento saudável/avariado (com a soma da quantidade

Tabela 5.8: N° de períodos de 20 ms e equilíbrio entre classes consoante o estado do motor para os dados CWRU

N° de porções de 20 ms por estado do rolamento				Equilíbrio entre classes
Saudável	Avaria PI	Avaria PE	Avaria E	
7076	6090	6098	6089	1.2 : 1 : 1 : 1

de dados de cada avaria no estado avariado) e a quantidade de dados disponíveis discriminando cada um dos estados de avaria, sendo também possível observar o desequilíbrio entre classes nas mesmas. Este desequilíbrio, apesar de menos severo que o verificado no *dataset* optisigma descrito na secção 5.1.1.1, é na ordem de 1:2.6 entre os dados com rolamento saudável e rolamento avariado, sendo de menor ordem quando discriminado o tipo de avaria mas mantendo-se (1.2:1:1:1).

### 5.1.2 Observação das Correntes e Tensões Elétricas, e da Vibração no Domínio Temporal

Ao longo desta observação é recorrentemente utilizado o *dataset* optisigma para exemplos presentes nas figuras, sendo utilizada a frequência de amostragem máxima disponível (10 kHz) dado ser a que de forma mais realista e precisa representa os dados presentes neste *dataset*. Nas figuras que incluem visualizações de correntes ou tensões elétricas foi tomada a opção de limitar o escopo a apenas um ciclo (com duração de 20 ms) de forma a favorecer a clareza da mesma, sendo que em visualizações relacionadas com a vibração o escopo foi alargado para 1 segundo. De modo a que os gráficos com registos de vibração dos diferentes *datasets* apresentassem as mesmas unidades (dado que o *dataset* optisigma contém os registos da aceleração em  $g$  e o *dataset* CWRU em  $ms^2$ ), as unidades dos gráficos referentes a dados presentes no *dataset* CWRU foram alteradas para  $g$  segundo a equação  $1g = 9.80665ms^2$ .

Como previamente demonstrado, na descrição dos *datasets* utilizados, estes contêm registos de 3 grandezas físicas distintas: vibração, correntes elétricas e tensões elétricas. A utilização desta última, apesar de presente no *dataset* optisigma, foi descartada para a classificação do estado de avaria do rolamento dada a origem laboratorial deste conjunto de dados e consequente utilização de tensões perfeitas na realização das simulações de forma a separar o efeito do desequilíbrio da tensão de alimentação do efeito da avaria no rolamento. Ao observar as Figuras 5.6, 5.7, 5.8 e 5.9, que demonstram um ciclo de tensões elétricas quando na presença de um rolamento saudável, um rolamento com um defeito com 1 mm de diâmetro, um rolamento com um defeito com 2 mm de diâmetro e um rolamento com um defeito com 4 mm de diâmetro, respetivamente, com as três cargas utilizadas, verifica-se que as tensões são de facto perfeitas na medida em que a amplitude é igual em todas as fases e o ângulo entre as mesmas é de 120°. Comprova-se também que, como desejado, todas as tensões elétricas se assemelham a uma senoide perfeita

independentemente do estado de avaria do rolamento.

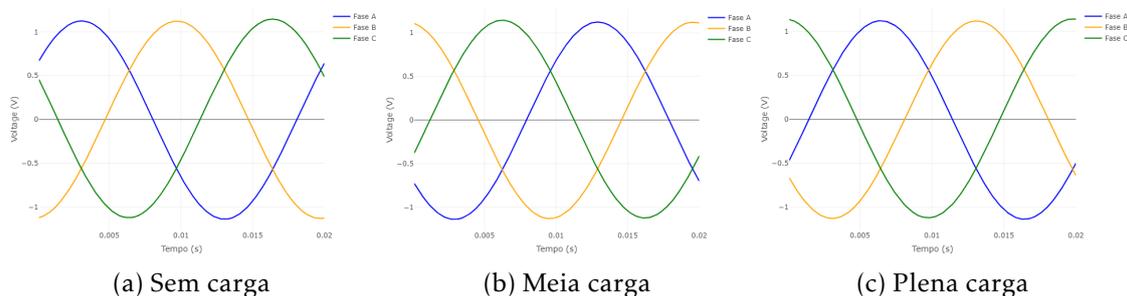


Figura 5.6: Tensões elétricas do motor com todas as cargas com um rolamento saudável

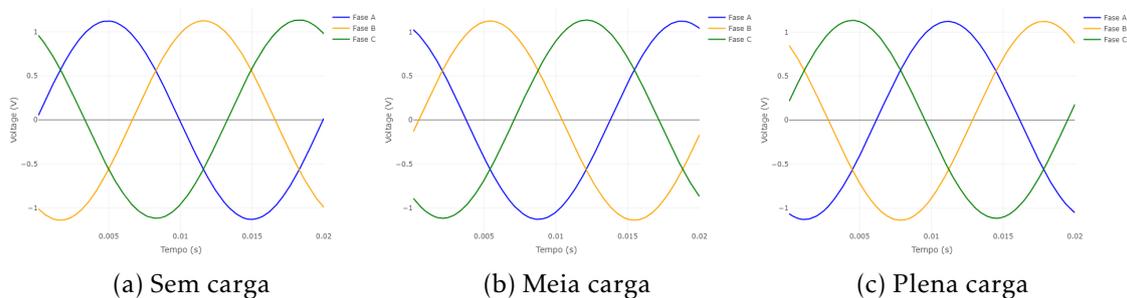


Figura 5.7: Tensões elétricas do motor com todas as cargas com um rolamento avariado (defeito de 1 mm)

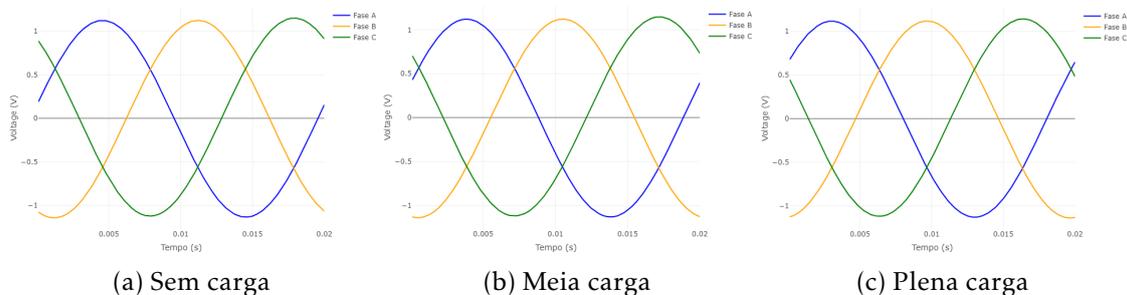


Figura 5.8: Tensões elétricas do motor com todas as cargas com um rolamento avariado (defeito de 2 mm)

Em relação às correntes elétricas, a Figura 5.10 ilustra um ciclo das mesmas registadas com um rolamento saudável com as três cargas utilizadas. Nesta é possível observar que existe uma variação na amplitude das correntes com a variação da carga onde, quanto maior a carga, maior a amplitude das correntes, sendo também possível notar o aparecimento de pequenas oscilações nas fases em que as correntes mudam de sentido com o aumento da carga (o escopo do eixo das ordenadas das Figuras 5.10, 5.11, 5.13 e 5.14 varia entre cargas de forma a facilitar a visualização).

Analisando os ciclos de correntes elétricas com um rolamento com um defeito de 1 mm visíveis na Figura 5.11, estes não parecem apresentar diferenças visíveis em relação

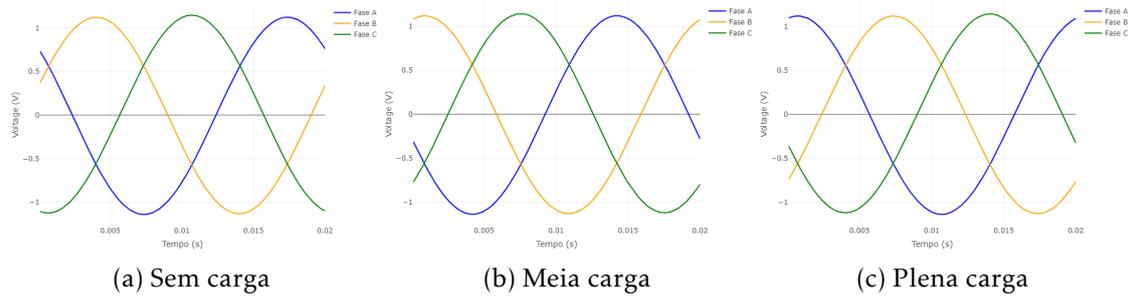


Figura 5.9: Tensões elétricas do motor com todas as cargas com um rolamento avariado (defeito de 4 mm)

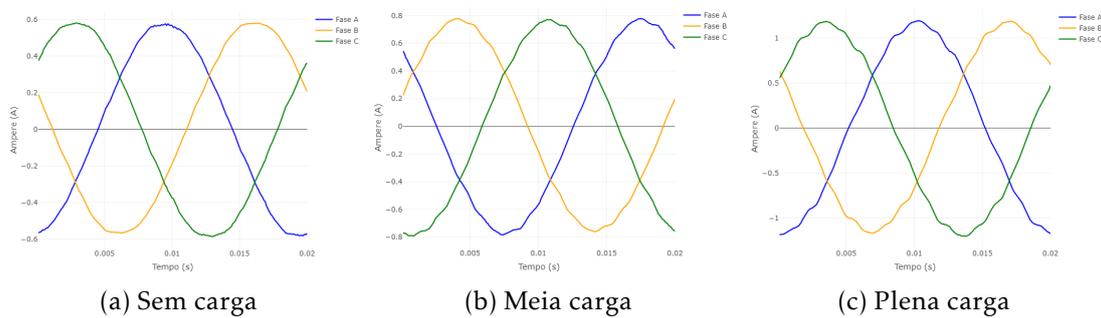


Figura 5.10: Correntes elétricas do motor com todas as cargas com um rolamento saudável

aos ciclos com rolamento saudável. A comparação entre um ciclo de correntes elétricas de ambos os estados do rolamento da Figura 5.12 ilustra o elevado grau de semelhança entre as mesmas e consequente dificuldade de distinção, sendo perceptível a complexidade de identificação de características distintas.

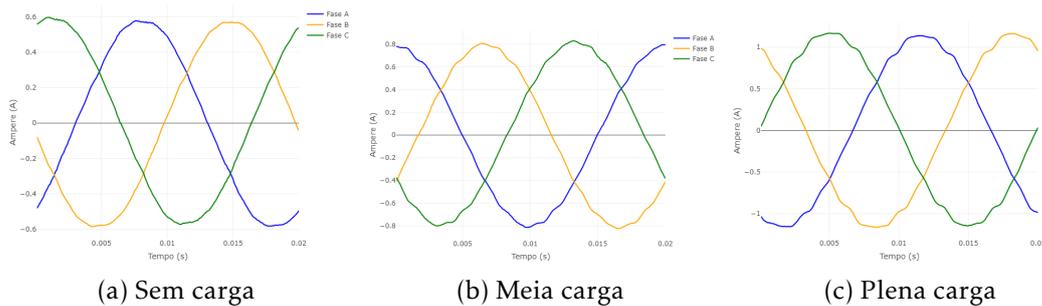


Figura 5.11: Correntes elétricas do motor com todas as cargas com um rolamento avariado (defeito de 1 mm)

Em relação aos ciclos de correntes elétricas com um rolamento avariado com um defeito de 2 mm (ilustrados na Figura 5.13), estes aparentam manter características semelhantes às observadas nos ciclos de correntes elétricas com o rolamento com um defeito de 1 mm sendo que, com a severidade de um defeito de 4 mm, estas não se mantêm. Neste último caso, como é possível observar na Figura 5.14, as correntes elétricas começam inclusivamente a demonstrar a presença de um desequilíbrio entre as mesmas,

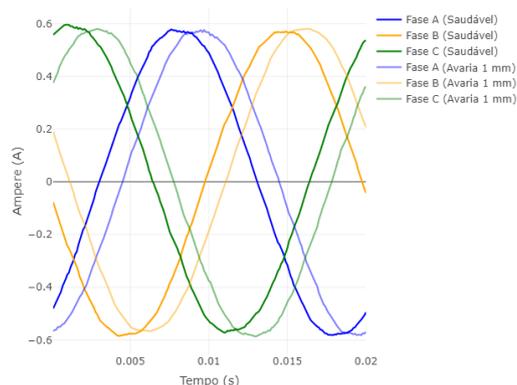


Figura 5.12: Comparação entre as correntes elétricas do motor sem carga com um rolamento saudável e com um rolamento avariado (defeito de 1 mm)

independentemente da carga do motor.

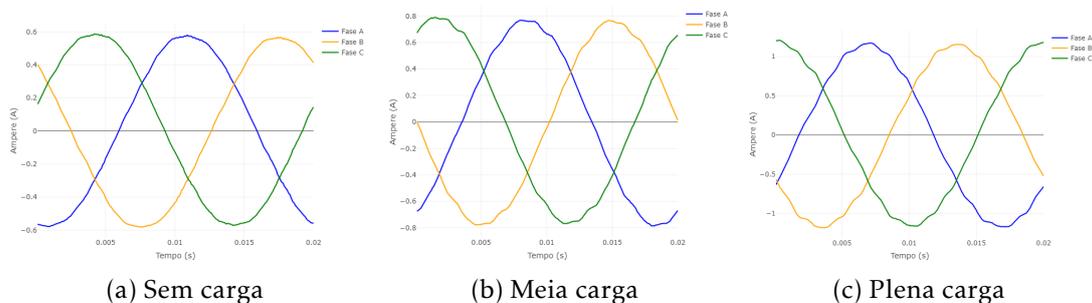


Figura 5.13: Correntes elétricas do motor com todas as cargas com um rolamento avariado (defeito de 2 mm)

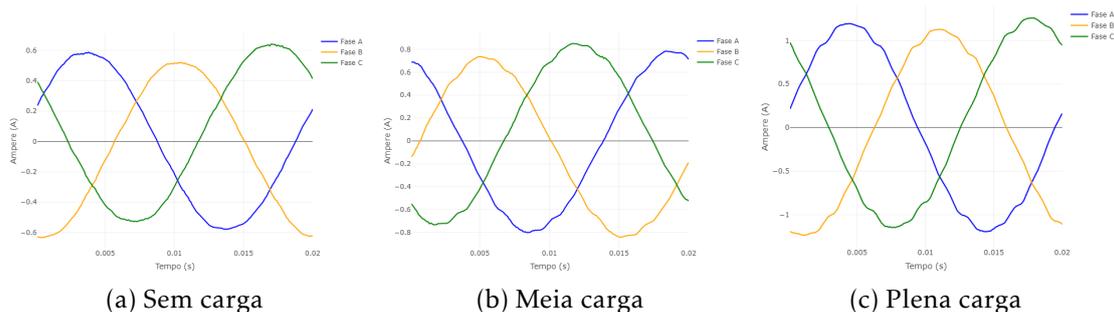


Figura 5.14: Correntes elétricas do motor com todas as cargas com um rolamento avariado (defeito de 4 mm)

A distribuição da magnitude de cada ciclo de correntes (RMS) ilustrada na Figura 5.15 demonstra que a magnitude das correntes não é influenciada pelo estado de avaria do rolamento, estando apenas diretamente relacionada com a carga do motor (a zona correspondente a cada uma das cargas está assinalada na figura).

Em relação aos registos da vibração, as Figuras 5.16 e 5.17 mostram um fragmento de 1 segundo das mesmas em todos os estados de avaria com todas as cargas do motor

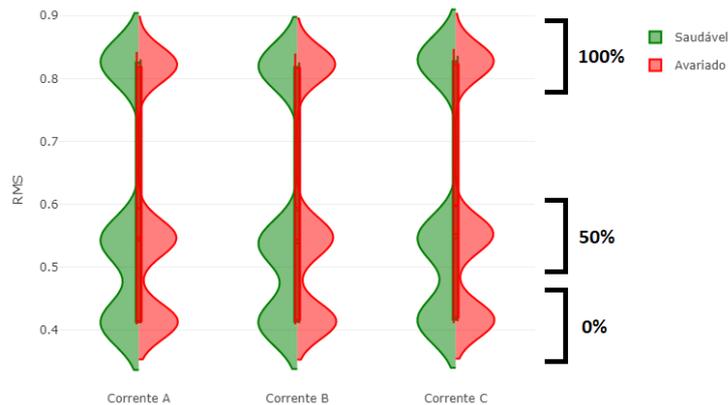


Figura 5.15: Distribuição da magnitude das correntes elétricas do *dataset* optisigma

do *dataset* optisigma, sendo possível observar valores pico de vibração bastante distintos entre o estado saudável e os 3 estados de avaria (o escopo do eixo das ordenadas varia entre figuras com diferentes intensidades da avaria no rolamento de forma a facilitar a visualização). Apesar de se verificar esta distinção entre valores pico para cada estado de avaria do rolamento nestes períodos de observação, é importante notar também a existência de diversos instantes em que os valores são semelhantes.

No caso do rolamento saudável, observando a Figura 5.16a, verifica-se uma tendência para os valores de vibração serem inferiores quando o motor se encontra com meia carga quando comparados com as restantes cargas do motor estudadas. Com o aumento do diâmetro da avaria no rolamento constata-se, no entanto, uma tendência para a dissipação da distinção entre cargas do motor verificada com um rolamento saudável, passando a ser registados valores de vibração semelhantes independentemente da carga do motor (como é possível observar na Figura 5.17 e, em detalhe, na Figura 5.18).

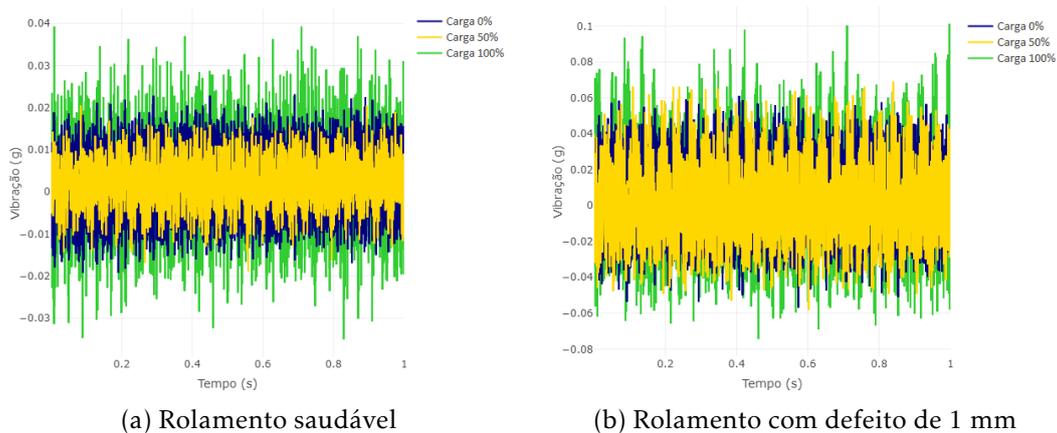


Figura 5.16: Vibração do motor com todas as cargas com o rolamento saudável e avariado com defeito de 1 mm (*dataset* optisigma)

Ao analisar a média do módulo da vibração e o desvio padrão para cada um dos estados do *dataset* optisigma (foi calculada a média do módulo dado que a média dum

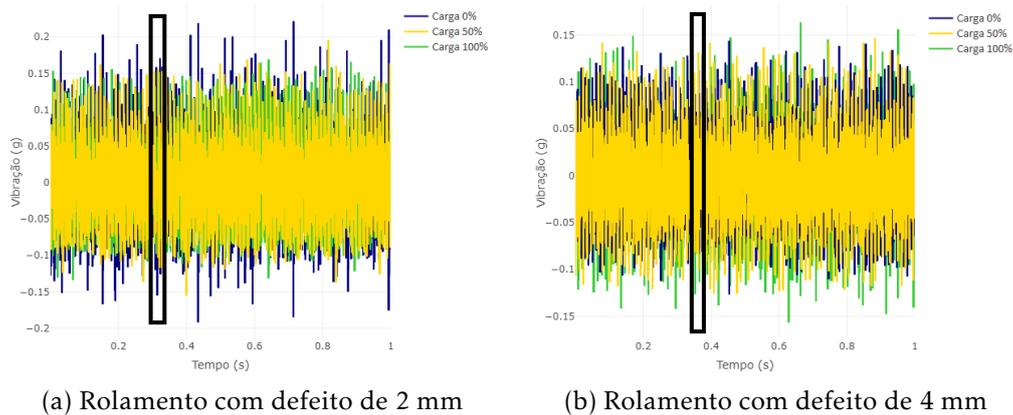


Figura 5.17: Vibração do motor com todas as cargas com os rolamentos avariados com defeitos de 2 mm e 4 mm (*dataset optisigma*)

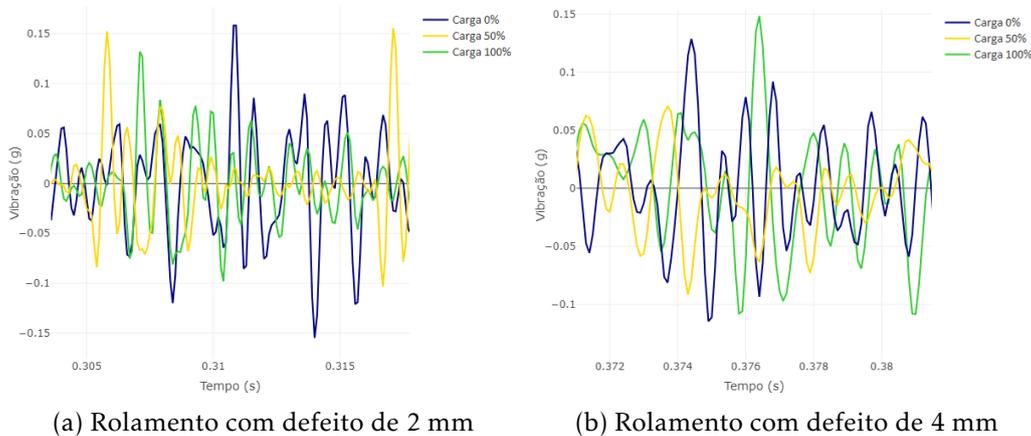


Figura 5.18: Visualização aproximada da vibração do motor com todas as cargas com os rolamentos avariados com defeitos de 2 mm e 4 mm (*dataset optisigma*)

grandeza física da natureza da aceleração radial de um ME tenderá sempre para 0) na tabela da Figura 5.19, é possível confirmar o indiciado na observação das Figuras 5.16 e 5.17. A nível da média obtida é possível verificar uma clara distinção em termos de valores entre o estado saudável e avariado, sendo também observável um aumento da vibração consoante o aumento do diâmetro do defeito (a partir do momento em que o diâmetro do defeito é de 2 mm esse aumento aparenta estagnar). O desvio padrão dos estados de avaria também é superior quando comparado ao estado saudável, sendo possível observar que, para cada uma das situações registadas, o desvio padrão da meia carga é sempre inferior ao obtido sem carga e em plena carga.

Nos valores de vibração registados com o rolamento saudável no *dataset CWRU*, da Figura 5.20 (em detalhe na Figura 5.21), é possível observar que são registados valores um pouco inferiores mas semelhantes ao registados no *dataset optisigma*. Tal como observado previamente, verifica-se a tendência dos valores mais elevados de aceleração serem registados com os valores mínimos e máximos da carga do motor (com principal destaque para

Carga (%)	Diâmetro (mm)	Média do módulo	Desvio Padrão
0	0	0,0062	0,0045
	1	0,0158	0,0112
	2	0,0368	0,0293
	4	0,0317	0,0259
50	0	0,0046	0,0003
	1	0,0151	0,0012
	2	0,0325	0,0029
	4	0,0296	0,0026
100	0	0,0087	0,0065
	1	0,021	0,0158
	2	0,031	0,0274
	4	0,0321	0,0259

Figura 5.19: Análise estatística (média do módulo e desvio padrão) dos registos de vibração do *dataset* optisigma com uma frequência de amostragem de 10 kHz

os valores registados sem carga onde a média obtida foi, praticamente em todos os casos de avaria, superior aos valores registados com as restantes cargas), sendo que os valores registados com cargas de 50% são, geralmente, inferiores aos restantes (o escopo do eixo das ordenadas das Figuras 5.20, 5.22, 5.23 e 5.24 varia para diferentes intensidades do defeito do rolamento de forma a facilitar a visualização).

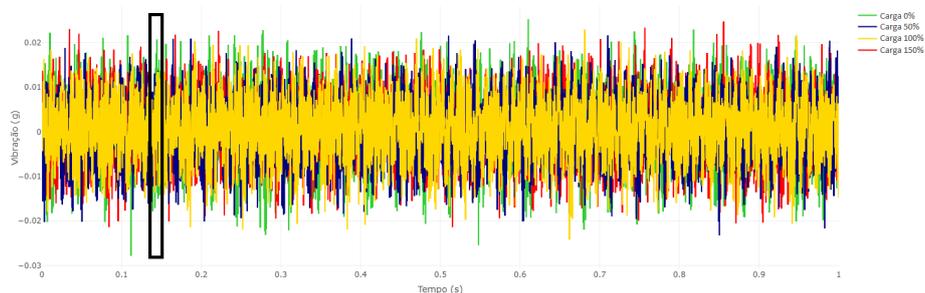


Figura 5.20: Vibração do motor com todas as cargas com um rolamento saudável (*dataset* CWRU)

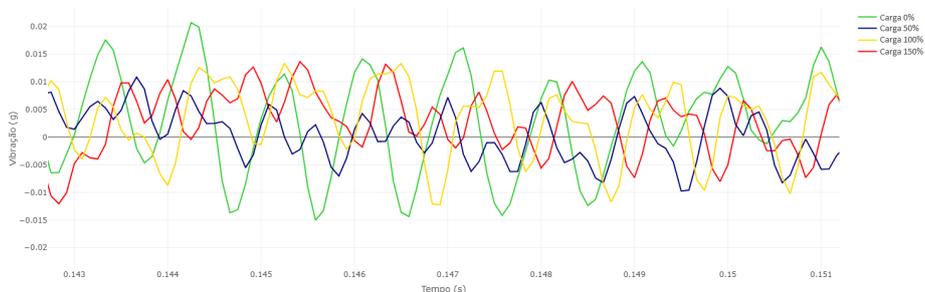


Figura 5.21: Visualização aproximada da vibração do motor com todas as cargas com um rolamento saudável (*dataset* CWRU)

Ao observar as Figuras 5.22, 5.23 e 5.24 é possível comprovar que os valores registados apresentam um comportamento ligeiramente diferente do observado no *dataset* optisigma.

Nas Figuras 5.22a, 5.23b e 5.22c, por exemplo, apesar de grande parte do sinal registar valores da mesma ordem dos observados no *dataset* optisigma, existe uma enorme variação de valores registados onde é possível comprovar a existência de picos de aceleração muito elevados quando comparados com a média observada, cenário que não foi observado no *dataset* optisigma. O facto de ter sido utilizado um *setup* experimental diferente no registo de ambos os *datasets* dificulta uma identificação da causa para a diferença observada, sendo que a mesma poderá estar simplesmente relacionada com terem sido utilizados motores e rolamentos diferentes, como também com o facto de terem sido utilizados sensores diferentes com posicionamentos distintos.

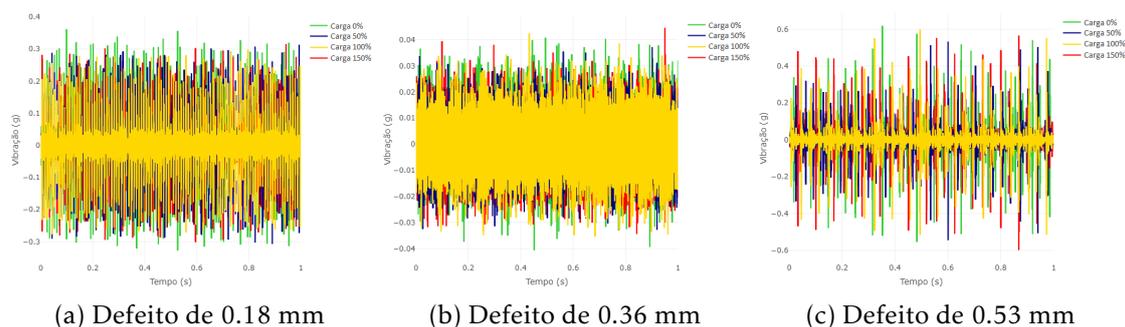


Figura 5.22: Vibração do motor com todas as cargas com rolamentos com defeitos na pista externa (*dataset* CWRU)

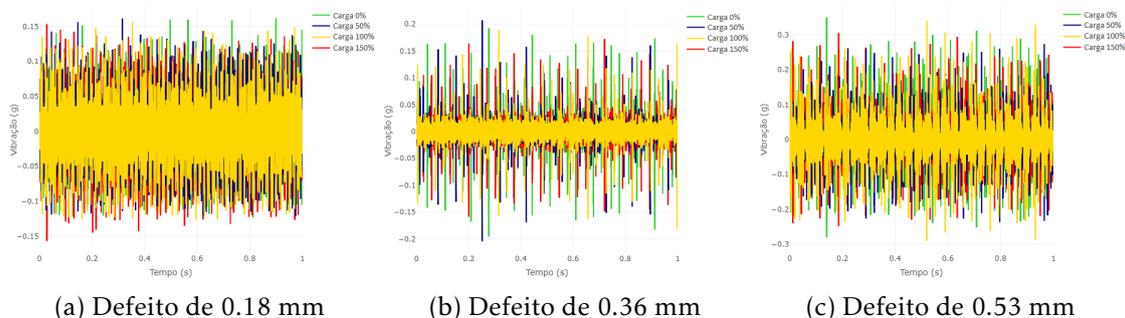


Figura 5.23: Vibração do motor com todas as cargas com rolamentos com defeitos na pista interna (*dataset* CWRU)

Ao focar apenas no *dataset* CWRU e analisar os valores de vibração observados nas figuras, observa-se a existência de uma diferença clara entre estado saudável e avariado, sendo a mesma verificável na Tabela 5.9 que não discrimina a média do módulo e o desvio padrão para cada carga (apresentando apenas a média obtida com todas as cargas) dado que, como previamente mencionado, o efeito da carga do motor nos valores registados foi semelhante ao obtido no *dataset* optisigma da tabela da Figura 5.19 e, desta forma, a consulta desta tabela torna-se mais perceptível. Ao contrário do esperado, a vibração registada com um defeito de 0.36 mm na pista externa apresenta uma média e desvio padrão inferiores aos registados com as dimensões de 0.18 mm e 0.53 mm. No entanto, ao observar as Figuras 5.22, estes valores estão diretamente relacionados com a menor

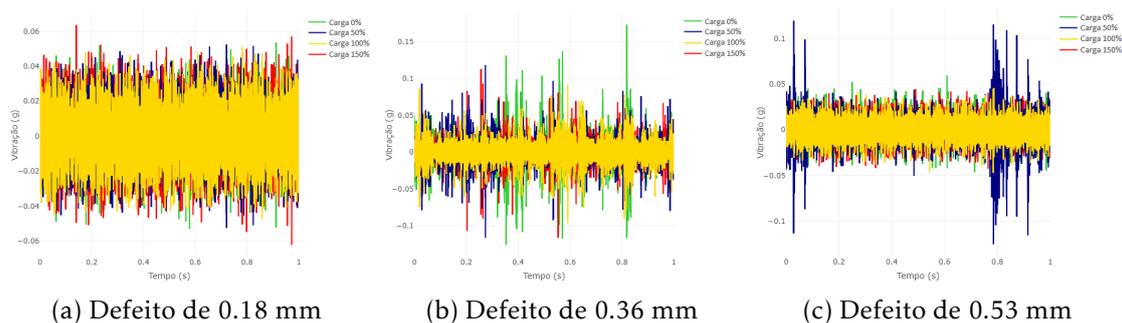


Figura 5.24: Vibração do motor com todas as cargas com rolamentos com defeitos na esfera (*dataset* CWRU)

existência de picos de aceleração, sendo que ao observar as Figuras 5.22a e 5.22c é possível verificar que existe uma elevada concentração da aceleração na mesma ordem de grandeza. O mesmo se verifica para o caso do rolamento com defeito de 0.36 mm na pista interna, que regista menos picos de aceleração que os defeitos de menor e maior diâmetro.

Tabela 5.9: Análise estatística (média do módulo e desvio padrão) dos registos de vibração do *dataset* CWRU

Avaria	Dimensão (mm)	Média do módulo	Desvio Padrão
Saudável	0	0.005575	0.004075
Pista Externa	7	0.037675	0.0486
	14	0.007825	0.005975
	21	0.0287	0.050325
Pista Interna	7	0.0218	0.0214
	14	0.010975	0.0143
	21	0.032825	0.0358
Esfera	7	0.011825	0.00885
	14	0.009975	0.010575
	21	0.009525	0.008025

Em relação aos valores de vibração registados com rolamentos com defeitos na esfera, estes parecem ser relativamente constantes e com médias semelhantes sendo que, em comparação com os restantes estados de avaria, as médias destes são relativamente inferiores às observadas com avarias na pista externa e interna do rolamento. Os picos observados nas Figuras 5.24b e 5.24c não aparentam estar relacionados com a presença de defeitos na esfera do rolamento dado o seu espaçamento e surgimento com uma frequência aleatória.

### 5.1.3 Estudo da Assinatura Espectral das Correntes Elétricas e da Vibração

De forma a avaliar a assinatura espectral das correntes elétricas e da vibração para os diferentes estados de avaria, o espectro de frequências foi computado através da TRF com base nos registos efetuados com uma frequência de amostragem de 10 kHz do *dataset* optisigma, sendo que a utilização da frequência de amostragem mais elevada se justifica

pelo facto da mesma permitir o estudo do maior intervalo de frequências possível (entre os dados disponíveis).

Considerando a alimentação deste *dataset*, o espectro de frequências das correntes elétricas é totalmente dominado pela frequência de 50 Hz, sendo que quando o motor se encontra sem carga, a magnitude desta frequência é sempre ligeiramente inferior a 0.6 A, com o motor com meia carga é ligeiramente inferior a 0.8 A e, em plena carga, é ligeiramente inferior a 1.2 A, independentemente do estado de avaria, pelo que o eixo das ordenadas da visualização dos espectros de frequências das correntes elétricas das Figuras 5.25, 5.26, 5.27 e 5.28 foi limitado ao intervalo de 0 A a 0.02 A de forma a ser possível observar as mínimas alterações registadas. Nas figuras mencionadas é apenas ilustrado o resultado da TRF da fase A das correntes elétricas dados os resultados semelhantes da TRF das fases B e C e a melhoria na visualização que esta opção garante.

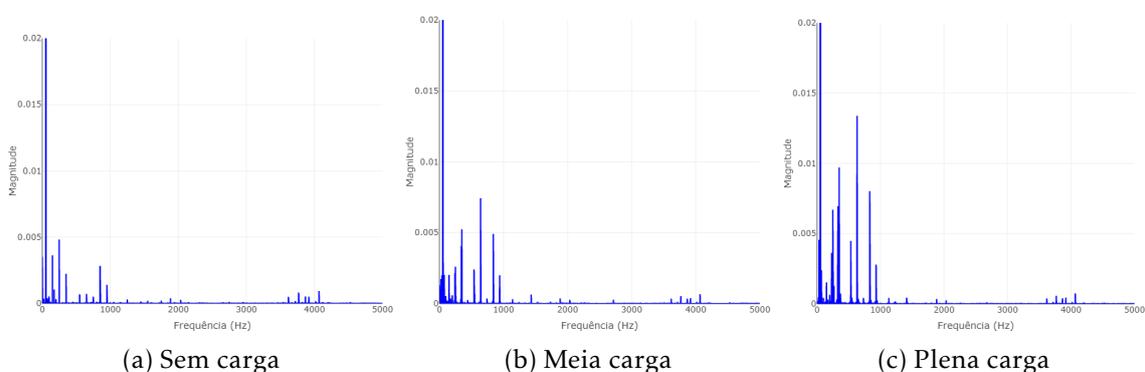


Figura 5.25: Espectro de frequências das correntes elétricas do motor com todas as cargas com um rolamento saudável

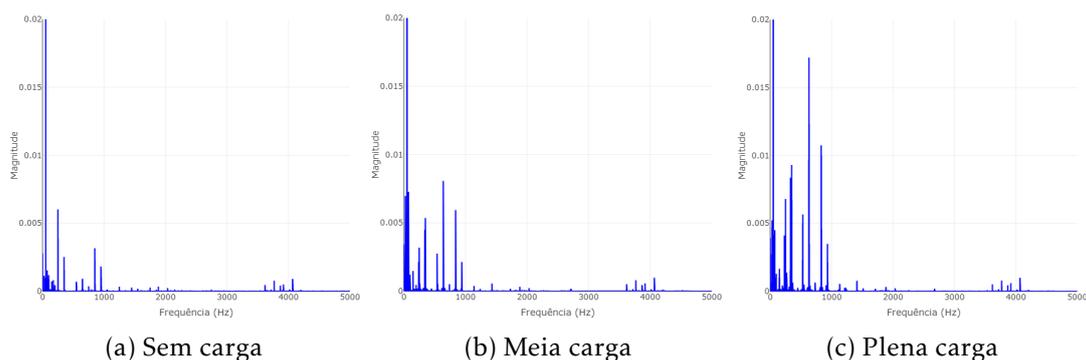


Figura 5.26: Espectro de frequências das correntes elétricas do motor com todas as cargas com um rolamento avariado (defeito de 1 mm)

Analisando o espectro de frequências das correntes elétricas com um rolamento saudável, visível na Figura 5.25, verificamos a existência de picos de frequência de intensidades mínimas quando comparados com a intensidade verificada com a frequência de 50 Hz, sendo que grande parte destes picos de frequência se encontram no intervalo de 0 Hz a cerca de 1000 Hz, com a existência de alguns picos de frequência no intervalo de 1000 Hz

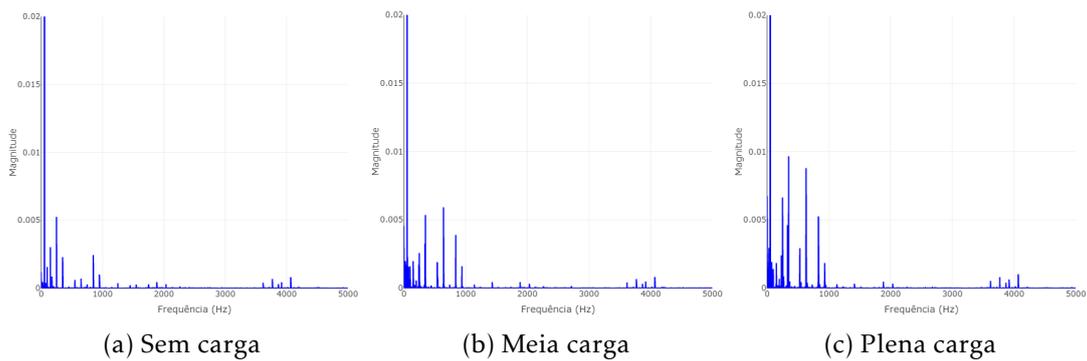


Figura 5.27: Espectro de frequências das correntes elétricas do motor com todas as cargas com um rolamento avariado (defeito de 2 mm)

a cerca de 2000 Hz e à volta dos 4000 Hz. Analisando a variação entre cargas é possível verificar o aumento da intensidade destes picos de frequência correspondente ao aumento da intensidade da carga, sem existir variação da frequência a que ocorrem, sendo que este se verifica em todos os estados de avaria avaliados.

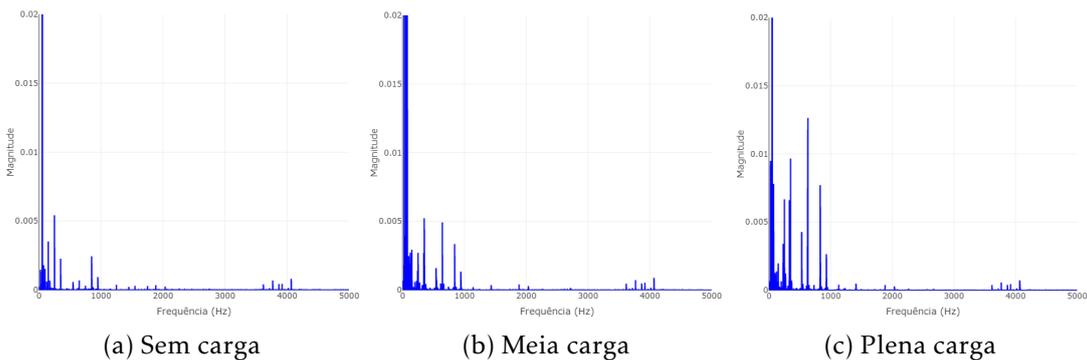


Figura 5.28: Espectro de frequências das correntes elétricas do motor com todas as cargas com um rolamento avariado (defeito de 4 mm)

Em termos de diferenças observáveis entre o estado saudável e avariado estas aparentam ser ligeiras e acontecem principalmente em volta da frequência dominante do sinal (50 Hz). Utilizando o exemplo do espectro de frequências da avaria de diâmetro de 4 mm na Figura 5.28, que corresponde ao que mais manifesta estas alterações, verificamos a existência de um maior número de picos de frequência com maior intensidade na zona previamente mencionada, sendo que nos espectros de frequência dos defeitos de diâmetro inferior das Figuras 5.26 e 5.27 estes efeitos são menos visíveis.

Em relação à vibração, as Figuras 5.29a, 5.29b, 5.30a e 5.30b apresentam, respetivamente, o espectro de frequências entre 0 Hz e 2500 Hz (onde se concentra a maior parte do sinal) da vibração dos estados com rolamento saudável, rolamento com avaria no rolamento com 1 mm de diâmetro, rolamento com avaria no rolamento com 2 mm de diâmetro e rolamento com avaria no rolamento com 4 mm de diâmetro, com as três cargas utilizadas do *dataset* optisigma. Como é possível observar, existe a característica comum

de que a grande maioria do conteúdo espectral se encontra no intervalo de 0 Hz até cerca de 2000 Hz, sendo também exibida uma diferença evidente na intensidade dos picos de frequência entre o estado com rolamento saudável e rolamentos com avarias. Verifica-se, também, uma tendência para haver um aumento no número de picos de frequência com maior intensidade consoante o aumento do diâmetro da avaria, sendo este visível até aproximadamente 1500 Hz.

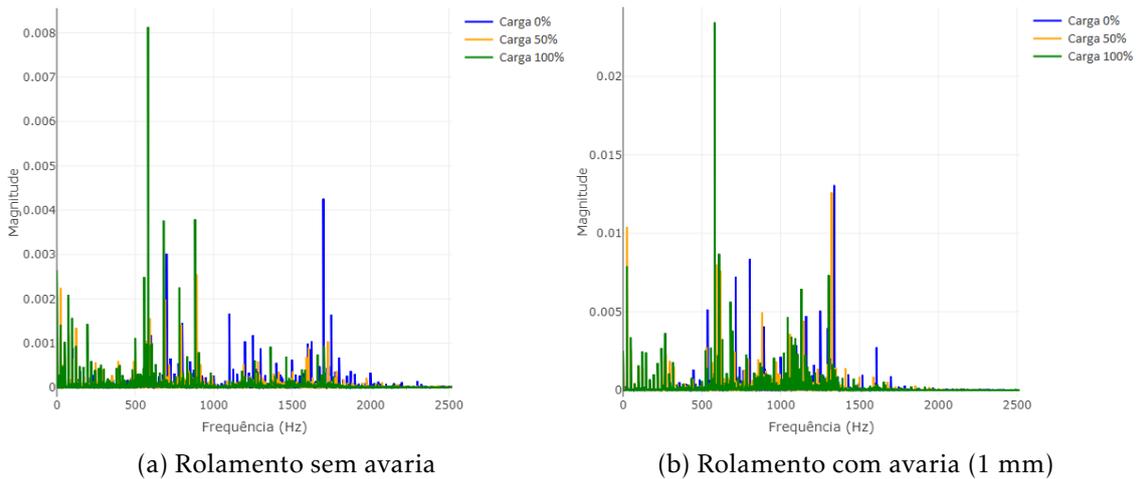


Figura 5.29: Espectro de frequências da vibração do rolamento saudável e do rolamento com avaria de 1 mm de diâmetro na pista externa do *dataset* optisigma

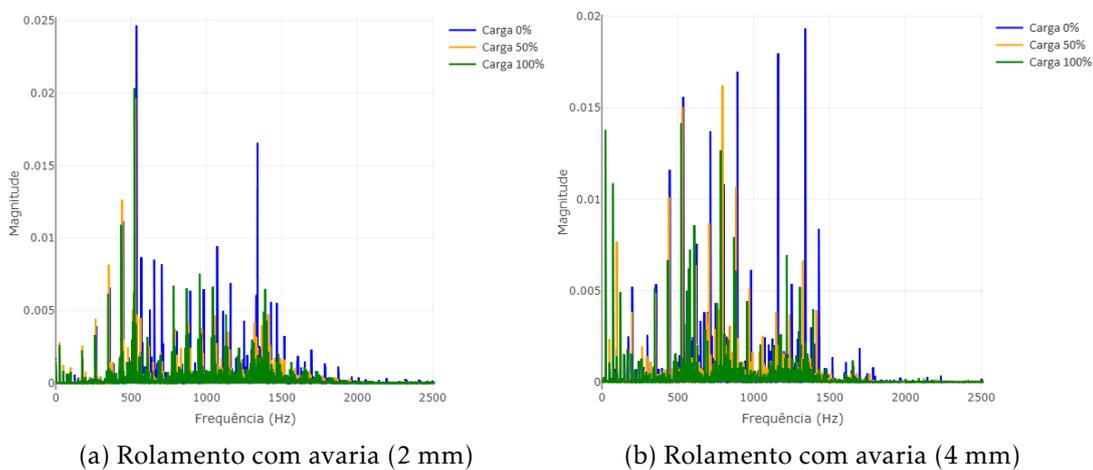


Figura 5.30: Espectro de frequências da vibração dos rolamentos com avarias de 2 mm e 4 mm de diâmetro na pista externa do *dataset* optisigma

Ao observar o espectro de frequência da vibração do rolamento saudável do *dataset* CWRU na Figura 5.31, verifica-se que o intervalo predominante de frequências é de cerca de 0 Hz a 2000 Hz, sendo este semelhante ao observado no mesmo estado saudável do rolamento com o *dataset* optisigma. A nível dos espectros de frequência da vibração com rolamentos avariados das Figuras 5.32, 5.33 e 5.34 observa-se alguma atividade presente no mesmo intervalo de frequências que o estado saudável destacando-se, no

entanto, o surgimento de uma forte componente de frequências a partir de 2000 Hz. Independentemente da localização da avaria, existe uma grande concentração do sinal principalmente no intervalo de frequências entre 2500 Hz e 4000 Hz para qualquer carga do motor.

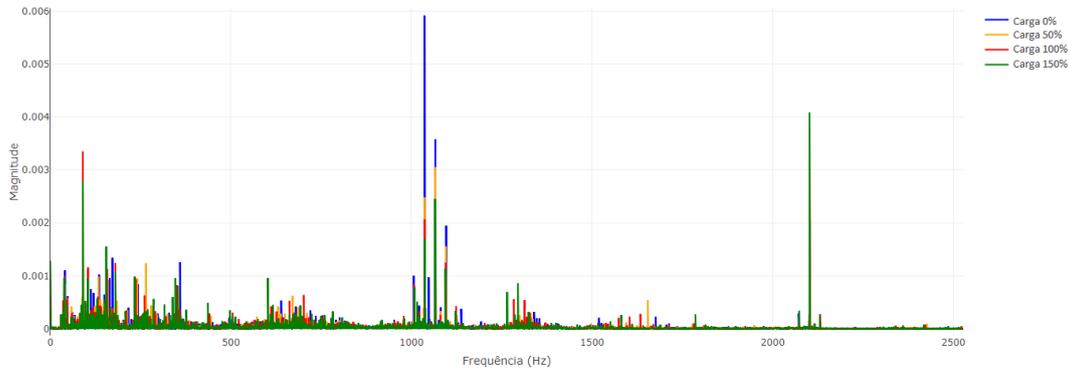


Figura 5.31: Espectro de frequências da vibração do rolamento saudável do *dataset CWRU*

Do ponto de vista teórico seria esperado que o pico de frequência da vibração de um rolamento de 9 esferas com avaria na pista externa fosse, para uma velocidade de rotação do rotor de 1500 rpm ou 25 Hz (*dataset optisigma*), de aproximadamente  $0.4 \times 9 \times 25 = 90\text{Hz}$ , sendo que para uma velocidade de rotação do rotor de 1800 rpm ou 30 Hz (*dataset CWRU*), seria de aproximadamente  $0.4 \times 9 \times 30 = 108\text{Hz}$ . No entanto, como é possível observar nos espectros de frequência de ambos os *datasets*, as frequências destes picos de frequência teóricos têm uma magnitude muitíssimo inferior à dos picos de frequência realmente constatados no espectro de frequência computado, verificando-se apenas a relação de que as avarias no *dataset CWRU* apresentam picos de frequência em frequências mais altas que o *dataset optisigma* dada a velocidade de rotação superior do seu rotor.

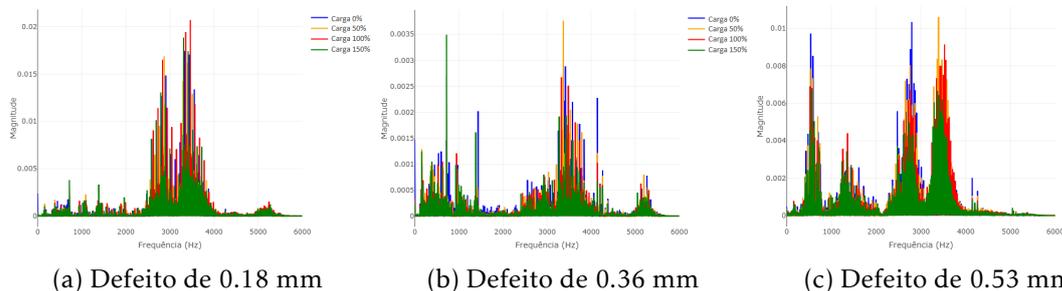


Figura 5.32: Espectro de frequências da vibração dos rolamentos com avarias na pista externa do *dataset CWRU*

Tal como observado nos espectros de frequências do *dataset optisigma*, os espectros de frequências do *dataset CWRU* demonstram um grande potencial de distinção entre o estado saudável e avariado com assinaturas espectrais bastante distintas. Comparando os espectros de frequência das diferentes avarias nas Figuras 5.32, 5.33 e 5.34 verifica-se,

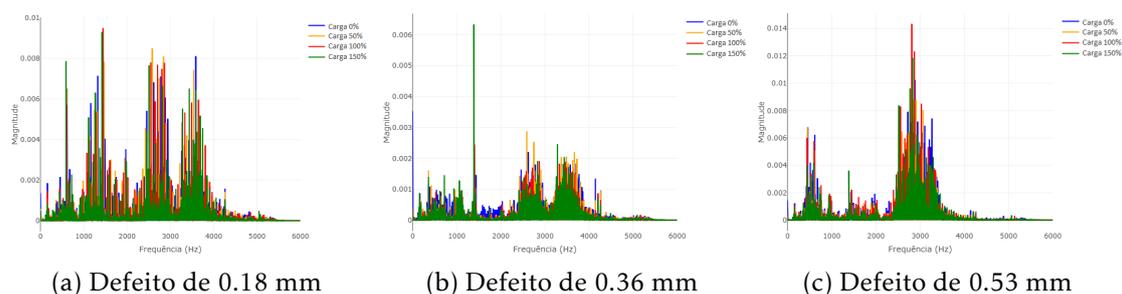


Figura 5.33: Espectro de frequências da vibração dos rolamentos com avarias na pista interna do *dataset* CWRU

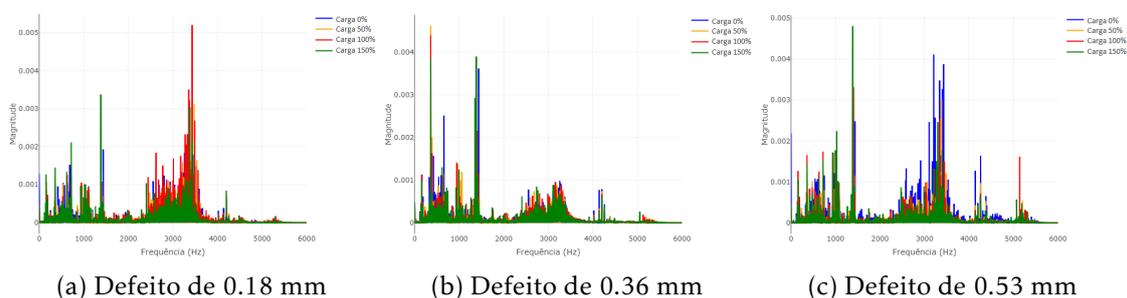


Figura 5.34: Espectro de frequências da vibração dos rolamentos com avarias na esfera do *dataset* CWRU

inclusivamente, a capacidade de diferenciação de cada uma das avarias, possibilitando uma eventual deteção da localização da avaria.

### 5.1.4 Avaliação do Impacto da Frequência de Amostragem no Sinal das Correntes Elétricas e da Vibração

A frequência de amostragem é uma noção muito presente ao longo desta dissertação e é alvo de avaliação no capítulo 6, pelo que o seu impacto é aqui avaliado na amostragem da vibração e das correntes elétricas do *dataset* optisigma. Obviamente que este impacto depende de inúmeras variáveis nomeadamente a nível do motor e seus componentes (como foi possível observar nas diferentes assinaturas espectrais dos *datasets* previamente estudados), sendo que esta comparação permite, no entanto, avaliar o impacto para um caso semelhante ao do *dataset* optisigma, e ter uma ideia geral deste possível impacto no sinal de ambas as grandezas físicas observadas.

A diferença entre uma frequência de amostragem de 0.8 kHz e 10 kHz é facilmente observável no sinal das correntes elétricas na Figura 5.35 (em detalhe na Figura 5.36), onde é visível a perda de algum detalhe registado apenas com a frequência de amostragem de 10 kHz, sendo que comparando dois registos de vibração que representam o mesmo período com duração de 20 ms, com as mesmas frequências de amostragem, na Figura 5.37, as diferenças são incontestáveis e demonstram a omissão de grande parte do sinal da vibração no caso do uso da frequência de amostragem de 0.8 kHz.

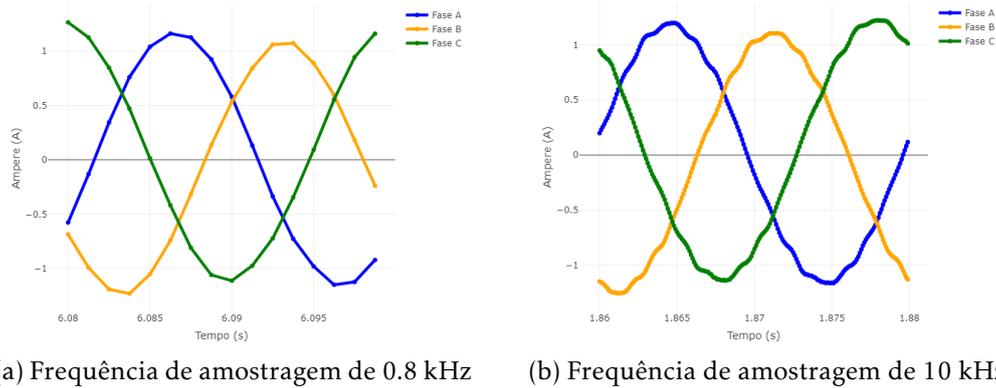


Figura 5.35: Registos de ciclos das correntes de um MITGE com diferentes frequências de amostragem

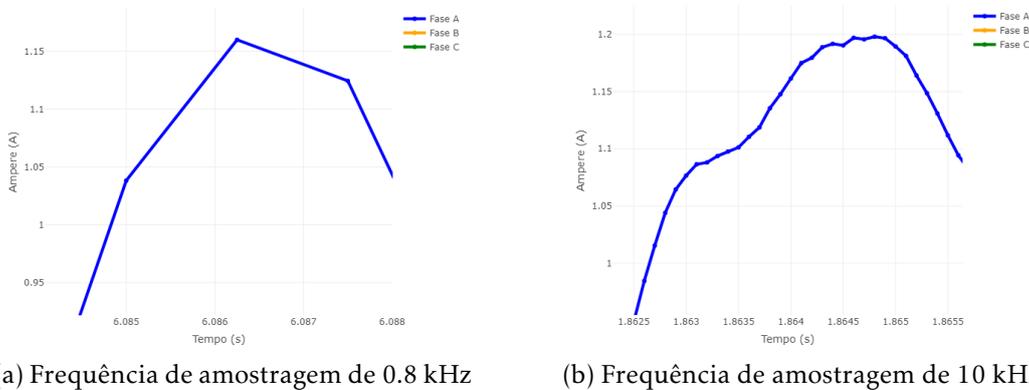
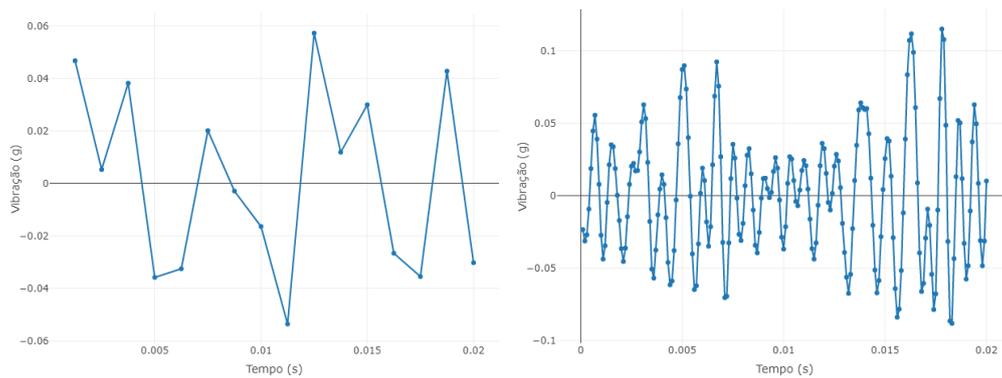


Figura 5.36: Observação aproximada de uma corrente de um MITGE com diferentes frequências de amostragem

À primeira vista, as frequências de amostragem mais baixas parecem refletir uma melhor realidade dos sinais das correntes elétricas quando comparados com o sinal da vibração dada a sua forte presença na frequência de 50 Hz, indiciando um potencial impacto superior no uso das mesmas para o registo e posterior análise da vibração.

No sentido de determinar, em concreto, as possíveis perdas de sinal que frequências de amostragem mais baixas poderão propiciar, foram utilizados os sinais da vibração e das correntes do *dataset* optisigma com uma frequência de amostragem de 10 kHz para computar a percentagem do sinal presente em cada frequência de amostragem utilizando os espectros de frequência resultados da TRF e analisados na secção 5.1.3. Como mencionado previamente, segundo o teorema de Nyquist, uma dada frequência de amostragem permite o estudo de um intervalo de frequências até metade da mesma, ou seja, num sinal com uma frequência de amostragem de 1000 Hz, podem ser estudadas frequências até 500 Hz, pelo que cada uma das frequências de amostragem utilizadas permitem, portanto, o estudo de um intervalo de frequências distinto, sendo que os intervalos estão descritos na Tabela 5.10 para todas as frequências de amostragem disponíveis nos diferentes *datasets*. A percentagem de sinal presente em cada intervalo de frequências foi calculada, para



(a) Frequência de amostragem de 0.8 kHz (b) Frequência de amostragem de 10 kHz

Figura 5.37: Registos da vibração de um MITGE com diferentes frequências de amostragem

cada estado (por exemplo, rolamento saudável e motor sem carga), segundo a equação 5.3, sendo posteriormente calculada a média dos resultados obtidos com todos os estados disponíveis.

$$D_f = \frac{M_f}{\sum_{i=0}^n M_i} \quad (5.3)$$

onde  $M_f$  representa a magnitude da frequência  $f$  e  $D_f$  indica a percentagem do sinal presente na frequência  $f$  considerando todo o espectro de frequências a ser analisado.

Tabela 5.10: Intervalos de frequência avaliados por cada frequência de amostragem segundo o teorema de Nyquist

Frequência de amostragem (Hz)	Intervalo de frequências (Hz)
800	0-400
1000	0-500
2000	0-1000
5000	0-2500
10000	0-5000
12000	0-6000

Como previamente indiciado na comparação da visualização de um curto intervalo de tempo de um registo de vibração com duas frequências de amostragem distintas, a Figura 5.38a possibilita verificar que, a nível da vibração, existe uma perda muito significativa de sinal com frequências de amostragem iguais ou inferiores a 2 kHz. Com uma frequência de amostragem de 1 kHz, ou inferior, é perdido cerca de 90% do sinal, sendo que com uma frequência de amostragem de 2 kHz a perda é diminuída para cerca de 60%, continuando a ser muito relevante. A frequência de amostragem de 5 kHz possibilita a captação de cerca de 90% do sinal captado com o dobro da frequência de amostragem (10 kHz). A nível das correntes, dada a natureza do sinal, as perdas dos sinais não são da mesma intensidade que as da vibração como é possível observar na Figura 5.38b, sendo que as frequências de amostragem até 1 kHz perdem cerca de 35% do sinal, a frequência

de amostragem de 2 kHz remete para uma perda na ordem dos 25% e a frequência de amostragem de 5 kHz para uma perda de sensivelmente 15%.

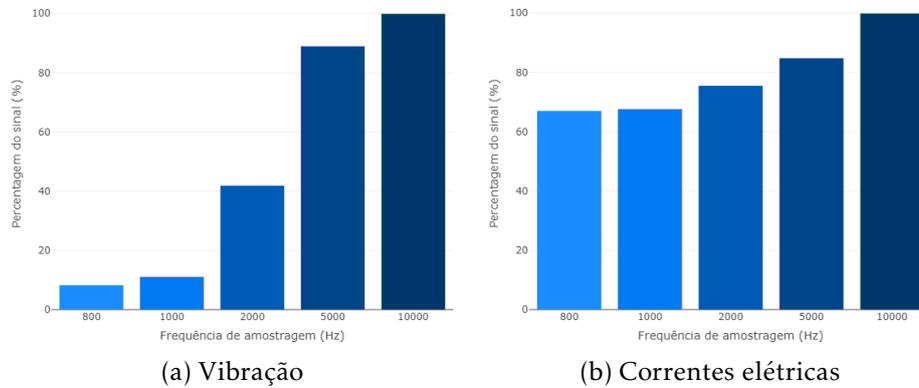


Figura 5.38: Percentagem do sinal presente no intervalo Nyquist de cada frequência de amostragem

Comparando a percentagem de sinal presente nas diferentes frequências de amostragem em ambas as grandezas físicas é possível confirmar que, até cerca de 2 kHz (inclusive), as correntes parecem ser descritas de forma muito mais fidedigna quando comparadas com a vibração. Para as frequências até 1 kHz a diferença é notória, onde as correntes descrevem uma percentagem cerca de 6 vezes maior à da vibração, sendo que com uma frequência de amostragem de 2 kHz as correntes descrevem cerca do dobro da percentagem. A partir de 5 kHz os resultados são semelhantes.

## 5.2 Preparação dos Dados

A fase da preparação dos dados da metodologia **CRISP-DM** envolve a seleção das variáveis a ser utilizadas na fase de modelação, pelo que nesta secção são detalhadamente descritas as diversas análises realizadas aos *datasets* previamente abordados na secção 5.1, sendo avaliado o seu potencial em relação à classificação do estado de avaria do rolamento.

Os *datasets* utilizados contêm registos de valores de diferentes grandezas físicas ao longo do tempo, sendo que para poder ser feita a sua análise em contexto de **AA** estes registos são particionados em períodos com uma determinada duração e avaliados individualmente. A Figura 5.39 exemplifica o funcionamento destas partições onde de um registo de vibração com duração de 20s resultam 1000 períodos de 20ms.

Todas as figuras presentes em ilustrações de análises das secções seguintes são resultantes da avaliação do *dataset* optisigma com a frequência de amostragem de 10 kHz dado ser o que, de entre as frequências de amostragem disponíveis, melhor reflete a realidade de ambas as grandezas físicas analisadas, sendo que o tempo de análise considerado para avaliar a distribuição das variáveis foi de 20 ms (um ciclo de correntes) como a Figura 5.40 ilustra.

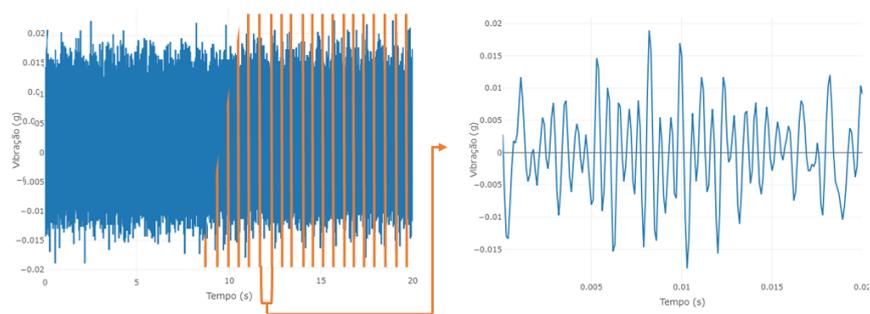


Figura 5.39: Exemplo de particionamento de um registo da vibração

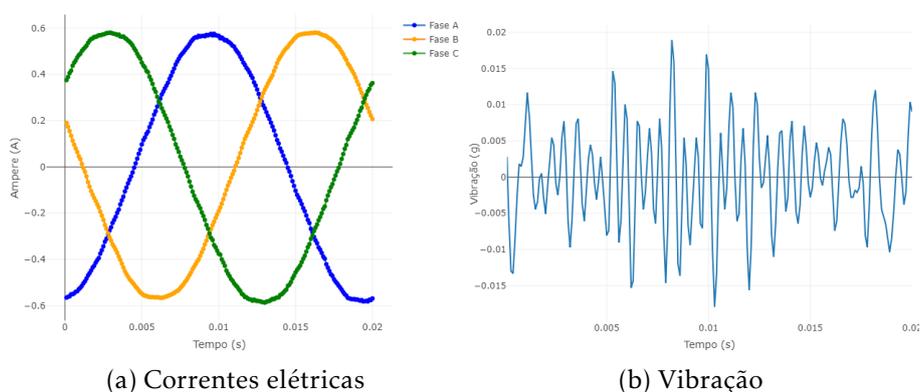


Figura 5.40: Exemplo de um registo de 20 ms de correntes elétricas e vibração

As análises realizadas sobre a vibração encontram-se descritas nas secções 5.2.1 e 5.2.2, e as análises sobre as correntes elétricas nas secções 5.2.3, 5.2.4 e 5.2.5.

### 5.2.1 Análise Estatística da Vibração e da Amplitude Instantânea da Transformada de Hilbert da Vibração no Domínio Temporal

Foram observados, no estado da arte do capítulo 4, resultados interessantes alcançados por outros autores na deteção de avaria nos rolamentos usando a análise estatística da vibração no domínio temporal para o processo de extração de *features* e respetiva utilização de técnicas de AA. Neste sentido, esta análise estatística foi avaliada tendo sido realizada em duas variações distintas: diretamente sobre o registo da vibração (como observado na secção 4.3.1) e sobre a amplitude instantânea da TH da vibração (transformada observada na secção 4.3.3 num contexto de análise espectral), estando ambas as variações ilustradas na Figura 5.41.

Em relação à análise estatística da vibração, o cálculo da média e da mediana é realizado sobre o módulo da mesma dada a natureza do movimento de aceleração radial do motor e conseqüente tendência para registar valores próximos de 0, sendo o valor máximo do módulo também calculado. Diretamente sobre a vibração é feito o cálculo do RMS, da variância, do desvio padrão, do valor máximo, do valor mínimo, da amplitude, da assimetria, da curtose e do o fator *crest* definido como

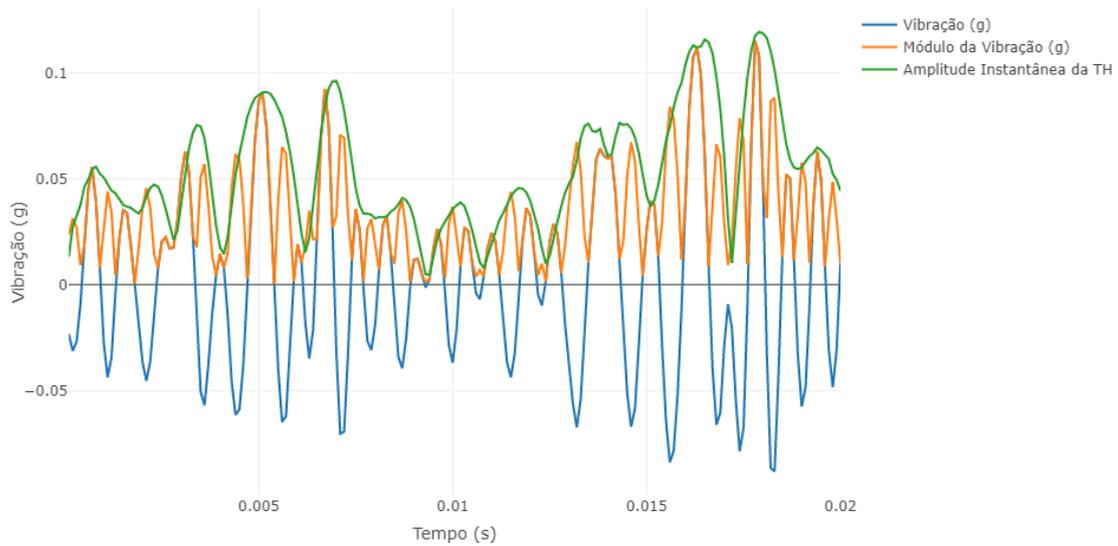


Figura 5.41: Exemplo de visualização da vibração, módulo da vibração e amplitude instantânea da Transformada de Hilbert da vibração

$$\text{Fator } crest = \frac{\max(mod(s))}{RMS(s)} \quad (5.4)$$

onde  $\max(mod(s))$  representa o valor máximo do módulo da aceleração da vibração.

Para a análise estatística da amplitude instantânea da TH foram avaliados os mesmos cálculos estatísticos exceto o máximo do módulo (que seria igual ao valor máximo) e o fator *crest*.

Analisando a distribuição do cálculo estatístico do RMS, média do módulo e mediana do módulo observada na Figura 5.42 (ilustrada através de gráficos violino), é possível verificar que todas estas *features* apresentam informação com valor no que toca à discriminação do estado de avaria do rolamento. Analisando as figuras e a *box* presente nas mesmas verificamos que a maioria das amostras de cada estado de avaria é discriminada por cada uma destas variáveis existindo, no entanto, amostras em que os resultados obtidos foram semelhantes para o estado saudável e avariado do rolamento (na zona em volta dos 0.013 g para o RMS, 0.012 g para a média e 0.01 g para a mediana).

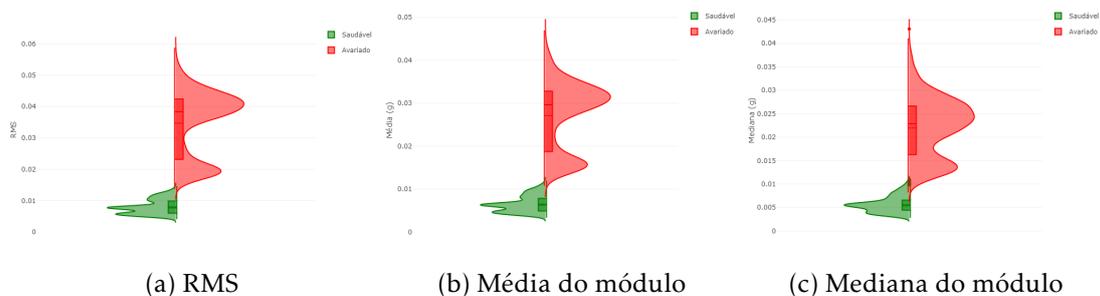


Figura 5.42: Distribuição do cálculo estatístico do RMS, média do módulo e mediana do módulo sobre a vibração para os estados saudável e avariado do rolamento

O valor máximo e mínimo da vibração, a amplitude, o desvio padrão e a variância, cujas distribuições de resultados se encontram descritas nas Figuras 5.43 e 5.44, apresentam resultados semelhantes às variáveis previamente analisadas, sendo que a zona de confusão aparenta ser ligeiramente superior no caso do valor máximo e mínimo. Para o valor máximo foram registados valores semelhantes na zona dos 0.03 g, -0.03 g para o valor mínimo, 0.06 g para a amplitude, 0.013 g para o desvio padrão e 0.0002 g para a variância.



Figura 5.43: Distribuição do cálculo estatístico do valor máximo, valor mínimo e amplitude sobre a vibração para os estados saudável e avariado do rolamento

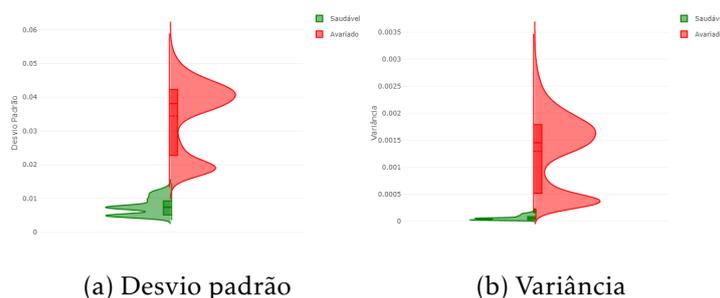


Figura 5.44: Distribuição do cálculo estatístico do desvio padrão e variância sobre a vibração para os estados saudável e avariado do rolamento

A curtose e a assimetria não apresentam o mesmo poder discriminativo previamente observado com outras estatísticas, registando a existência de uma zona de confusão relativamente superior. De qualquer forma é possível observar que a média e mediana dos valores da curtose e da assimetria com o rolamento avariado são superiores às registada com um rolamento saudável, sendo também possível observar zonas completamente discriminativas.

O fator *crest* apresenta resultados semelhantes aos obtidos com o cálculo da curtose e da assimetria, em termos da discriminação do estado de avaria do rolamento. Por outro lado, o valor máximo do módulo é bastante discriminativo registando apenas uma pequena zona de confusão em torno de 0.03 g.

A maior parte das estatísticas apresentam um poder discriminativo semelhante quando realizados sobre a amplitude instantânea da TH, mostrando bastante potencial na discriminação do estado de avaria como é possível observar na Figura 5.47 que ilustra a

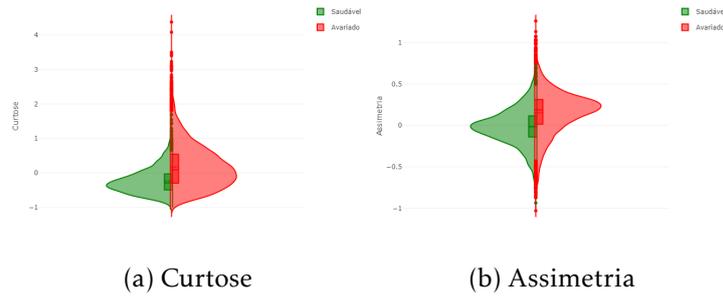


Figura 5.45: Distribuição do cálculo estatístico da curtose e assimetria sobre a vibração para os estados saudável e avariado do rolamento

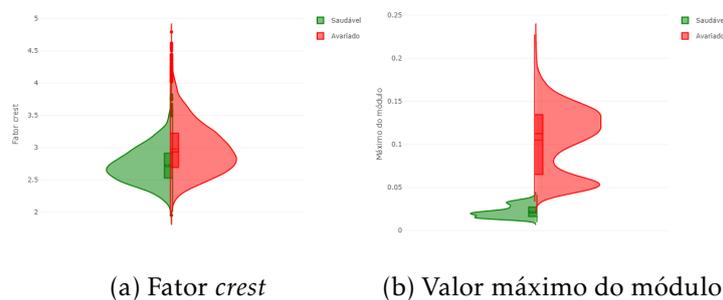


Figura 5.46: Distribuição do cálculo estatístico do fator *crest* e valor máximo do módulo sobre a vibração para os estados saudável e avariado do rolamento

distribuição de resultados obtidos para o cálculo do **RMS**, da média e da mediana.

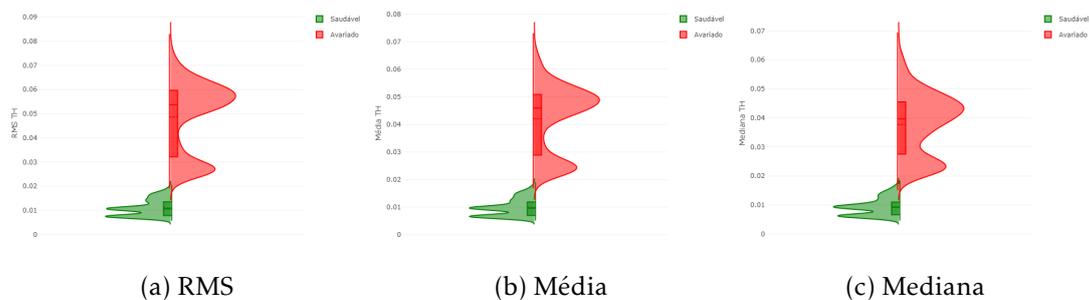


Figura 5.47: Distribuição do cálculo estatístico do **RMS**, média e mediana sobre a amplitude instantânea da Transformada de Hilbert da vibração para os estados saudável e avariado do rolamento

Todos os restantes cálculos estatísticos, exceto o valor mínimo e a variância, apresentam um valor discriminativo semelhante ao observado na análise realizada diretamente sobre a vibração. No caso do valor mínimo e da variância, dada a natureza da amplitude instantânea da TH, observa-se um claro aumento da zona de valores comuns a ambos os estados do motor e uma consequente diminuição da discriminação oferecida por estes cálculos estatísticos quando comparados com os cálculos realizados diretamente da vibração.

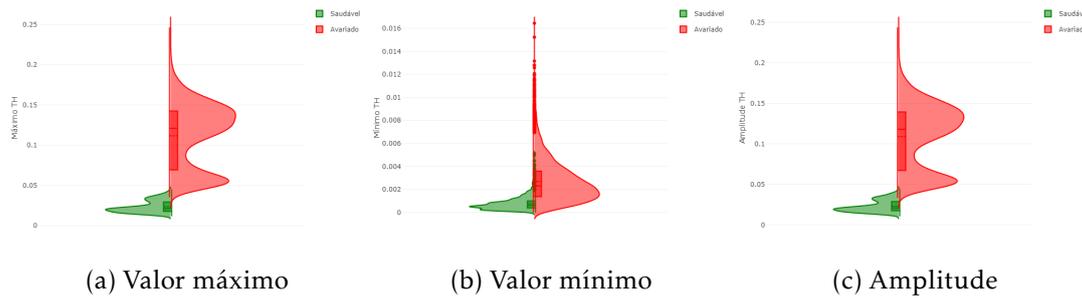


Figura 5.48: Distribuição do cálculo estatístico do valor máximo, valor mínimo e amplitude sobre a amplitude instantânea da Transformada de Hilbert da vibração para os estados saudável e avariado do rolamento

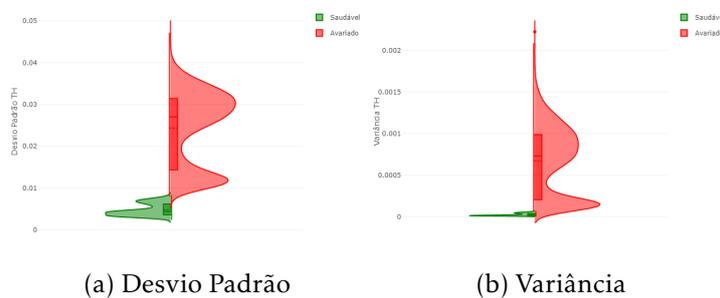


Figura 5.49: Distribuição do cálculo estatístico do desvio padrão e variância sobre a amplitude instantânea da Transformada de Hilbert da vibração para os estados saudável e avariado do rolamento

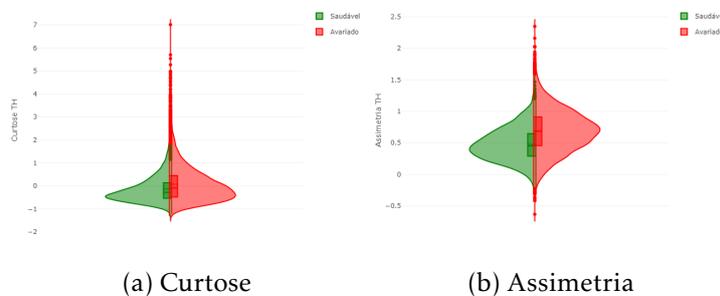


Figura 5.50: Distribuição do cálculo estatístico da curtose e assimetria sobre a amplitude instantânea da Transformada de Hilbert da vibração para os estados saudável e avariado do rolamento

As relações entre estado avariado e estado saudável para os cálculos estatísticos realizados diretamente sobre a vibração e sobre a amplitude instantânea da TH da vibração apresentam comportamentos muito semelhantes quando observadas sobre o *dataset* CWRU pelo que, de forma a evitar redundância, as mesmas foram omitidas.

Para os casos das frequências de amostragem inferiores a 10 kHz do *dataset* optisigma basicamente observa-se um aumento da zona de valores comuns a ambos os estados do rolamento equivalente à diminuição da frequência de amostragem continuando, no entanto, a ser visível o potencial de discriminação do estado do motor.

### 5.2.2 Análise do Espectro Vibracional Resultante da Transformada Rápida de Fourier

A análise da vibração no domínio das frequências é um método habitualmente utilizado na deteção de avarias nos rolamentos, sendo que este mostrou bons resultados em contexto de AA, na secção 4.3.2 do estado da arte, ao analisar o conteúdo do espectro de frequências próximo das frequências características de avaria.

De forma a realizar esta análise, o sinal da vibração foi convertido do domínio temporal para o domínio da frequência com recurso à TRF, oferecendo uma perspetiva diferente do mesmo registo de vibração ao isolar o sinal por frequências.

Ao observar a Figura 5.51, que ilustra o espectro de frequências da vibração observada com um rolamento saudável e com um rolamento avariado, é possível verificar que a assinatura espectral de ambos os casos difere bastante tanto a nível da magnitude dos picos de frequência, como a nível das frequências a que os picos são registado e do número de picos de frequência com elevada magnitude. Neste sentido, e considerando as diferentes características verificadas, foram avaliadas *features* que pudessem refletir estas diferenças no domínio espectral pelo que, basicamente, de cada pico de frequência foram consideradas a própria frequência a que o pico de frequência foi registado, a sua magnitude e a sua densidade espectral (não deve ser confundida com a densidade espectral de energia ou de potência) definida como

$$D_f = \frac{M_f}{\sum_{i=0}^n M_i} \quad (5.5)$$

onde  $M_f$  representa a magnitude da frequência  $f$  e  $D_f$  indica a percentagem do sinal presente na frequência  $f$  considerando todo o espectro de frequências a ser analisado.

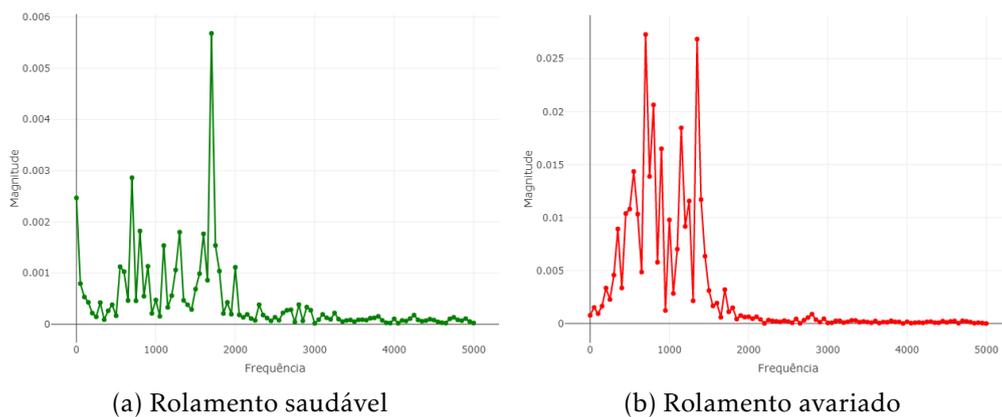


Figura 5.51: Exemplo de visualização de um espectro de frequências resultante da análise de um período de 20 ms de vibração de um rolamento saudável e avariado

Observando a distribuição dos quatro maiores picos de frequência e da magnitude desses picos na Figura 5.52 (é ilustrada a distribuição de apenas quatro picos por motivos de espaço) é possível verificar que, a nível das frequências a que os picos de frequência são observados, a distribuição registada com os rolamentos avariados está maioritariamente

presente no intervalo entre 500 Hz e 1500 Hz sendo que, com um rolamento saudável, esta é bastante mais inconstante e, com exceção do segundo pico de frequência, raramente apresenta uma frequência constante. A magnitude dos picos de frequência varia bastante consoante o estado de avaria, sendo claramente mais elevada com um rolamento avariado e apresentando um relativo baixo número de instâncias de ambos os estados do rolamento com o mesmo valor.

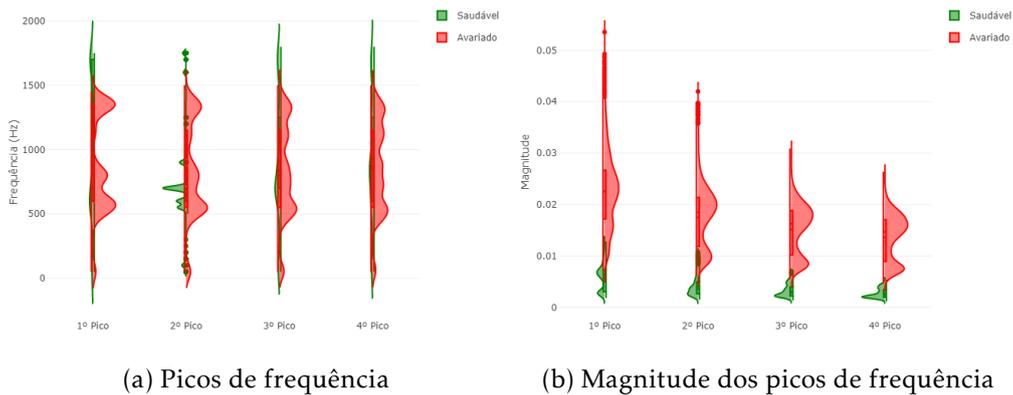


Figura 5.52: Distribuição dos quatro maiores picos de frequência e magnitude dos picos de frequência observados no domínio espectral da vibração para os estados saudável e avariado do rolamento

A nível da distribuição da densidade espectral dos quatro maiores picos de frequência observada na Figura 5.53 parece não existir uma clara distinção entre o estado saudável e avariado para os primeiros picos de frequência, mas uma tendência para o estado avariado apresentar uma densidade espectral superior à do estado saudável à medida que é observado o pico de frequência inferior, ou seja, por exemplo, o 3º pico de frequência do estado avariado apresenta uma densidade espectral superior à do estado saudável e essa diferença entre estado saudável e avariado é superior no 4º pico de frequência.

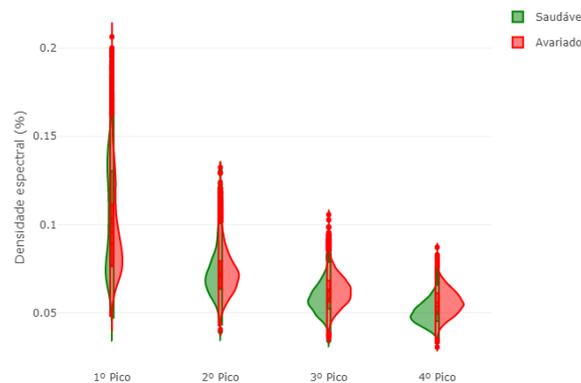


Figura 5.53: Distribuição da densidade espectral dos quatro maiores picos de frequência observados no domínio espectral da vibração para os estados saudável e avariado do rolamento

Com a diminuição da frequência de amostragem registam-se distribuições muito semelhantes às observadas nas Figuras 5.52 e 5.53, sendo a principal diferença a maior tendência para a discriminação através dos mesmos ser diminuída dada a diminuição do intervalo de frequências estudado segundo o teorema de Nyquist.

A nível do *dataset* CWRU o poder discriminativo das *features* observadas é idêntico.

### 5.2.3 Análise do Desvio das Correntes Elétricas a uma Sinusoide Perfeita no Domínio Temporal

Apesar de ter sido previamente observado que a magnitude das correntes não sofre alterações com base no estado de avaria do rolamento, é teoricamente esperado que um estado do rolamento avariado se revele nas correntes elétricas do motor aumentando o seu desvio a uma sinusoide perfeita. Neste sentido, foi realizada a avaliação do desvio das mesmas a uma sinusoide perfeita diretamente do estudo das correntes elétricas no domínio temporal.

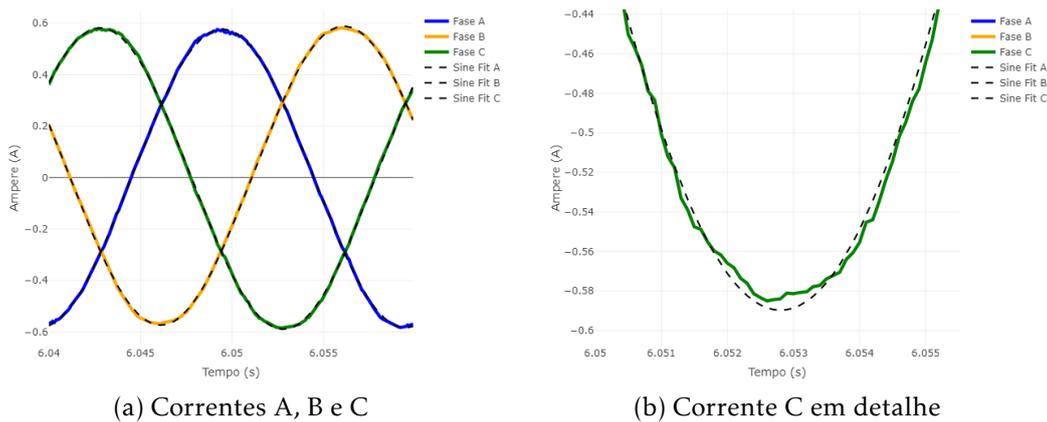


Figura 5.54: Exemplo de visualização da aproximação de uma sinusoide perfeita às correntes elétricas A, B e C

De forma a efetuar o cálculo deste desvio, é feita a aproximação máxima de uma função seno com o mesmo período das correntes a cada uma das correntes elétricas (como é possível observar na Figura 5.54a), sendo posteriormente calculado o desvio entre a função obtida e a corrente. Na Figura 5.54b é possível observar as diferenças de forma mais detalhada.

O desvio entre a corrente e a sinusoide é calculado através da raiz quadrada da soma do quadrado das diferenças entre todos os pontos da corrente e a sinusoide perfeita segundo

$$\text{Desvio}_x = \sqrt{\frac{\sum_n^i (c_i - s_i)^2}{n}} \quad (5.6)$$

em que  $x$  representa uma das correntes elétricas,  $c$  representa o sinal dessa corrente,  $s$  representa a sinusoide perfeita e  $n$  o número de pontos comparados.

Além do desvio de cada uma das correntes a uma senoide perfeita, foi também avaliada a média do desvio das 3 correntes (A, B e C) definida como

$$\text{Média do desvio} = \frac{\text{Desvio}_A + \text{Desvio}_B + \text{Desvio}_C}{3} \quad (5.7)$$

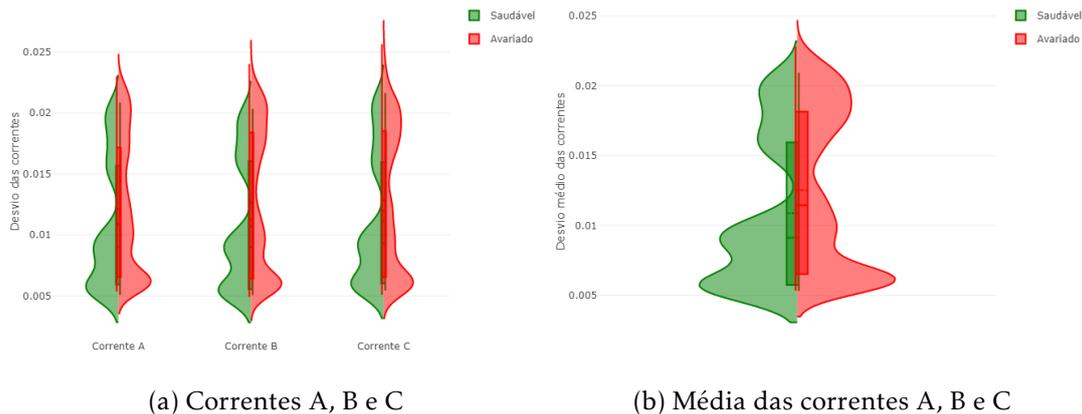


Figura 5.55: Distribuição dos desvios das correntes a uma senoide perfeita observados para os estados saudável e avariado do rolamento

Observando a distribuição dos desvios das correntes e da média das correntes a uma senoide perfeita na Figura 5.55a é possível verificar que esta apresenta o comportamento esperado com o ligeiro aumento do desvio quando o motor apresenta um estado avariado sendo que, no entanto, a zona de confusão é considerável. Comparativamente a outras análises observadas previamente o potencial discriminativo aparenta ser mais limitado.

Esta discriminação vai diminuindo ligeiramente consoante a diminuição da frequência de amostragem sendo que, considerando a natureza deste tipo de análise realizada às correntes, esta diminuição era esperada. De qualquer modo, os resultados observados em termos de relação entre estado saudável e avariado mantêm-se independentemente da frequência de amostragem utilizada.

#### 5.2.4 Análise da Excentricidade da Elipse Resultante da Transformada de Park das Correntes Elétricas

Como visto no estado da arte, nomeadamente na secção 4.3.5, a TP das correntes elétricas mostrou reagir a avarias nos rolamentos apresentando uma forma cada vez mais próxima de uma elipse quanto maior a avaria. Como tal, procedeu-se à avaliação deste método de deteção de avaria.

Inicialmente foi feita a decomposição das correntes ABC no domínio do tempo para as componentes D e Q, sendo esta decomposição dada pela equação 5.8 e resultando numa elipse no domínio DQ (como é possível observar na Figura 5.57).

$$\begin{cases} i_d(t) = \sqrt{\frac{2}{3}}i_A(t) - \sqrt{\frac{1}{6}}i_B(t) - \sqrt{\frac{1}{6}}i_C(t) \\ i_q(t) = \sqrt{\frac{1}{2}}i_B(t) - \sqrt{\frac{1}{2}}i_C(t) \end{cases} \quad (5.8)$$

Após as correntes estarem decompostas nas componentes D e Q no domínio DQ, é então feito o estudo da excentricidade da elipse que, teoricamente, indica a presença de avaria no ME. Ao observar a Figura 5.56, que apresenta as elipses de um estado saudável e de um estado avariado com um defeito de 4 mm, é possível observar a semelhança entre as mesmas e a ausência da manifestação da avaria neste caso, sendo praticamente impercetível a diferença entre o estado saudável e avariado.

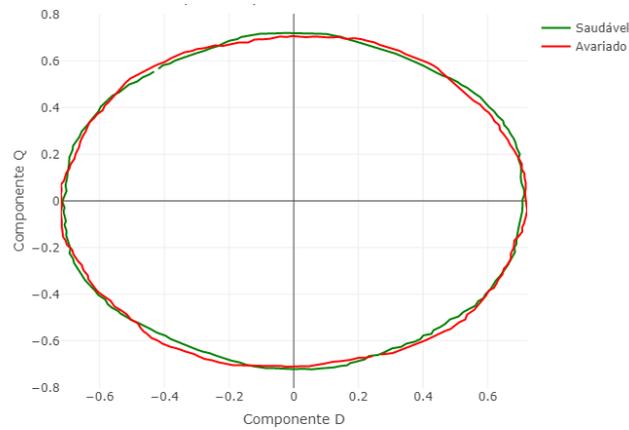
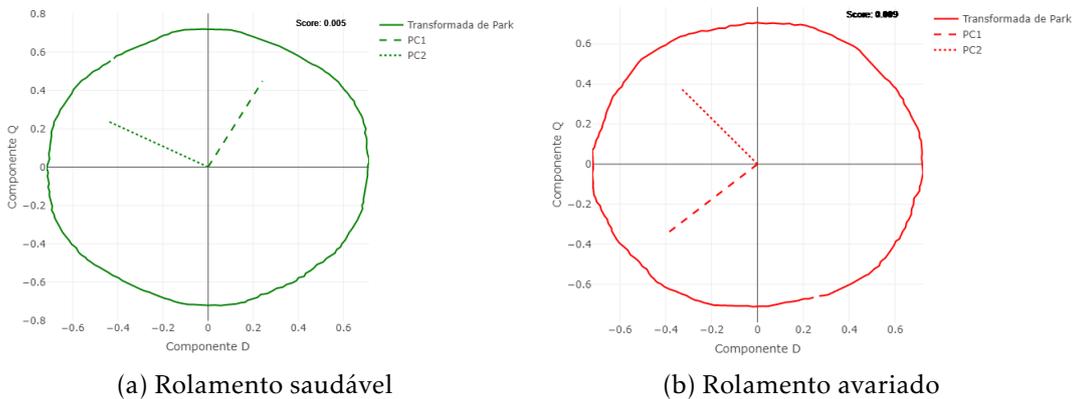


Figura 5.56: Comparação entre a elipse resultante da TP das correntes elétricas de um motor saudável e avariado

Independentemente da primeira observação, o estudo da excentricidade da elipse foi desenvolvido e avaliado sendo que de forma a efetuar este estudo, foi seguido o procedimento mencionado na secção 4.3.5, onde este foi feito através da ACP.



(a) Rolamento saudável

(b) Rolamento avariado

Figura 5.57: Exemplo de visualização da TP de um período de 20 ms de vibração de um rolamento saudável e avariado

Da ACP da elipse no domínio DQ resultam duas componentes ( $PC_1$  e  $PC_2$ ), como é possível observar na Figura 5.57, sendo a excentricidade da elipse calculada através da

comparação da magnitude das mesmas segundo

$$\text{excentricidade}_{DQ} = |PC_1| - |PC_2| \quad (5.9)$$

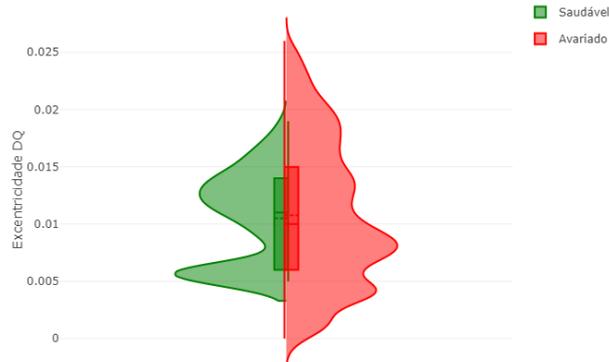


Figura 5.58: Distribuição da excentricidade da elipse observada nos estados saudável e avariado do rolamento

Ao observar a distribuição dos resultados obtidos relativamente à excentricidade da elipse obtida, na Figura 5.58, é demonstrado o previamente indicado de que não se verifica uma relação direta entre a excentricidade da elipse e o estado do motor, ao contrário do estudado no estado da arte.

Como esperado, a imperceptibilidade da avaria através da análise da TP mantém-se independentemente da frequência de amostragem utilizada.

### 5.2.5 Análise Estatística e Espectral da Transformada de Park Estendida das Correntes Elétricas

A TPE surge no seguimento da TP, sendo esta dada pelo módulo das componentes D e Q segundo a equação

$$\text{TPE} = \sqrt{i_d^2 + i_q^2} \quad (5.10)$$

A utilização desta transformada para a deteção de avarias nos rolamentos de MIT revelou resultados positivos na secção 4.3.6, sendo que a análise a esta é tipicamente feita através da sua análise espectral, onde é esperado que MITs com rolamentos avariados revelem uma assinatura espectral distinta da de um motor com um rolamento saudável.

Como é possível observar no exemplo da Figura 5.59, as diferenças entre a TPE de um motor saudável (Figura 5.59a) e a de um motor avariado (Figura 5.59b) aparentam ser visíveis no domínio temporal pelo que, neste sentido, além da análise espectral, foi também feito um estudo estatístico dos resultados da TPE no domínio temporal.

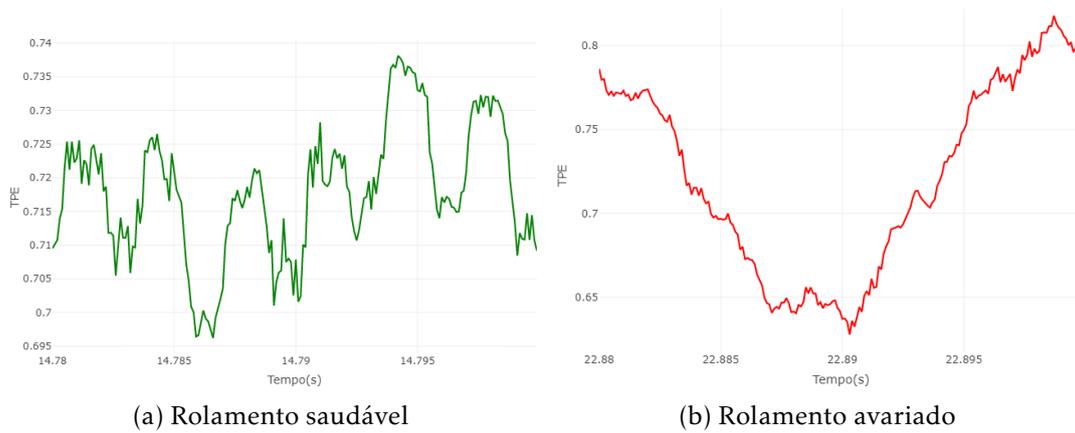


Figura 5.59: Exemplo de visualização da TPE de um período de 20 ms de vibração de um rolamento saudável e avariado

De forma semelhante ao feito na avaliação estatística da vibração e da amplitude instantânea da TH da vibração no domínio temporal, foram feitas diversas análises estatísticas ao resultado da TPE. Mais especificamente, foi feito o cálculo do RMS, média, mediana, valor mínimo e máximo, variância, amplitude, o valor da assimetria e a curtose (com as mesmas fórmulas descritas na análise estatística da vibração da secção 5.2.1).

O estudo e visualização dos resultados destas análises permitiram, à partida, a identificação de diversos cálculos estatísticos cuja variação de resultados não estava relacionada com o estado de avaria do motor, sendo estes o valor do RMS, da média, da mediana, do valor máximo e mínimo. A principal causa de variação destas *features* está associada à variação da carga do motor, sendo possível observar isto nas sub-figuras das Figuras 5.60 e 5.61, onde em todas os gráficos são claramente visíveis 3 curvas distintas.

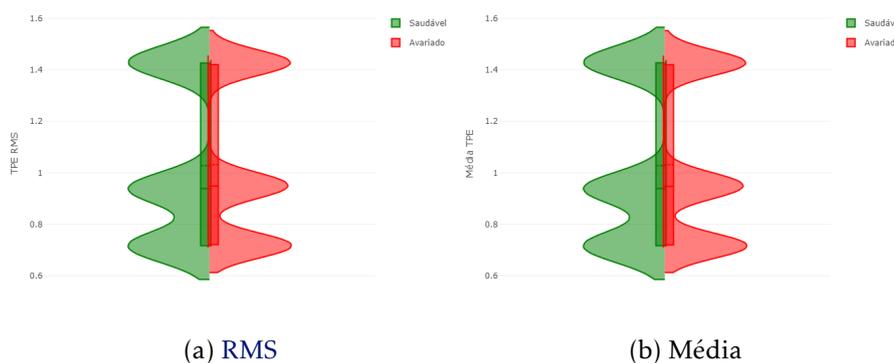


Figura 5.60: Distribuição do cálculo estatístico do RMS e média sobre o resultado da TPE para os estados saudável e avariado do rolamento

Nestas 3 curvas distintas, a curva mais abaixo no eixo das ordenadas corresponde à carga 0%, a do meio corresponde à carga 50% e a superior à carga de 100%.

Dentro deste conjunto de *features* resultantes da análise estatística da TPE foi, no entanto, possível identificar *features* cuja variação não está diretamente relacionada com a

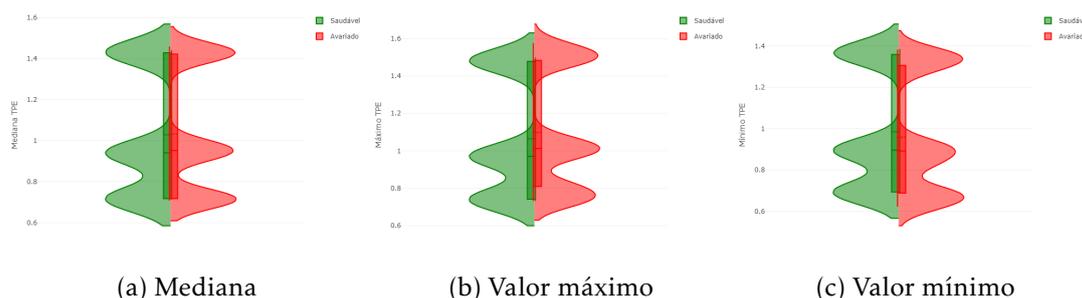


Figura 5.61: Distribuição do cálculo estatístico da mediana, valor máximo e mínimo sobre o resultado da TPE para os estados saudável e avariado do rolamento

variação da carga, sendo este o caso da assimetria (Figura 5.62a), amplitude (Figura 5.62b), variância (Figura 5.63a) e curtose (Figura 5.63b). Como é possível observar nas figuras, estas apresentam diferenças visíveis consoante o estado de avaria do motor, exibindo um poder discriminativo relativamente elevado.

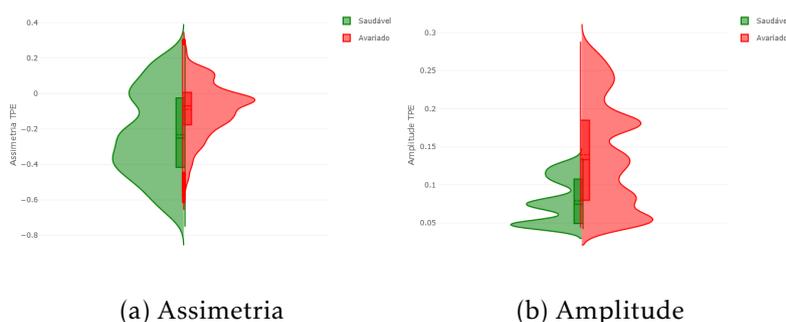


Figura 5.62: Distribuição do cálculo estatístico da assimetria e amplitude sobre o resultado da TPE para os estados saudável e avariado do rolamento

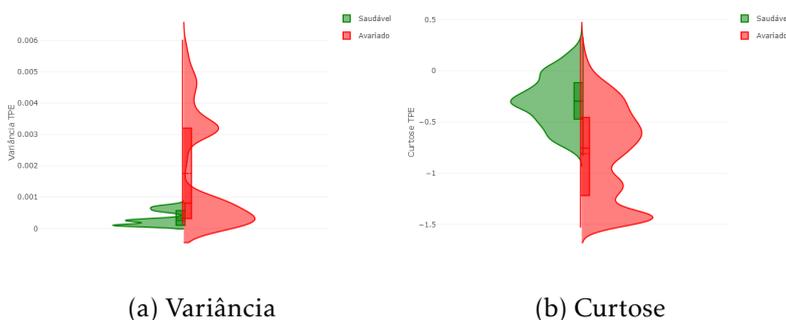


Figura 5.63: Distribuição do cálculo estatístico da variância e curtose sobre o resultado da TPE para os estados saudável e avariado do rolamento

Além da análise estatística da TPE, foi também realizada a análise espectral da mesma. Para tal, foi seguido o mesmo procedimento das análises espectrais mencionadas na secção 5.2.2, onde dos picos de frequência foram registados as frequências a que aconteceram, a respetiva magnitude, e calculada a sua densidade espectral.

O principal pico de frequência registado em todos os estados de avaria do motor foi o da frequência = 0 Hz, sendo isto o teoricamente esperado dado que, se o motor tivesse num estado perfeito, o sinal resultante da TPE não teria qualquer conteúdo espectral (estando, portanto, 100% do sinal na frequência = 0 Hz). Apesar deste facto, foi possível verificar diferenças na assinatura espectral da TPE olhando para outros parâmetros a ser analisados no principal pico de frequência, assim como analisando o restante intervalo de frequências.

As diferenças na assinatura espectral da TPE relacionadas com o estado de avaria do motor são visíveis nas Figuras 5.64 e 5.65, onde se observa o espectro de frequências de um motor saudável e de um motor avariado, respetivamente. Nestas figuras é possível verificar que, por exemplo, na frequência = 50 Hz (que habitualmente é a segunda frequência pico), se observa uma diferença considerável em termos de magnitude, sendo visível na Figura 5.65b uma magnitude muito superior à verificada no espectro do motor saudável da Figura 5.64b.

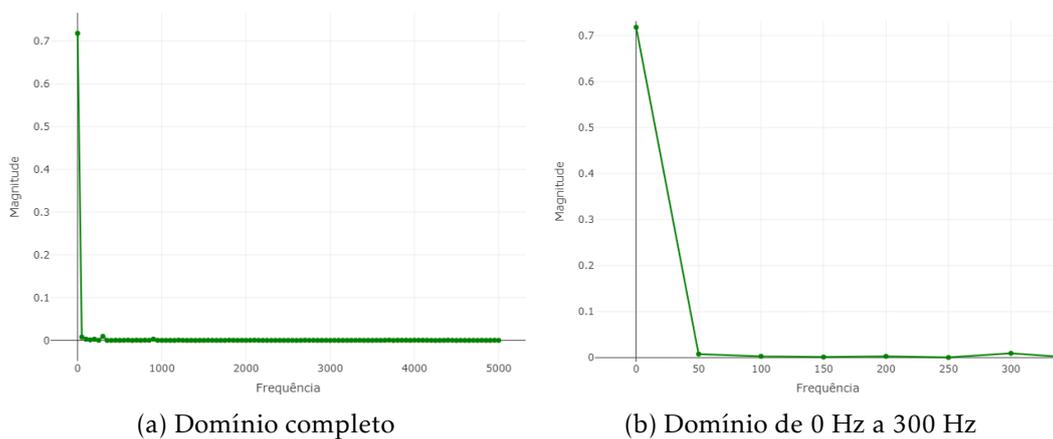


Figura 5.64: Exemplo de visualização do domínio espectral da TPE de um período de 20 ms de vibração de um rolamento saudável

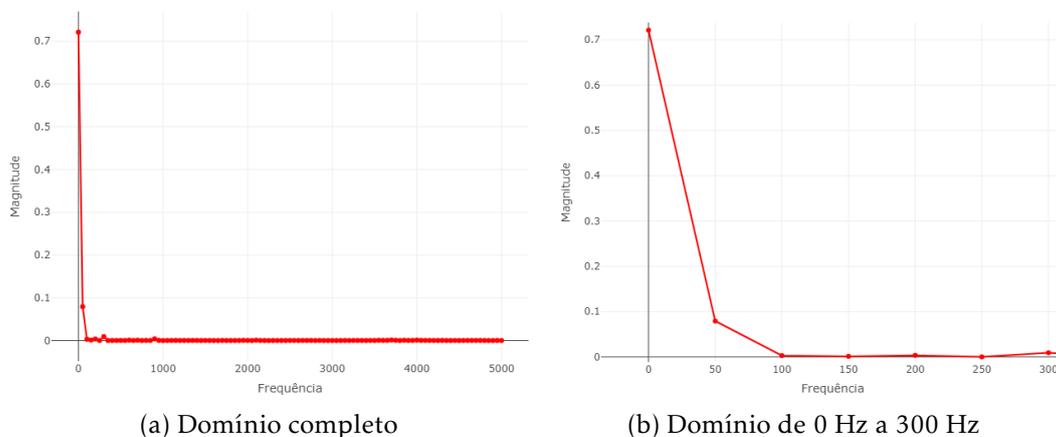


Figura 5.65: Exemplo de visualização do domínio espectral da TPE de um período de 20 ms de vibração de um rolamento avariado

Observando a distribuição da magnitude dos picos de frequência na Figura 5.66 é possível verificar o previamente indicado em relação às intensidades dos mesmos, onde se observa uma clara tendência (no caso das figuras, a título de exemplo, para o segundo e terceiro pico de frequência) para se constatar uma intensidade superior quando o motor está avariado. O facto de existir mais conteúdo espectral fora do pico principal de frequências (frequência = 0 Hz) faz com que a sua densidade espectral diminua quando o motor se encontra num estado avariado, com esta tendência a ser verificada na Figura 5.67a, sendo que a densidade espectral é normalmente superior nos restantes picos de frequência quando o motor se encontra num estado avariado (Figura 5.67b).

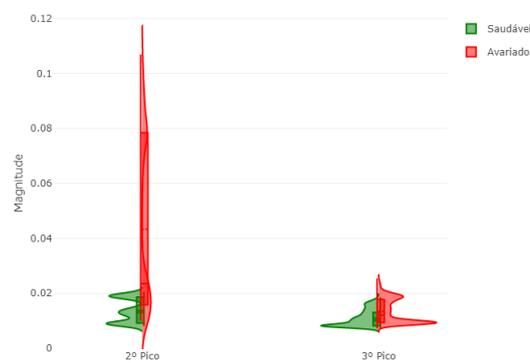
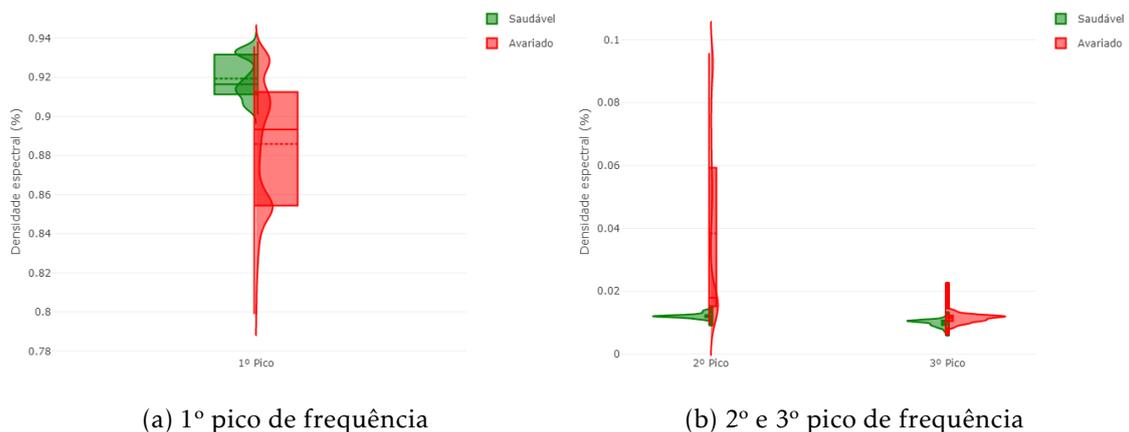


Figura 5.66: Distribuição da magnitude dos picos de frequência da TPE para os estados saudável e avariado do rolamento



(a) 1º pico de frequência

(b) 2º e 3º pico de frequência

Figura 5.67: Distribuição da densidade espectral dos picos de frequência da TPE para os estados saudável e avariado do rolamento

A relação entre estado saudável e avariado para as diversas variáveis observadas através da análise estatística e espectral da TPE mantém-se independentemente da frequência de amostragem utilizada, sendo a discriminação de estados através da análise estatística a que aparenta sofrer o maior impacto.

### 5.3 Conclusões

A observação, no domínio temporal e espectral, dos registos de ambas as grandezas físicas presentes nos *datasets* utilizados (descrita nas secções 5.1.2 e 5.1.3) permitiu constatar a existência de diferenças nos mesmos com a variação do estado de avaria do rolamento do motor. O estudo do impacto das frequências de amostragem utilizadas nestes registos (descrito na secção 5.1.4) demonstrou, para a utilização das frequências de amostragem mais baixas (inferiores a 5 kHz), uma perda de sinal dos registos de vibração superior à verificada nos registos das correntes elétricas.

Em relação às técnicas utilizadas para a análise da vibração, a análise estatística da vibração e da amplitude instantânea da TH da vibração descrita na secção 5.2.1 e a análise do espectro vibracional resultante da TRF descrita na secção 5.2.2 apresentaram o maior potencial de classificação de avaria sendo que, em relação às técnicas utilizadas para a análise das correntes, a análise do desvio das correntes elétricas a uma senoide perfeita descrita na secção 5.2.3 e a análise estatística e espectral da TPE descrita na secção 5.2.5 mostraram ser as análises mais promissoras para a classificação pretendida. A excentricidade da elipse resultante da TP das correntes elétricas não mostrou relação com o estado de avaria do rolamento.



## MODELAÇÃO E AVALIAÇÃO

Este capítulo apresenta a fase de modelação e avaliação da metodologia **CRISP-DM**. Primeiramente, na secção 6.1, são apresentadas as nomenclaturas utilizadas ao longo do capítulo, sendo que na secção 6.2 é apresentado o procedimento aplicado a nível de pré-processamento, divisão de dados e validação do modelo, algoritmos de classificação e métricas de avaliação. A deteção da avaria através da análise da vibração é descrita na secção 6.3, sendo a deteção da avaria através da análise da corrente caracterizada na secção 6.4.

### 6.1 Definições e Nomenclaturas

Sendo o objetivo das modelações aqui descritas a deteção de avarias nos rolamentos, foi definido o caso positivo como representação do estado avariado e o caso negativo do estado saudável.

O conceito de **período de análise** refere-se à duração do período de tempo utilizado no particionamento dos registos dos *datasets* e, conseqüentemente, a duração do período de tempo a partir do qual as análises e respetiva extração de *features* é realizada.

Dada a existência de 5 registos distintos para cada estado de avaria no *dataset* optisigma, com frequências de amostragem diferentes, é mencionado ao longo desta secção o conceito de **kappa médio** que indica a média do kappa obtido para um dado conjunto *feature set*-algoritmo com as 5 frequências de amostragem diferentes, sendo este dado pela equação 6.1.

$$\text{Kappa Médio} = \frac{K_{0.8\text{kHz}} + K_{1\text{kHz}} + K_{2\text{kHz}} + K_{5\text{kHz}} + K_{10\text{kHz}}}{5} \quad (6.1)$$

A noção de *feature set*, predominantemente mencionada por extenso, é por vezes assinalada como **FS**.

## 6.2 Procedimento

### 6.2.1 Pré-processamento, Divisão de Dados e Validação do Modelo

Os dados foram normalizados com a técnica min-max dada a grande amplitude de valores registados nas *features* avaliadas, garantindo assim que todas contribuem aproximadamente da mesma forma. De entre os algoritmos utilizados, esta normalização de dados mostra especial importância para a ANN.

De modo a garantir que o conjunto de treino e de teste continham a mesma proporção das diferentes situações de estados de avaria (tipo de avaria, diâmetro da avaria, e carga do motor) foi feita uma amostragem estratificada dos conjuntos de treino e de teste, sendo que a divisão utilizada foi de 70:30, ou seja, 70% para o conjunto de treino e 30% para o conjunto de teste. A nível da validação do modelo e ajuste de parâmetros dos algoritmos de classificação utilizados (com base no conjunto de treino), esta foi realizada com recurso à técnica cross-validation com 10 partições, sendo esta validação repetida 3 vezes e feita a média dos resultados de forma a garantir o valor mais próximo do real. Os testes foram realizados de forma única com base nos respetivos conjuntos de teste e os resultados destes correspondem aos resultados descritos ao longo deste capítulo.

### 6.2.2 Algoritmos de Classificação

Dado o extenso volume de modelações a serem realizadas nesta dissertação e considerando a natureza dos *datasets* e as diferentes grandezas físicas a ser analisadas, foram escolhidos 4 algoritmos de classificação como referência: a SVM e ANN foram selecionados devido aos resultados obtidos nas referências estudadas no estado da arte desta dissertação, o RF tendo em conta os bons resultados obtidos no projeto REARM e o XGBOOST dadas as boas menções encontradas ao longo do estudo das técnicas de AA.

De forma a obter os melhores resultados com cada um dos algoritmos, os seus parâmetros foram ajustados. O *package caret* permite a personalização desses parâmetros de forma manual, sendo também possível deixar esta a cargo do próprio *package*, tendo sido realizada uma pequena comparação entre estes dois tipos de otimização utilizando um *feature set* de referência. A comparação dos desempenhos encontra-se detalhada no apêndice A, sendo que as parametrizações utilizadas nas modelações descritas ao longo deste capítulo encontram-se detalhadas abaixo.

---

#### SVM - Support Vector Machine (Radial Basis Function Kernel)

$C = (0.25, 0.5, 1, 2, 4, 8, 16, 32, 64, 128, 512, 1000)$

$\text{sigma} = (0.0025, 0.005, 0.01, 0.015, 0.02, 0.03, 0.04, 0.06, 0.08, 0.1)$

---

#### ANN - Artificial Neural Network

$\text{size} = (1, 2, 3, 4, 5, 6, 7, 8, 9, 10)$

$\text{decay} = (0.1, 0.2, 0.3, 0.4, 0.5)$

#### RF - Random Forests

Optimização de parâmetros realizada automaticamente pelo *package* *caret*.

---

#### XGB - eXtreme Gradient Boosting

```
eta = (0.05, 0.075, 0.1)
nrounds = (50, 75, 100)
max_depth = (6, 7, 8)
min_child_weight = (2.0, 2.25, 2.5)
colsample_bytree = (0.3, 0.4, 0.5)
gamma = 0
subsample = 1
```

---

Analisando os parâmetros utilizados em cada algoritmo observamos que são testadas 120, 50, 3 e 243 combinações de valores para os algoritmos *SVM*, *ANN*, *RF* e *XGBOOST*, respetivamente e, juntando o facto da validação ser feita com recurso à técnica 10-Fold Cross-Validation (repetida 3 vezes), para ser obtido um modelo final resultante de cada um dos algoritmos mencionados, são validados 3600, 1500, 90 e 7290 modelos, respetivamente. Dado o complexo e demorado processo de modelação envolvido na realização desta dissertação, além deste ter sido realizado paralelamente em dois computadores, foi implementado um *script* com o objetivo de fazer a modelação de forma paralela no mesmo processador (com base no número de núcleos) e prosseguir a modelação no mesmo local em caso de falha.

#### 6.2.3 Métricas de Avaliação

A principal métrica de avaliação tida em conta para a avaliação dos resultados foi o Kappa, devendo-se esta escolha ao elevado desequilíbrio existente entre classes em ambos os *datasets* utilizados.

Como explicado na sub-seção 3.6.6 esta é uma métrica de avaliação extremamente exigente e pode ser vista como uma exatidão normalizada pelo desequilíbrio entre classes dos dados garantindo, para este caso, uma avaliação mais realista dos resultados quando comparada com a exatidão.

### 6.3 Deteção da Avaria através da Análise da Vibração

Após um primeiro estudo e avaliação das *features* resultantes de diferentes análises feitas à vibração na secção 5.2, foi observado que as análises estatísticas da vibração e da amplitude instantânea da vibração e a sua análise espectral exibem potencial na classificação do estado de avaria do rolamento. Com base na natureza do estudo efetuado na análise espectral da vibração, destaca-se a necessidade de efetuar uma primeira calibração da

mesma de modo a definir o número de picos de frequência a serem considerados para o *feature set* correspondente, estando esta avaliação descrita na secção 6.3.1.

Na secção 6.3.2 são descritos os *feature sets* constituídos, sendo a respetiva avaliação de resultados obtidos em relação à deteção da avaria com os mesmos detalhada na secção 6.3.3. Dado o valor acrescido que o *dataset* CWRU oferece devido ao facto de conter registos de avarias em localizações distintas do rolamento, foi também realizada a avaliação de resultados obtidos com estes *feature sets* na identificação da localização da avaria, estando a mesma detalhada na secção 6.3.4.

### 6.3.1 Calibração da Análise Espectral da Vibração

Como previamente mencionado, dado o método utilizado na realização da análise espectral da vibração, surgiu a necessidade de estabelecer o número de picos de frequência a serem utilizados em futuras modelações com *features* resultantes desta análise. Este estudo foi realizado com base no *dataset* CWRU que, quando comparado com o *dataset* op-tisigma, oferece as menores intensidades de avaria, avarias distintas e a maior frequência de amostragem.

As modelações foram efetuadas com o algoritmo RF e com um período de análise de 20 ms variando o número de picos de frequência analisados de 1 a 9, sendo que objetivo desta calibração passa por observar o comportamento geral do kappa consoante o aumento do número de picos de frequência analisados, procurando avaliar e obter o número de picos de frequência a partir dos quais o kappa deixa de indicar um ganho relevante e não o número de picos de frequência analisados onde se obtém o kappa máximo (semelhante ao feito com a técnica do cotovelo na análise de *clusters*).

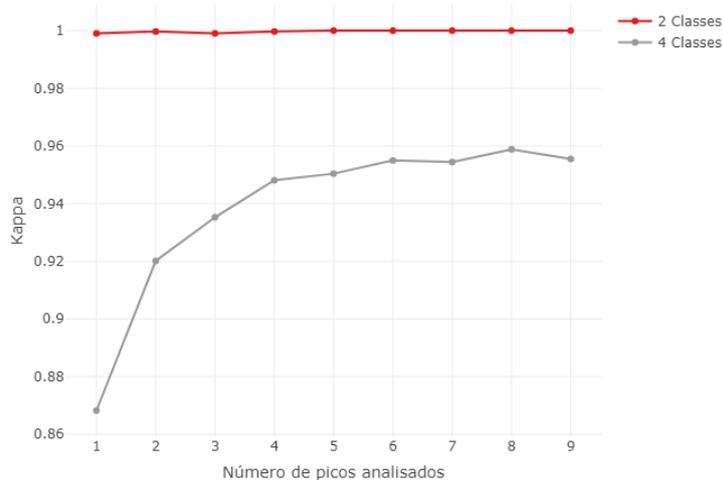


Figura 6.1: Variação do kappa obtido segundo o número de picos de frequência avaliados na análise espectral da vibração para a classificação entre duas e quatro classes

Observando o gráfico 6.1, que ilustra a variação do kappa obtido com base na análise de um número de picos de frequência entre 1 e 9 para a classificação entre estado saudável e avariado (2 classes) e entre estado saudável e avariado com identificação da

localização da avaria (4 classes), é possível verificar que essa variação apresenta um comportamento distinto para os dois tipos de classificação. Analisando a classificação entre duas classes, constata-se que a variação do kappa é muito baixa, obtendo resultados excelentes analisando, por exemplo, apenas o maior pico de frequência, sendo que no caso das quatro classes existe um claro aumento no desempenho do classificador com o aumento do número de picos de frequência considerados para análise.

Tabela 6.1: Variação do kappa segundo o número de picos resultantes da análise espectral da vibração para a classificação entre duas e quatro classes

Nº de picos de frequência analisados	4 Classes		2 Classes	
	Kappa	Varição (%)	Kappa	Varição (%)
1	0.8682		0.999	
2	0.9201	5.64	0.9997	0.07
3	0.9353	1.62	0.999	-0.07
4	0.9481	1.35	0.9997	0.07
5	0.9504	0.24	1	0.03
6	0.955	0.48	1	0
7	0.9544	-0.06	1	0
8	0.9588	0.46	1	0
9	0.9555	-0.35	1	0

Dada a variação mínima do kappa obtida com a classificação entre duas classes, com excelentes resultados independentemente do número de picos de frequência analisados, foi decidido pesar esta decisão principalmente com base nos resultados obtidos na classificação entre quatro classes. A Tabela 6.1 ajuda a clarificar os valores de kappa obtidos e a verificar que a partir de 6 picos de frequência o kappa deixa de apresentar melhorias significativas para a classificação entre quatro classes, apresentando um estado de relativa estagnação, sendo que este número de picos de frequência analisados também apresenta um resultado excelente na classificação entre duas classes pelo que foi definido como o número de picos de frequência a serem utilizados no *feature set* correspondente.

### 6.3.2 Descrição dos *Feature Sets*

Após a observação das análises com maior potencial na classificação do estado de avaria do rolamento na secção 5.2, foram encontrados os *feature sets* iniciais a ser utilizados. Este processo de formação dos *feature sets* continuou a ser efetuado de forma iterativa, ou seja, houve uma primeira observação do desempenho dos *feature sets* diretamente resultantes de cada uma das análises efetuadas (independentemente) e formados outros *feature sets* com base nestes resultados. Neste sentido, numa primeira fase foram definidos 3 *feature sets*: o primeiro correspondendo às *features* resultantes da análise estatística da vibração, o segundo com as *features* resultantes da análise estatística da amplitude instantânea da TH da vibração e o terceiro com as *features* resultantes da análise espectral da vibração.

Posteriormente a um primeiro balanço dos desempenhos destes 3 *feature sets* foi observado o melhor desempenho por parte do terceiro (análise espectral da vibração) para

a classificação entre duas e quatro classes, pelo que foram definidos outros 3 *feature sets* correspondendo a todas as combinações possíveis entre o terceiro *feature set* e os restantes. De outra forma foi também definido um novo *feature set* com a junção da análise estatística da vibração e da amplitude instantânea da TH de modo a avaliar a diferença de desempenho quando utilizadas em conjunto. Todas as combinações estão ilustradas na Figura 6.2.

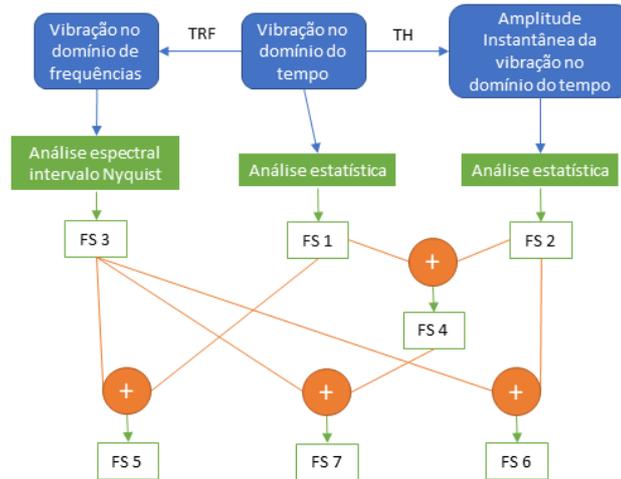


Figura 6.2: Esquema da constituição dos *feature sets* resultantes da análise da vibração

Além dos *feature sets* previamente mencionados foi criado um resultante da avaliação da RFE ao conjunto de todas as *features* utilizadas para a classificação, ou seja, o conjunto de *features* do *feature set* 7, passando este a corresponder ao *feature set* 8. A RFE foi efetuada para a classificação entre duas e quatro classes, estando detalhada na secção 6.3.2.1.

A descrição de cada um dos *feature sets* encontra-se abaixo.

### FS 1. Análise estatística da vibração no domínio do tempo

Cada linha é composta por 12 colunas, sendo que estas contêm as *features* resultantes da análise estatística da vibração (*RMS*, *média*, *mediana*, *variância*, *desvio padrão*, *máximo*, *mínimo*, *amplitude*, *assimetria*, *curtose*, *máximo do módulo da vibração* e *crest*), como descrito na sub-secção 5.2.1.

### FS 2. Análise estatística da amplitude instantânea da TH da vibração no domínio do tempo

Cada linha é composta por 10 colunas, sendo que estas contêm as *features* resultantes da análise estatística da amplitude instantânea da TH da vibração (*RMS*, *média*, *mediana*, *variância*, *desvio padrão*, *máximo*, *mínimo*, *amplitude*, *assimetria*, *curtose*), como descrito na sub-secção 5.2.1.

### FS 3. Análise espectral da vibração no intervalo Nyquist

*Cada linha é composta por 18 colunas, sendo que estas contêm a análise espectral dos 6 maiores picos de frequência (frequência, intensidade e densidade espectral de cada pico) no intervalo de frequências disponível para análise segundo o teorema de Nyquist, como descrito na sub-secção 5.2.2.*

---

#### **FS 4. Análise estatística da vibração e da amplitude instantânea da TH da vibração no domínio do tempo**

*Cada linha é composta por 22 colunas, sendo que estas contêm a junção das features descritas nos feature sets 1 e 2.*

---

#### **FS 5. Análise estatística da vibração no domínio do tempo + Análise espectral da vibração no intervalo Nyquist**

*Cada linha é composta por 30 colunas, sendo que estas contêm a junção das features descritas nos feature sets 1 e 3.*

---

#### **FS 6. Análise estatística da amplitude instantânea da TH da vibração no domínio do tempo + Análise espectral da vibração no intervalo Nyquist**

*Cada linha é composta por 28 colunas, sendo que estas contêm a junção das features descritas nos feature sets 2 e 3.*

---

#### **FS 7. Análise estatística da vibração e da amplitude instantânea da TH da vibração no domínio do tempo + Análise espectral da vibração no intervalo Nyquist**

*Cada linha é composta por 40 colunas, sendo que estas contêm a junção das features descritas nos feature sets 1, 2 e 3.*

---

#### **FS 8. Recursive Feature Elimination**

*No caso da classificação entre duas classes cada linha é composta por 13 colunas, sendo que na classificação entre quatro classes cada linha é composta por 20 colunas. Estes conjuntos de features correspondem aos conjuntos que obtiveram melhores resultados na RFE descrita na secção 6.3.2.1.*

---

##### **6.3.2.1 Recursive Feature Elimination**

Na definição de um dos *feature sets* foi utilizada a abordagem RFE sendo que esta foi feita com base na análise do *dataset* CWRU. Dado que existem dois objetivos diferentes de classificação com base na análise da vibração (classificação entre estado saudável e avariado e classificação entre estado saudável e avariado com identificação da avaria), esta técnica foi utilizada para ambos.

Para a classificação entre estado saudável e avariado (duas classes) a RFE foi feita sobre todas as *features* excepto as resultantes do 9º pico de frequência da análise espectral

da vibração. Esta opção foi tomada dado que era de conhecimento prévio (com base nos resultados obtidos com os restantes *feature sets*) de que o potencial de classificação não seria limitado pela não utilização deste 9º pico e esta opção possibilita replicar a utilização do *feature set* resultante em todos os conjuntos de dados da optisigma (no caso da utilização de uma frequência de amostragem de 0.8 kHz e um período de análise de 20 ms é possível analisar apenas 8 picos de frequência entre 1-400 Hz).

No caso da classificação entre quatro classes foram avaliadas a totalidade das *features* disponíveis.

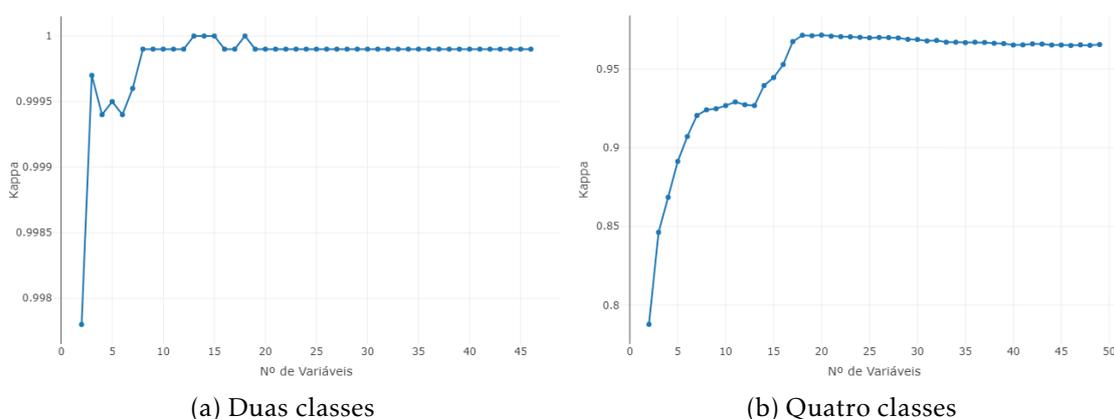


Figura 6.3: Variação do kappa obtido com a RFE para a classificação entre duas e quatro classes

Como é possível observar na Figura 6.3, que ilustra a variação do kappa obtido consoante o número de variáveis utilizadas para a classificação, os resultados da RFE mostram que a classificação entre duas classes consegue atingir o melhor resultado com a utilização de um menor número de *features* que a classificação entre quatro classes, como esperado.

No caso da classificação entre duas classes, na Figura 6.3a, o melhor resultado é atingido com a utilização de 13 *features*, sendo que são todas resultantes da análise espectral da vibração e correspondem às frequências dos 8 maiores picos de frequência e às densidades espectrais dos 5 maiores picos de frequência. Para o caso da classificação entre quatro classes, na Figura 6.3b, é atingido o melhor resultado com 20 *features* sendo que estas resultam maioritariamente da análise espectral da vibração mas também da análise estatística da vibração e da amplitude instantânea da TH da vibração e correspondem às frequências dos 9 maiores picos de frequência, às densidades espectrais dos 5 maiores picos de frequência, à mediana, variância, desvio padrão, curtose e assimetria da amplitude instantânea da TH da vibração e à amplitude da vibração.

Os resultados detalhados do uso desta técnica para a definição de um *feature set* estão detalhados no apêndice C na secção C.1.

### 6.3.3 Distinção entre Estado Avariado e Saudável

Com o objetivo de fazer uma primeira comparação entre *feature sets*, e entender o seu potencial desempenho a nível de classificação entre o estado avariado e saudável, foi feita a escolha de utilizar o algoritmo RF como referência.

Comparando o desempenho dos oito *feature sets* constituídos em ambos os *datasets* utilizados, com um período de análise de 20 ms (Figura 6.4), é possível observar que todos mostram um elevado poder preditivo com valores de kappa relativamente elevados. De entre todos os *feature sets* destacam-se os *feature sets* 3, 5, 6, 7 com kappas de 1 quando treinados e avaliados com o *dataset* CWRU e kappas médios acima de 0.98 quando o mesmo procedimento foi seguido com o *dataset* optisigma.

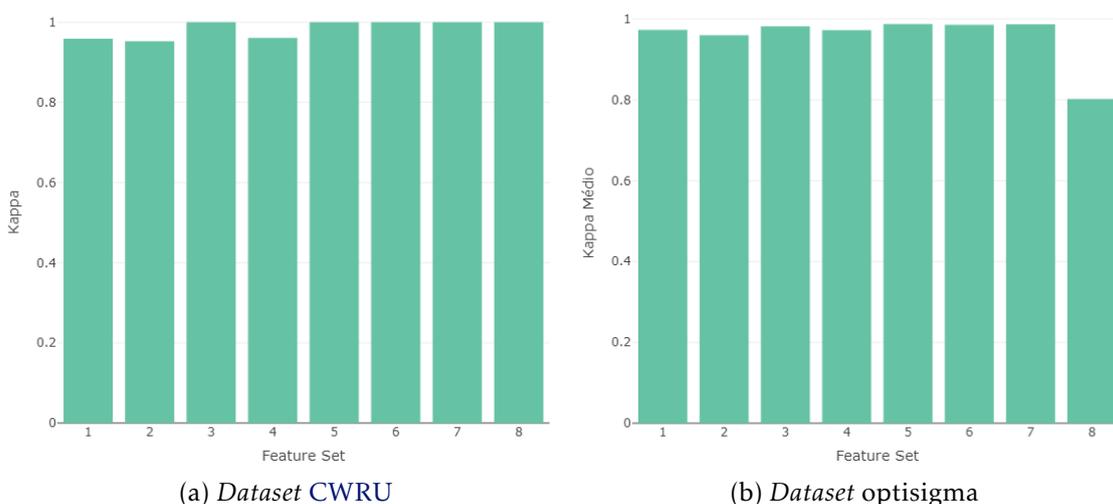


Figura 6.4: Comparação entre o kappa obtido para os diferentes feature sets com um período de análise de 20 ms para a classificação entre duas classes

O facto de todos os *feature sets* apresentarem um desempenho semelhante em ambos os *datasets* excepto o *feature set* 8 será abordado mais à frente, sendo que a principal razão para tal está relacionada com a abordagem RFE.

No sentido de averiguar em que medida um período de análise alargado poderia melhorar a classificação do estado de avaria, e avaliar o impacto que este aumento poderia ter nas diferentes frequências de amostragem utilizadas, foram também estudados períodos de análise superiores a 20 ms, tendo estes sido definidos de 20 ms a 100 ms com intervalos de 10 ms (20 ms, 30 ms, 40 ms, etc.).

Observando os gráficos da Figura 6.5 verifica-se que, em geral, todos os *feature sets* beneficiam com o aumento do período de análise, sendo este aumento refletido num aumento do kappa. Para casos em que a frequência de amostragem é alta, como o caso do gráfico 6.5a (12 kHz) constata-se que este aumento do período de análise aparenta beneficiar maioritariamente *feature sets* resultantes de análises estatísticas no domínio temporal, sendo que *feature sets* resultantes de análises espectrais não mostram necessitar de um período de análise estendido para atingir o seu potencial máximo (como é observável,

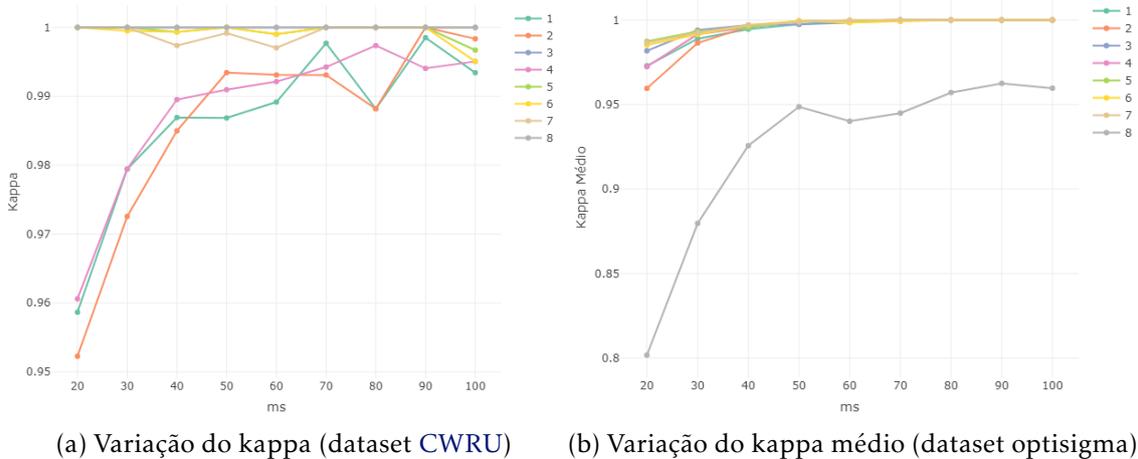


Figura 6.5: Variação do kappa e do kappa médio segundo o período de análise para todos os feature sets com os datasets CWRU e optisigma

por exemplo, no caso do *feature set* 3 que registra um kappa de 1 independentemente do período de análise utilizado). O gráfico 6.5b contrasta com o gráfico 6.5a ao observar-se um aumento de desempenho equivalente ao aumento do período de análise em todos os *feature sets*, sendo este explicado pelo benefício geral de todos os *features sets* com o aumento do período de análise quando a frequência de amostragem é menor. Isto é ilustrado no gráfico 6.6, que apresenta a variação média do kappa a cada aumento do período de análise em 10 ms em todos os *feature sets* para cada uma das frequências de amostragem utilizadas com o *dataset* optisigma, onde se verifica que o aumento do período de análise é especialmente benéfico para frequências de amostragem baixas, sendo que à medida que é aumentada a frequência de amostragem, diminui a necessidade de um maior período de análise.

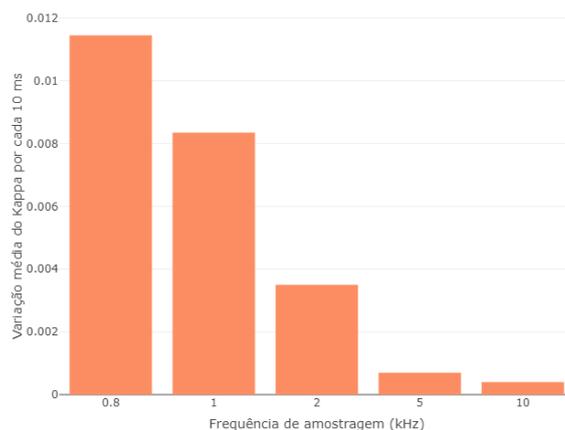


Figura 6.6: Variação média do kappa obtido com todos os *feature sets* a cada aumento do período de análise em 10 ms para cada uma das frequências de amostragem utilizadas com o *dataset* optisigma

Analisando em concreto, e comparando para cada *feature set*, o impacto que o período

de análise e a frequência de amostragem têm no mesmo (as legendas de cada figura são independentes, ou seja, a mesma cor poderá ter significados diferentes em cada figura dado que um mapeamento geral das cores impossibilita uma boa visualização), podemos observar que para os *feature sets* 1 e 2 (nas Figuras 6.7a e 6.7b) a classificação tende a ser perfeita com um período de análise de 20 ms a partir de uma frequência de amostragem de 5 kHz, sendo que com um período de análise de 30 ms ou 40 ms são atingidos resultados semelhantes com uma frequência de amostragem de 2 kHz e a partir de um período de análise de 50 ms são obtidos excelentes resultados com qualquer frequência de amostragem. Ambos os *feature sets* apresentam desempenhos semelhantes, no entanto, o *feature set* 1 apresenta resultados ligeiramente melhores com períodos de análise mais baixos (menores de 40 ms), especialmente para frequências de amostragem menores, sendo que o *feature set* 2 mostra ser uma ligeira vantagem para períodos de análise entre 40 ms e 60 ms (a partir de 70 ms as classificações são sempre perfeitas com ambos os *feature sets*). Apesar do *feature set* 4 apresentar a junção de ambos os *feature sets* previamente mencionados, este aparenta não apresentar melhorias relevantes e o seu desempenho é semelhante a ambos os *feature sets*, mostrando uma ligeira superioridade em relação ao *feature set* 2 para períodos de análise e frequências de amostragem baixas mas não necessariamente em relação ao *feature set* 1, como é possível observar na Figura 6.8b.

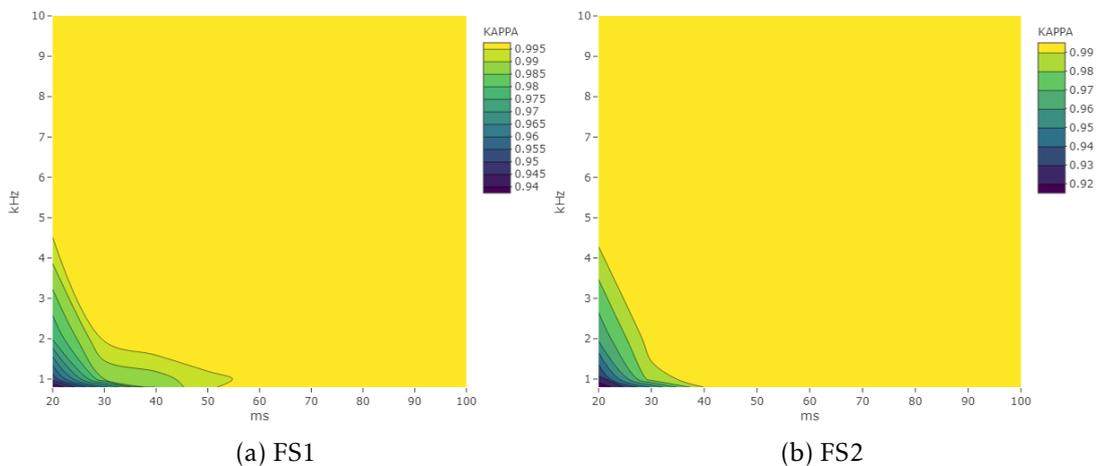


Figura 6.7: Variação do kappa obtido consoante o período de análise e a frequência de amostragem para os feature sets 1 e 2

No caso do *feature set* 3 (Figura 6.8a), que corresponde às *features* resultantes da análise espectral, a classificação é praticamente perfeita com um período de análise de 30 ms a partir de uma frequência de amostragem de 1 kHz, verificando-se os mesmos resultados para qualquer frequência de amostragem a partir de 40 ms. Este *feature set* mostra obter uma melhor classificação que a conseguida por qualquer um dos *feature sets* 1, 2 e 4 particularmente para frequências de amostragem até 5 kHz, sendo que a partir dessa frequência de amostragem ou a partir de um período de análise cerca de 40 ms são obtidos resultados semelhantes com os *feature sets* previamente mencionados.

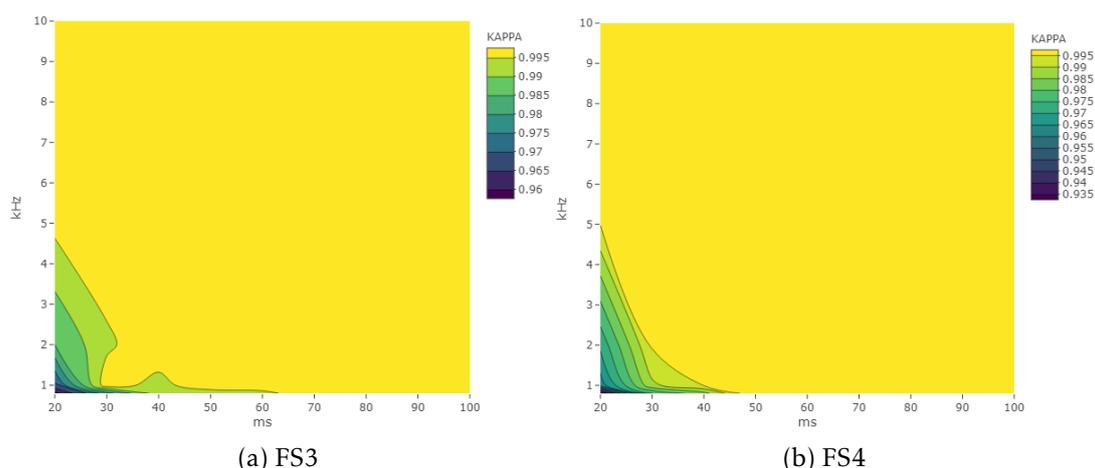


Figura 6.8: Variação do kappa obtido consoante o período de análise e a frequência de amostragem para os feature sets 3 e 4

Como observado anteriormente nos desempenhos obtidos para um período de análise de 20 ms, e dada a natureza dos *feature sets* 5, 6, 7, estes apresentam uma melhoria em termos das classificações obtidas em relação aos restantes, como é possível observar nas Figuras 6.9a, 6.9b e 6.10a. Em geral, estes *feature sets* obtiveram sempre o melhor resultado para todas as condições de períodos de análise e frequência de amostragem. Comparando o *feature set* 3 com o *feature set* 5 é perceptível que a junção com as *features* resultantes da análise estatística da vibração permitiu uma melhor classificação com um menor período de análise, sendo esta praticamente perfeita com um período de análise de 20 ms e a partir de uma frequência de amostragem de 2 kHz. Este *feature set* aparenta, basicamente, melhorar os desempenhos obtidos com o *feature set* 3 com as frequências de amostragem mais baixas.

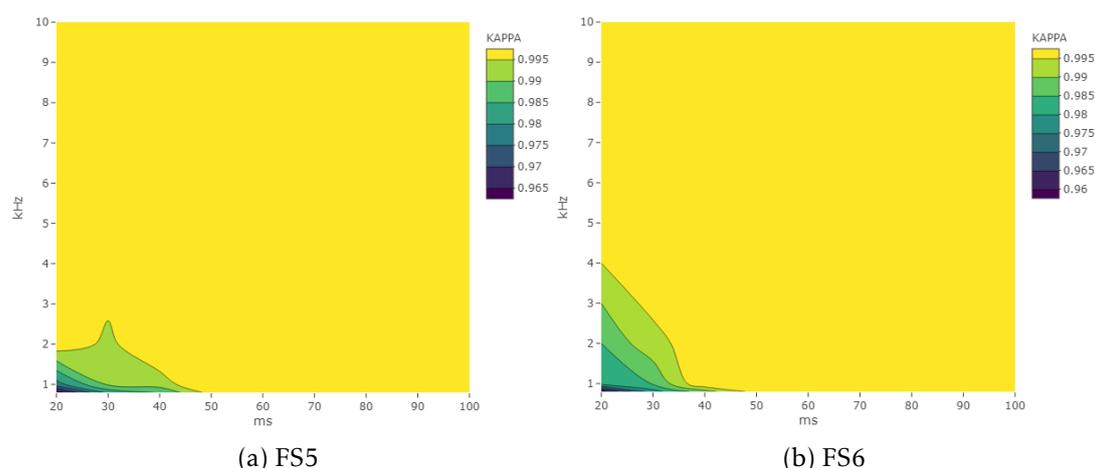


Figura 6.9: Variação do kappa obtido consoante o período de análise e a frequência de amostragem para os feature sets 5 e 6

A diferença entre as classificações obtidas com os *feature sets* 5 e 6 é mínima, sendo

que o *feature set 5* apresenta ligeiramente melhores resultados com um período de análise de 20 ms. Entre todos os *feature sets*, o *feature set 7* mostra ser a melhor opção pois é o que mais consistentemente apresenta melhores resultados registando kappas superiores a 0.98 com um período de análise de 20 ms e uma frequência de amostragem igual ou superior a 1 kHz, com os mesmos resultados a serem obtidos com qualquer frequência de amostragem a partir de um período de análise de 30 ms.

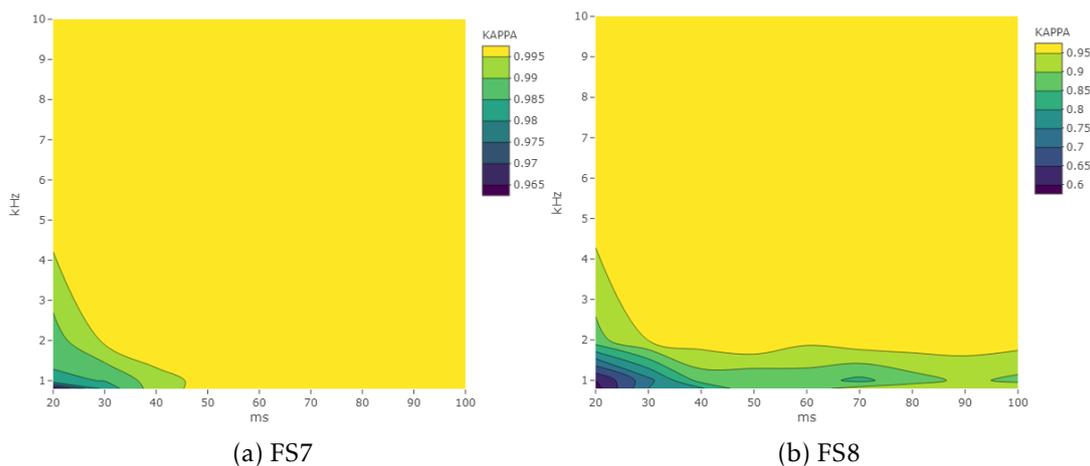


Figura 6.10: Variação do kappa obtido consoante o período de análise e a frequência de amostragem para os feature sets 7 e 8

Ao observar a Figura 6.10b verifica-se que a situação do *feature set 8* é um caso particular onde apenas são obtidos bons desempenhos com frequências de amostragem elevadas. Isto deve-se ao facto de este *feature set* ter sido definido com recurso à abordagem RFE no *dataset CWRU* (que tem uma frequência de amostragem de 12 kHz) e, apesar do desempenho obtido com este *feature set* neste *dataset* ter sido excelente, o *dataset optisigma* contém diversas outras frequências de amostragem inferiores à avaliada. Além deste pormenor, é também plausível a ocorrência de *overfitting* do *feature set* ao *dataset CWRU* devido ao uso deste tipo de técnicas (RFE) na definição do *feature set*, explicando uma possível diminuição de desempenho quando testado no *dataset optisigma*. Analisando os desempenhos do *feature set 8* com um período de análise de 20 ms a diferença entre os desempenhos obtidos com os diferentes *datasets* aparenta, de facto, ser maioritariamente explicada pelos baixos desempenhos obtidos com as menores frequências de amostragem, sendo que no caso em que o *feature set* foi avaliado com a frequência máxima do *dataset optisigma* (10 kHz) os resultados foram prometedores, com um kappa próximo de 0.98. Em geral, desempenhos com kappa superior a 0.95 apenas são atingidos com uma frequência de amostragem igual ou superior a 2 kHz independentemente do período de análise utilizado, sendo que os desempenhos são pobres com frequências de amostragem abaixo desta. Para frequências de amostragem iguais ou superiores a 5 kHz o desempenho é bom, registando sempre kappas superiores a 0.97 (o kappa obtido a partir de um período de análise de 40 ms foi sempre entre 0.99 e 1). Estes resultados permitem concluir que, como

previamente questionado, este é um *feature set* ajustado a frequências de amostragem altas e isto reflete-se no seu desempenho em frequências de amostragem baixas.

Dados os, no geral, excelentes desempenhos obtidos com todos os *feature sets* na classificação com o algoritmo RF, foram também realizadas avaliações de desempenho com os algoritmos SVM, ANN e XGBOOST. No caso do *dataset CWRU* todos os *feature sets* foram avaliados para um período de análise de 20 ms no sentido de, não só avaliar se os resultados com  $\kappa = 1$  se devem ao desempenho das features ou ao desempenho do algoritmo, mas também perceber se seria possível registrar melhores classificações com os *feature sets* 1, 2 e 4 com outros algoritmos, sendo que com os *feature sets* 7 e 8 (sendo os *feature sets* com maior poder preditivo), a avaliação foi feita com todos os algoritmos mencionados para todos os diferentes períodos de análise de forma a validar os resultados obtidos. No caso do *dataset optisigma*, tendo em conta que nenhum dos *feature sets* registou um  $\kappa$  médio = 1 com um período de análise de 20 ms, havendo no entanto registos de  $\kappa = 1$  com frequências de amostragem superiores, as avaliações de desempenho com os algoritmos mencionados anteriormente foram estendidas até um período de análise de 50 ms para todos os *feature sets*.

A avaliação dos *feature sets* com outros algoritmos no *dataset CWRU* revelou ser possível obter uma melhor classificação com os *feature sets* que não obtiveram uma classificação perfeita (*feature sets* 1, 2 e 4) com um período de análise de 20 ms sendo que, no entanto, as melhorias não foram suficientemente relevantes para revelarem um poder preditivo superior aos *feature sets* previamente identificados como os de maior poder preditivo. De entre estes *feature sets*, resultantes de análises estatísticas no domínio temporal, destaca-se o resultado do *feature set* 2 que obteve uma classificação perfeita (registando um  $\kappa = 1$ ) com um período de análise de 90 ms.

Tabela 6.2: Kappa obtido com os *feature sets* 3, 5, 6, 7 e 8 e um período de análise de 20 ms

Feature Set	rf	xgboost	svm	ann
3	1	1	0.9997	0.9993
5	1	0.9997	1	0.9997
6	1	1	1	1
7	1	1	1	0.9997
8	1	1	1	1

Em relação aos *feature sets* 3, 5, 6, 7 e 8, cuja classificação perfeita com um período de análise de 20 ms e o algoritmo RF foi previamente ilustrada, verifica-se que a classificação também é perfeita com o uso de diferentes algoritmos (Tabela 6.2), estando a matriz de confusão destas classificações ilustrada na Tabela 6.3.

Observando os kappas obtidos para as classificações com os diferentes algoritmos com um período de análise de 20 ms com o *dataset CWRU* na Figura 6.11 verifica-se que, apesar de alguns algoritmos registarem ligeiramente melhores desempenhos que outros, os resultados obtidos são excelentes independentemente do algoritmo reconhecendo, consequentemente, estes *feature sets* como os fatores-chave para as classificações perfeitas

Tabela 6.3: Matriz de confusão da melhor classificação obtida para um período de análise de 20 ms com o *dataset* CWRU

		Classe Verdadeira	
		A	S
Classe Prevista	A	5471	0
	S	0	2120

nesta equação entre algoritmos e *feature sets*.

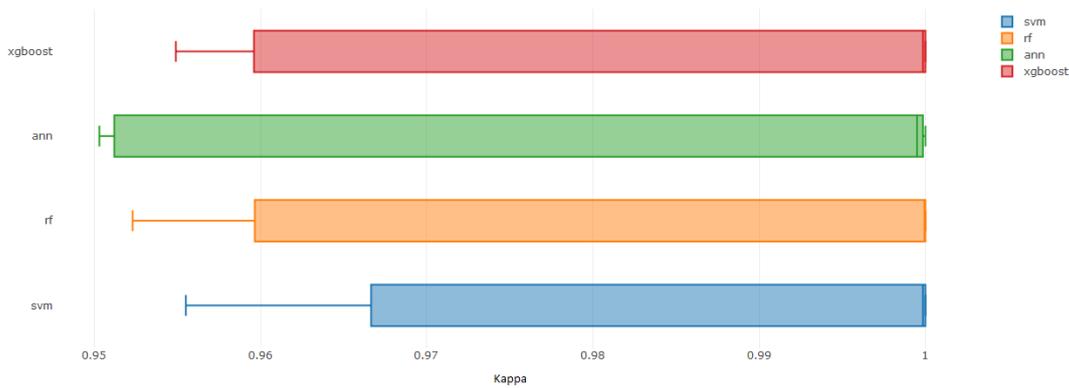


Figura 6.11: Comparação do kappa obtido com os diferentes algoritmos nas classificações com todos os *feature sets* com um período de análise de 20 ms com os dados CWRU

Analisando os resultados obtidos com o *dataset* optisigma verifica-se que, com uma frequência de amostragem de 0.8 kHz e um período de análise de 20 ms, o melhor kappa obtido foi de 0.9746 com o *feature set* 5 e o algoritmo SVM (com a matriz de confusão ilustrada na Tabela 6.4) sendo que, como previamente estudado e observado, a classificação é melhorada com o aumento do período de análise. Neste sentido, com um período de análise de 30 ms o kappa é superior a 0.99 com o mesmo *feature set* e algoritmo XGBOOST, sendo que com um período de análise de 40 ms e o *feature set* 3 apenas regista 1 falso positivo com o algoritmo ANN. Com um período de análise de 50 ms a classificação é perfeita com os *feature sets* 2, 4, 5, 6 e 7 com diversos algoritmos sendo que, naturalmente, o mesmo se verifica para períodos de análise superiores.

Tabela 6.4: Melhores resultados obtidos com uma frequência de amostragem de 0.8 kHz e diferentes períodos de análise

ms	FS	Kappa	Exatidão	VP	FP	VN	FN
20	5	0.9746	0.9924	2251	9	495	12
30	5	0.9909	0.9973	1506	4	332	1
40	3	0.9976	0.9993	1131	1	251	0
50	2, 4, 5, 6, 7	1	1	902	0	201	0

Com uma frequência de amostragem de 1 kHz os resultados obtidos para o mais baixo período de análise estudado foram melhores que os alcançados com a frequência de amostragem de 0.8 kHz, como esperado. Neste caso, a melhor classificação foi obtida

com o *feature set* 7 com o algoritmo SVM, com um kappa de praticamente 0.99 e com a matriz de confusão da Tabela 6.5. Com um período de análise de 30 ms a classificação é perfeita com o *feature set* 3 (com o algoritmo SVM) e 7 (com o algoritmo SVM e ANN), sendo que as classificações perfeitas se verificam com diversos *feature sets* e algoritmos com o aumento do período de análise.

Tabela 6.5: Melhores resultados obtidos com uma frequência de amostragem de 1 kHz e diferentes períodos de análise

ms	FS	Kappa	Exatidão	VP	FP	VN	FN
20	7	0.9889	0.9968	2310	3	489	6
30	3, 7	1	1	1541	0	327	0
40	3, 5, 6, 7	1	1	1157	0	246	0
50	3, 4, 5, 6, 7	1	1	921	0	195	0

A tendência de melhoria da classificação com o aumento da frequência de amostragem mantém-se e, para o caso em que a frequência de amostragem é de 2 kHz e o período de análise 20 ms, o melhor resultado obtido regista apenas 1 falso positivo com um kappa de 0.9989 (com a matriz de confusão da Tabela 6.6), tendo este sido obtido com o *feature set* 5 e o algoritmo RF. A partir de um período de análise de 30 ms a classificação é perfeita com diversos *feature sets* e algoritmos.

Tabela 6.6: Melhores resultados obtidos com uma frequência de amostragem de 2 kHz e diferentes períodos de análise

ms	FS	Kappa	Exatidão	VP	FP	VN	FN
20	5	0.9986	0.9996	2003	1	446	0
30	3, 4, 6, 7	1	1	1331	0	297	0
40	1, 2, 3, 4, 5, 6, 7	1	1	999	0	222	0
50	1, 2, 3, 4, 5, 6, 7, 8	1	1	795	0	177	0

A partir de uma frequência de amostragem de 5 kHz observa-se que, como indicado anteriormente, a classificação tende a obter resultados excelentes com diversos *feature sets* independentemente do período de análise. Com um período de análise de 20 ms a classificação é perfeita com os *feature sets* 3, 5 e 6, sendo que a classificação com os *feature sets* 5 e 6 obtêm um kappa de 1 com diversos algoritmos. Para períodos de análise superiores ao mencionado, a classificação é perfeita com os *feature sets* 1, 2, 3, 4, 5, 6 e 7 com diversos algoritmos para todos os *feature sets* (excepto o *feature set* 4 com um período de análise de 30 ms, cuja classificação perfeita apenas é registada com o algoritmo XGBOOST).

Com uma frequência de amostragem de 10 kHz a classificação é claramente mais fácil para os algoritmos, independentemente do período de análise e *feature set* utilizado. Os resultados obtidos mostram que, com a mencionada frequência de amostragem e o período de análise mínimo estudado, os *feature sets* 1, 3, 4, 5, 6 e 7 obtiveram classificações perfeitas, sendo que todos excepto o *feature set* 1 o fizeram com diversos algoritmos. A

Tabela 6.7: Melhores resultados obtidos com uma frequência de amostragem de 5 kHz e diferentes períodos de análise

ms	FS	Kappa	Exatidão	VP	FP	VN	FN
20	3, 5, 6	1	1	2361	0	507	0
30	1, 2, 3, 4, 5, 6, 7	1	1	1571	0	337	0
40	1, 2, 3, 4, 5, 6, 7	1	1	1176	0	252	0
50	1, 2, 3, 4, 5, 6, 7	1	1	939	0	201	0

partir de um período de análise de 30 ms a classificação também é perfeita com o *feature set 2* e com praticamente todos os algoritmos.

Tabela 6.8: Melhores resultados obtidos com uma frequência de amostragem de 10 kHz e diferentes períodos de análise

ms	FS	Kappa	Exatidão	VP	FP	VN	FN
20	1, 3, 5, 6, 7	1	1	3366	0	897	0
30	1, 2, 3, 4, 5, 6, 7	1	1	2241	0	597	0
40	1, 2, 3, 4, 5, 6, 7, 8	1	1	1680	0	447	0
50	1, 2, 3, 4, 5, 6, 7	1	1	1341	0	357	0

Ao analisar o período de análise mínimo necessário, com cada frequência de amostragem, para cada *feature set* registrar uma classificação perfeita na Tabela 6.9 verifica-se que os *feature sets 6* e *7* se destacam, sendo ou igualando os *feature sets* com o mínimo período de análise necessário para registrar uma classificação perfeita. Ambos os *feature sets* obtêm os mesmos resultados neste assunto excepto com uma frequência de amostragem de 1 kHz (em que o *feature set 7* obtém o melhor resultado) e com uma frequência de amostragem de 5 kHz (em que o *feature set 6* obtém o melhor resultado).

Tabela 6.9: Período de análise mínimo (ms) por frequência de amostragem (kHz) para atingir uma classificação perfeita para cada *feature set*

	Freq. de amostragem				
	0.8	1	2	5	10
<b>1</b>	60	70	40	30	20
<b>2</b>	50	60	40	30	30
<b>3</b>	70	30	30	20	20
<b>FS 4</b>	50	50	30	30	30
<b>5</b>	50	40	40	20	20
<b>6</b>	50	40	30	20	20
<b>7</b>	50	30	30	30	20
<b>8</b>	-	-	50	80	40

Observando os resultados obtidos com os diversos algoritmos e *feature sets* é interessante verificar que, além do confirmado anteriormente de que quanto maior a frequência de amostragem ou o período de análise, melhor a classificação, também se verifica que basicamente, quanto maior a frequência de amostragem ou o período de análise, menor

o número de *features* necessárias de avaliar. Isto pode ser concluído com base no facto de que os *feature sets* que não resultam de junções de *feature sets* previamente definidos atingirem cada vez melhores resultados com o aumento da frequência de amostragem ou do período de análise. É também possível verificar que *feature sets* que registam um bom desempenho com frequências de amostragem baixas, registam normalmente um bom desempenho com frequências de amostragem altas, sendo que o contrário não se verifica necessariamente.

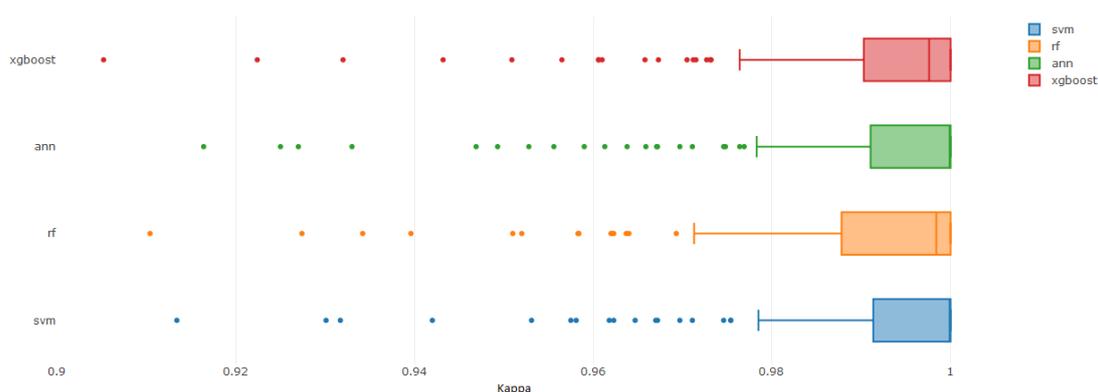


Figura 6.12: Comparação do kappa obtido com os diferentes algoritmos nas classificações com todos os *feature sets* excepto o FS 8, em todas as frequências de amostragem e com um período de análise entre 20 ms e 50 ms com os dados optisigma

Tal como verificado previamente com as classificações obtidas com base no *dataset CWRU*, as excelentes classificações registadas com o *dataset optisigma* devem-se principalmente aos *feature sets* e não necessariamente a nenhum algoritmo em concreto. Observando a Figura 6.12 é possível verificar que os 4 algoritmos utilizados registam desempenhos muito semelhantes, não havendo destaque para nenhum em concreto.

Os resultados obtidos com os cerca de 1000 modelos finais resultantes da análise da vibração com o *dataset optisigma* (840 modelos) e *CWRU* (144 modelos) estão descritos num documento disponível no [repositório gitlab](#). Estes incluem, para cada modelo, o valor do kappa, exatidão e abrangência obtidos, assim como a matriz de confusão.

#### 6.3.4 Identificação da Localização da Avaria no Rolamento

Dados os excelentes resultados obtidos da deteção da avaria através da vibração, e as características que o *dataset CWRU* oferece, foi também feito o estudo da deteção da avaria com identificação da localização da avaria com uma frequência de amostragem de 12 kHz (a única disponível). Assim como na classificação entre estado avariado e saudável, foi feita a escolha de utilizar o algoritmo RF como referência de forma a fazer uma primeira comparação entre *feature sets* sendo que, neste caso, além de ser feita a classificação do rolamento como saudável ou avariado, acrescenta-se o desafio da identificação da localização desta avaria entre pista interna, pista externa e esfera, sendo que passa a existir a noção de quatro classes:

- **Classe 1:** Rolamento saudável
- **Classe 2:** Rolamento com defeito na pista interna
- **Classe 3:** Rolamento com defeito na pista externa
- **Classe 4:** Rolamento com defeito na esfera

Na classificação entre quatro classes a relação entre desempenhos obtidos com os diferentes *feature sets* foram semelhantes aos observados na classificação entre duas classes, onde os *feature sets* 3, 5, 6, 7 e 8 apresentam o maior poder preditivo. Neste caso, a diferença é mais evidente entre *feature sets* e, como esperado dado o aumento de dificuldade na classificação, os kappas obtidos não são tão elevados, sendo possível observar a comparação entre o kappa obtido para os diferentes *feature sets* com um período de análise de 20 ms no gráfico 6.13.

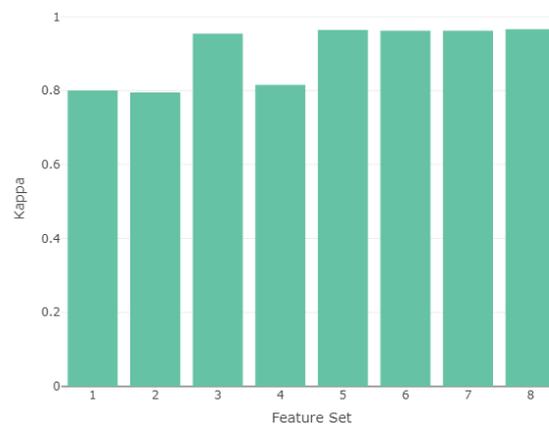


Figura 6.13: Comparação entre o kappa obtido com o algoritmo RF para os diferentes feature sets com um período de análise de 20 ms para a classificação entre quatro classes

Tal como realizado na classificação entre duas classes, foram também estudados períodos de análise superiores a 20 ms, tendo estes sido definidos de 20 ms a 100 ms com intervalos de 10 ms (20 ms, 30 ms, 40 ms, etc.) permitindo avaliar em que medida um período de análise alargado poderia melhorar a identificação da localização da avaria no rolamento.

Observando a variação do kappa obtido para todos os *feature sets* com o período de análise no gráfico 6.14, é interessante notar que, apesar da classificação entre duas classes também ter mostrado melhor desempenho com um maior período de análise, na classificação entre quatro classes este benefício é evidente em todos os *feature sets*. Tal como na classificação entre duas classes, os *feature sets* baseados em análises estatísticas mostram o maior aumento de desempenho com o aumento do período de análise.

Como constatado com um período de análise de 20 ms, os desempenhos dos *feature sets* 3, 5, 6, 7 e 8 continuam a ser os melhores de entre todos os *feature sets* para os períodos de análise estudados. No sentido de identificar o melhor *feature set* de entre este conjunto

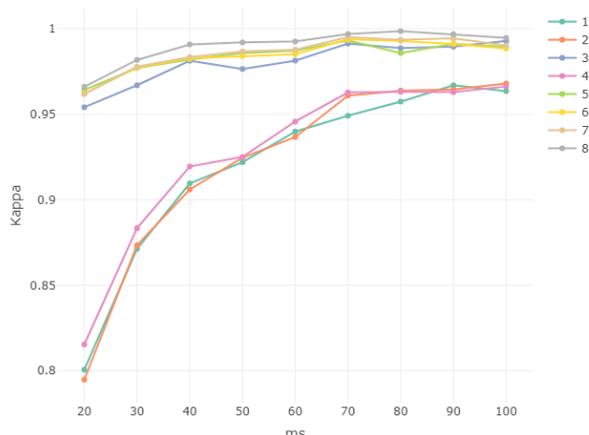


Figura 6.14: Variação do kappa obtido com o algoritmo RF segundo o período de análise para todos os *feature sets*

foi observada a Tabela 6.10 que apresenta o *feature set* com o melhor resultado obtido em termos de kappa para cada um dos períodos de análise utilizados, sendo que nesta se verifica que o *feature set* 8 regista os melhores resultados. Dado que o *feature set* 8 resulta da abordagem RFE foi também avaliado o melhor *feature set* definido através de outras abordagens pelo que, considerando apenas os resultados obtidos com os *feature sets* entre 1 e 7 (Tabela 6.11), observamos que o *feature set* 7 apresenta o melhor resultado em 7 das 9 classificações. Considerando os resultados registados nas tabelas mencionadas, e o destaque dos *feature sets* (7 e 8), a deteção da localização da avaria foi avaliada com diferentes algoritmos em detalhe com estes *feature sets*.

Tabela 6.10: Melhores resultados obtidos para cada período de análise e respetivo *feature set* com Random Forest

FS	ms	Kappa	Exatidão	Precisão
8	20	0.966	0.9746	1
8	30	0.9818	0.9863	1
8	40	0.9908	0.9931	1
8	50	0.992	0.994	1
8	60	0.9926	0.9944	1
8	70	0.9969	0.9977	1
8	80	0.9986	0.9989	1
8	90	0.9968	0.9976	1
8	100	0.9947	0.996	1

A avaliação dos *feature sets* 7 e 8 com diferentes algoritmos demonstrou resultados muito bons. Analisando os melhores resultados obtidos com todos os algoritmos utilizados na Tabela 6.12 observamos que os resultados são notáveis para praticamente todos os períodos de análise sendo que, principalmente para períodos de análise iguais ou superiores a 40 ms, os kappas obtidos são excelentes, mostrando o potencial destas *features* para a identificação da localização da avaria no rolamento.

### 6.3. DETEÇÃO DA AVARIA ATRAVÉS DA ANÁLISE DA VIBRAÇÃO

Tabela 6.11: Melhores resultados obtidos para cada período de análise e respetivo *feature set* (excluindo resultados obtidos com o *feature set 8*) com Random Forest

FS	ms	Kappa	Exatidão	Precisão
5	20	0.9643	0.9733	1
7	30	0.9778	0.9834	1
7	40	0.9834	0.9876	1
7	50	0.9867	0.99	1
7	60	0.9878	0.9908	0.9986
7	70	0.995	0.9963	1
7	80	0.9936	0.9952	1
7	90	0.9944	0.9958	1
3	100	0.9929	0.9947	1

Tabela 6.12: Melhores resultados obtidos para cada período de análise e respetivo *feature set* com todos os algoritmos

FS	ms	Algoritmo	Kappa	Exatidão	Precisão
8	20	xgb	0.9828	0.9871	1
8	30	xgb	0.9884	0.9913	1
8	40	xgb	0.9943	0.9958	1
8	50	xgb	0.9942	0.9957	0.9988
8	60	xgb	0.9952	0.9964	1
7	70	xgb	0.9994	0.9995	1
7	80	svm	0.9986	0.9989	1
8	80	rf	0.9986	0.9989	1
8	90	xgb	0.9984	0.9988	1
8	100	xgb, svm	0.9956	0.9967	1

Um importante aspeto a notar destes resultados obtidos é que a existência de classificações erradas, e consequentes kappas inferiores a 1, se devem à confusão entre estados avariados. Significa isto que, para a grande maioria dos modelos obtidos, a distinção entre estado saudável e avariado foi sempre correta, havendo apenas uma mínima confusão entre identificar se a avaria se deu na pista interna, externa ou esfera.

Tabela 6.13: Matriz de confusão da classificação obtida com o *feature set 7* e um período de análise de 70 ms com o algoritmo **XGBOOST**

		Referência			
		S	PI	PE	E
Previsão	S	605	0	0	0
	PI	0	516	0	0
	PE	0	0	515	0
	E	0	0	1	516

Apesar de, como mencionado previamente, os resultados serem excelentes a partir de um período de análise de 40 ms, a melhor classificação foi conseguida com um período de análise de 70 ms. A matriz de confusão desta classificação está descrita na Tabela 6.13

e é possível observar que, em 2153 classificações, o modelo apenas uma vez confundiu a localização da avaria como sendo na esfera em vez de na pista externa.

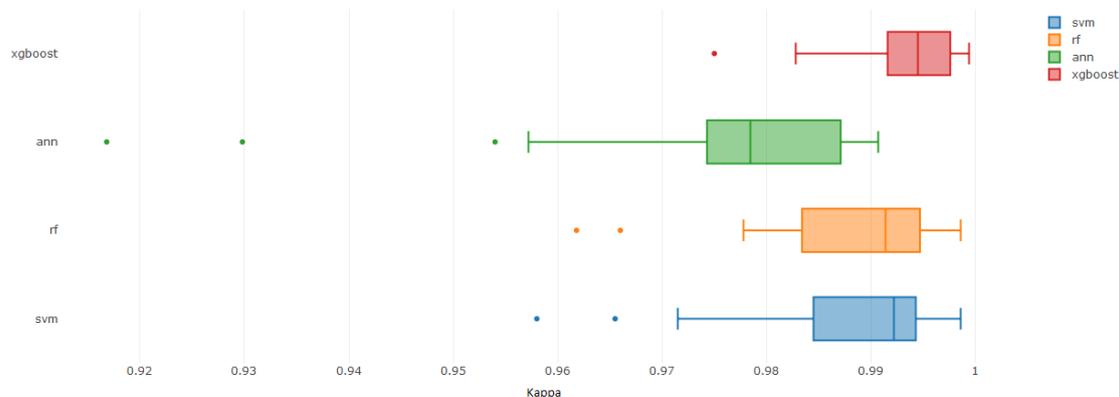


Figura 6.15: Comparação do kappa obtido com os 4 algoritmos nas classificações com os feature sets 7 e 8 e com um período de análise entre 20 ms e 100 ms com os dados [CWRU](#)

Comparando os desempenhos obtidos com os 4 algoritmos utilizados na identificação da localização da avaria observamos que o algoritmo [ANN](#) registou desempenhos ligeiramente inferiores aos restantes, sendo o [XGBOOST](#) o que se destaca. Apesar deste ligeiro destaque verifica-se um kappa regularmente elevado independentemente do algoritmo utilizado, permitindo assim comprovar a qualidade dos *feature sets*.

As matrizes de confusão dos modelos que obtiveram a melhor classificação com cada período de análise estão descritas no apêndice [D](#), sendo que os resultados obtidos com os 126 modelos finais resultantes da identificação da localização da avaria através da análise da vibração com o *dataset* [CWRU](#) estão descritos num documento disponível no [repositório gitlab](#). Estes incluem, para cada modelo, o valor do kappa e exatidão obtidos.

## 6.4 Detecção de Avaria através da Análise das Correntes

Após um primeiro estudo e avaliação das análises feitas às correntes, e respetivas *features* resultantes (na secção [5.2](#)), foi observado que o desvio de cada corrente a uma senoide perfeita e a análise estatística e espectral da [TPE](#) mostraram o maior potencial na classificação do estado de avaria do rolamento.

Dada a natureza do estudo efetuado na análise espectral da [TPE](#), destaca-se a necessidade de efetuar uma avaliação da quantidade indicada de número de picos de frequência a serem considerados num *feature set* resultante desta análise. Neste sentido, foi efetuada esta avaliação e consequente calibração do número de picos de frequência a serem utilizados em modelações futuras na secção [6.4.1](#). Em seguida, na secção [6.4.2](#), é feita a descrição dos *feature sets* constituídos, sendo a respetiva avaliação de resultados obtidos com os mesmos detalhada na secção [6.4.3](#).

### 6.4.1 Calibração da Análise Espectral da Transformada de Park Estendida

Dado o método utilizado para a fazer a análise espectral à TPE (descrito na secção 5.2.5), surgiu a necessidade de calibrar o mesmo avaliando o número de picos de frequência a serem utilizados em futuras modelações com *features* resultantes desta análise. Para tal, foi feita a modelação com um período de análise de 20 ms variando o número de picos analisados de 1 a 9 e observada a variação do kappa obtido em cada frequência de amostragem e do kappa médio. Pretende-se com esta calibração observar o comportamento geral do kappa consoante o aumento do número de picos analisados, procurando avaliar e obter o número de picos a partir dos quais o kappa deixa de indicar um ganho relevante e não o número de picos analisados onde se obtém o kappa máximo.

Dada a característica geral da assinatura espectral da TPE, previamente abordada na secção 5.2, em que a frequência dominante será sempre a de 0 Hz, a utilização da frequência a que o maior pico acontece foi descartada à partida para a utilização como *feature*. Sendo assim, do maior pico de frequência são apenas consideradas como *features* a intensidade e densidade espectral do mesmo.

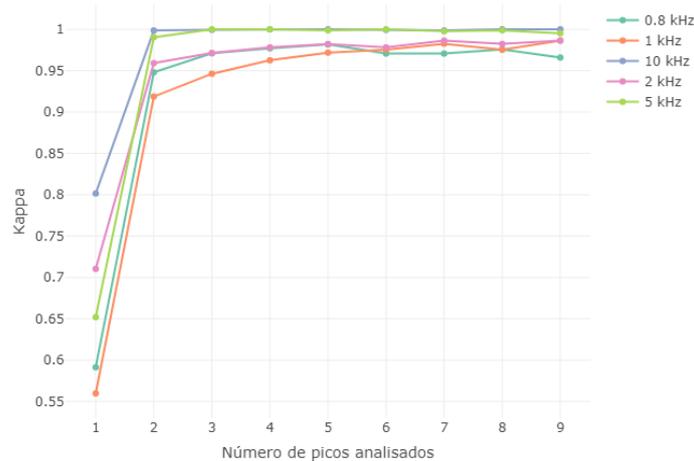


Figura 6.16: Variação do kappa obtido segundo o número de picos de frequência avaliados na análise espectral da TPE para diferentes frequências de amostragem

Observando o gráfico 6.16, que discrimina a variação do Kappa para cada frequência de amostragem é perceptível que, no geral, quanto maior a frequência de amostragem, melhor o desempenho com um menor número de picos de frequência analisados, sendo esta melhoria explicada não só pelo maior detalhe no sinal original, mas também pelo teorema de Nyquist que garante que uma maior frequência de amostragem oferece um maior intervalo de frequências a partir do qual pode ser feita a análise, possibilitando uma melhoria na informação a uma *feature* da natureza da densidade espectral.

Para todas as frequências de amostragem é observável uma melhoria muito relevante quando em vez do maior pico de frequência passam a ser analisados os 2 maiores picos de frequência, sendo que o aumento do kappa vai sendo mais moderado até atingir um

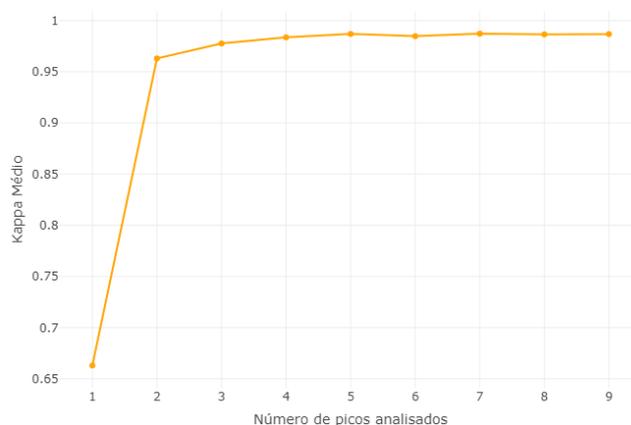


Figura 6.17: Variação do Kappa médio segundo o número de picos resultantes da análise espectral da TPE

ponto de relativa estagnação quando avaliados entre 5 a 9 picos. Neste sentido foi também observada a variação do Kappa médio no gráfico 6.17 (em detalhe na Tabela 6.14), e verificado o previamente observado pelo que ficou determinado que, para a análise espectral da TPE, seriam considerados e estudados os 5 maiores picos de frequência.

Tabela 6.14: Variação do Kappa médio segundo o número de picos resultantes da análise espectral da TPE

Nº de picos analisados	Kappa médio	Variação KM (%)
1	0.663	
2	0.9629	31.15
3	0.9776	1.49
4	0.9835	0.61
5	0.9869	0.34
6	0.9847	-0.22
7	0.9872	0.25
8	0.9864	-0.07
9	0.9868	0.03

Os resultados dos modelos resultantes destas avaliações encontram-se detalhados no apêndice B.

#### 6.4.2 Descrição dos *Feature Sets*

Como previamente mencionado, foi observado na secção 5.2 que o desvio de cada corrente a uma senoide perfeita e a análise estatística e espectral da TPE mostraram o maior potencial na classificação do estado de avaria do rolamento. Neste sentido, numa primeira fase foram definidos 3 *feature sets*: o primeiro *feature set* correspondendo às *features* resultantes do estudo do desvio de cada corrente a uma senoide perfeita, o segundo à análise estatística da TPE e o terceiro à análise espectral da TPE, sendo observado o

seu desempenho. Após um primeiro balanço dos desempenhos destes 3 *feature sets* foi observado o melhor desempenho por parte do terceiro (análise espectral da TPE), pelo que foram definidos outros 3 *feature sets* correspondendo a todas as combinações possíveis entre o terceiro *feature set* e os restantes (as combinações estão ilustradas na Figura 6.18).

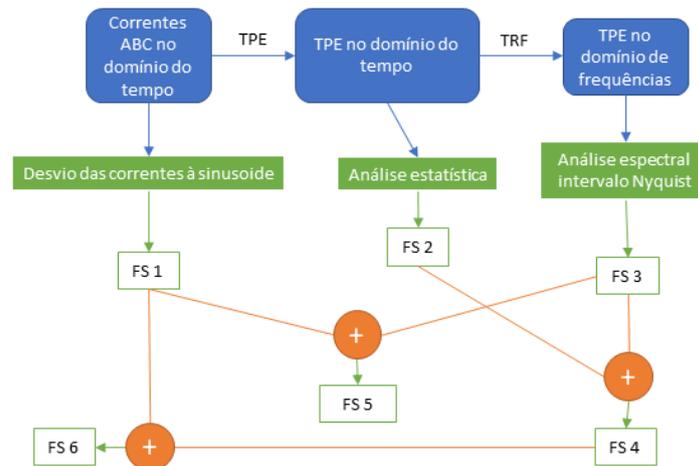


Figura 6.18: Esquema da constituição dos *feature sets* resultantes da análise das correntes

Além dos *feature sets* previamente mencionados foi também criado um resultante da avaliação da RFE ao conjunto de todas as *features* utilizadas para a classificação, ou seja, o conjunto de *features* do *feature set* 6, passando este a corresponder ao *feature set* 7.

A descrição detalhada de cada um dos *feature sets* encontra-se abaixo.

---

**FS 1. Média do desvio de cada corrente a uma senoide perfeita e desvio de cada corrente a uma senoide perfeita**

Cada linha é composta por 4 colunas, sendo que estas contêm a média do desvio de cada corrente a uma senoide perfeita e o desvio de cada uma das correntes a uma senoide perfeita, como descrito na sub-secção 5.2.3.

---

**FS 2. Análise estatística da TPE**

Cada linha é composta por 4 colunas, sendo que estas contêm a análise estatística da TPE (amplitude, assimetria, curtose e variância) no domínio do tempo, como descrito na sub-secção 5.2.5.

---

**FS 3. Análise espectral da TPE**

Cada linha é composta por 14 colunas, sendo que estas contêm a análise espectral dos 5 maiores picos de frequência (frequência, intensidade e densidade espectral de cada pico), como descrito na sub-secção 5.2.5. Do maior pico de frequência é usada apenas a sua intensidade e densidade espectral.

---

**FS 4. Análise espectral e estatística da TPE**

Cada linha é composta por 18 colunas, sendo que estas contêm a junção das features descritas nos feature sets 2 e 3.

**FS 5. Análise espectral da TPE + Média do desvio de cada corrente a uma senoide perfeita e desvio de cada corrente a uma senoide perfeita**

Cada linha é composta por 18 colunas, sendo que estas contêm a junção das features descritas nos feature sets 1 e 3.

**FS 6. Análise espectral e estatística da TPE + Média do desvio de cada corrente a uma senoide perfeita e desvio de cada corrente a uma senoide perfeita**

Cada linha é composta por 22 colunas, sendo que estas contêm a junção das features descritas nos feature sets 1, 2 e 3.

**FS 7. Recursive Feature Elimination**

Cada linha é composta por 19 colunas, sendo que estas contêm o conjunto de features com melhor resultados na RFE descrita na secção 6.4.2.1.

**6.4.2.1 Recursive Feature Elimination**

Na definição de um dos *feature sets*, à semelhança do que foi feito na deteção da avaria através da análise da vibração, foi utilizada a abordagem RFE. Dada a existência de múltiplas frequências de amostragem, foi feita a escolha de usar esta técnica na frequência de amostragem mais elevada disponível no *dataset* optisigma (10 kHz) dado apresentar a melhor versão do sinal.

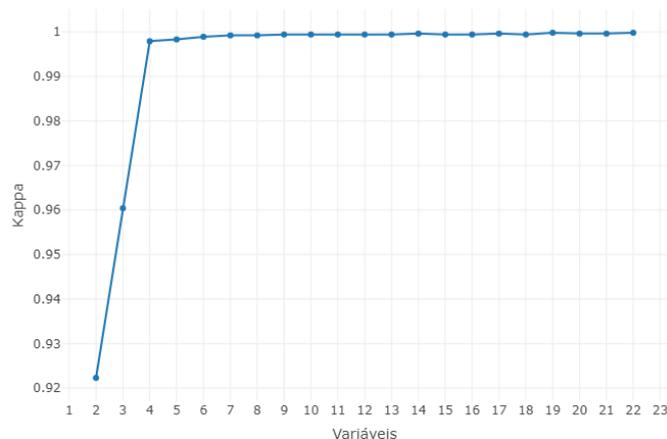


Figura 6.19: Variação do kappha obtido com a RFE

Como é possível observar no gráfico 6.19, que ilustra a variação do kappha obtido consoante o número de variáveis utilizadas para a classificação, existe uma melhoria

muito relevante do kappa até à utilização de 4 variáveis, sendo que a partir daí o valor fica relativamente estagnado mas continua a registar ligeiras melhorias. O melhor resultado foi obtido com 19 variáveis sendo estas todas as resultantes dos 5 picos da análise espectral da TPE exceto a intensidade do terceiro maior pico de frequência, a amplitude da TPE, os desvios das correntes A e B a uma senoide perfeita e a a média dos desvios de todas as correntes (A, B e C).

Os resultados detalhados do uso desta técnica para a definição de um *feature set* estão detalhados no apêndice C na secção C.2.

### 6.4.3 Distinção entre Estado Avariado e Saudável

Como efetuado na deteção da avaria através da análise da vibração, foi feita a escolha de utilizar o algoritmo RF como referência de forma a fazer uma primeira comparação entre *feature sets*. Nesta comparação, com o objetivo de discriminar quais teriam o maior potencial preditivo, foi calculado o kappa médio obtido com cada um com um período de análise de 20 ms (correspondente a um ciclo das correntes) e observado o seu comportamento. Como é possível observar na Figura 6.20, os *feature sets* 1 e 2 apresentam um desempenho relativamente baixo quando comparados com os restantes, mostrando um relativo baixo poder preditivo, sendo que os restantes exibem resultados prometedores com diferenças muito ligeiras entre eles e classificações praticamente perfeitas (ou perfeitas) com frequências de amostragem elevadas.

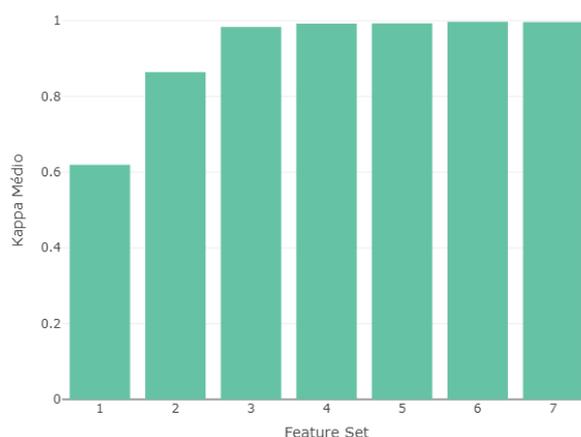


Figura 6.20: Comparação entre o kappa médio obtido para os diferentes feature sets com um período de análise de 20 ms

Com o objetivo de avaliar se o aumento do período de análise poderia beneficiar a classificação, e aumentar a certeza da deteção da avaria, foram também definidos outros períodos de análise. Ao contrário do que foi feito na análise da vibração em que foram definidos períodos de análise de 20 ms a 100 ms com variações de 10 ms em 10 ms, e tendo em conta a grandeza física em questão (correntes), foram definidos períodos de análise entre 20 ms e 100 ms com variações de 20 ms representando 1, 2, 3, 4 ou 5 ciclos das correntes. Apesar de haver uma clara distinção entre os *feature sets* com maior

poder preditivo considerando um período de análise de 20 ms, nenhum dos *feature sets* foi descartado do estudo da variação do kappa médio com o aumento deste período de análise.

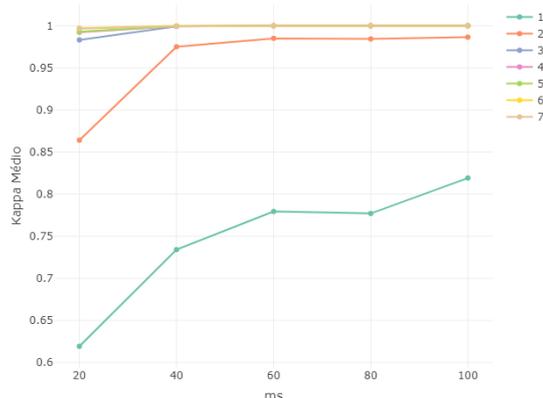


Figura 6.21: Variação do kappa médio de todos os *feature sets* segundo o período de análise

Ao observar esta variação na Figura 6.21, é possível verificar que apesar de se constatarem claras melhorias no desempenho de todos os *feature sets* com o aumento do período de análise (sendo estas melhorias muito relevantes nos *feature sets* com menor poder preditivo com um período de análise de 20 ms), os *feature sets* 1 e 2 não aparentam apresentar, de facto, o mesmo potencial quando comparados com os restantes (apesar de o *feature set* 2 se aproximar mais dos restantes). Os *feature sets* 3, 4, 5, 6 e 7 apresentam melhorias maioritariamente quando passam a ser analisados dois ciclos de corrente em vez de um, sendo que a partir desse ponto o kappa médio é sempre praticamente 1.

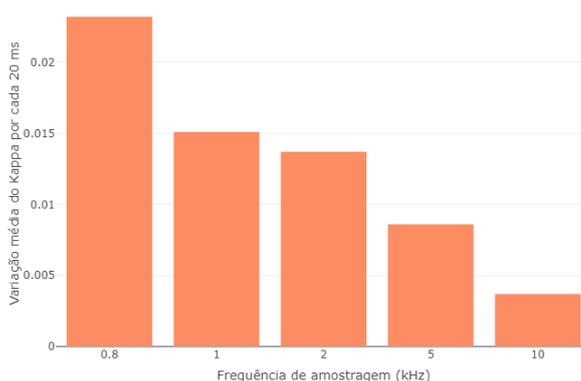


Figura 6.22: Variação média do kappa obtido com todos os *feature sets* a cada aumento do período de análise em 10 ms para cada uma das frequências de amostragem utilizadas com o *dataset* optisigma

Observando a variação média do kappa a cada aumento do período de análise em 20 ms em todos os *feature sets* para cada uma das frequências de amostragem utilizadas no gráfico 6.22 é possível verificar que, tal como constatado na deteção da avaria através da análise da vibração, todas as frequências de amostragem beneficiam do aumento do período de análise, sendo este aumento especialmente benéfico para frequências de

amostragem baixas. À medida que é aumentada a frequência de amostragem, diminui o aumento do kappa médio a cada aumento do período de análise em 20 ms pelo que diminui a necessidade de um maior período de análise.

Dado que o objetivo do estudo destes resultados passa por, não só identificar o melhor conjunto de *features* para classificação do estado de avaria do rolamento com base na análise das correntes, mas também estudar o impacto que a frequência de amostragem e o período de análise das correntes pode ter nesta classificação, todos os *feature sets* foram analisados ao pormenor. Observando em detalhe o desempenho dos *feature sets* 1 e 2 com a variação da frequência da amostragem e do período de análise na Figura 6.23, confirmamos que o *feature set* 1 não apresenta resultados prometedores em nenhuma situação (quando comparado com os restantes), sendo que o *feature set* 2 demonstra um maior potencial principalmente quando utilizado com um período de análise igual ou superior a 40 ms e a partir de uma frequência de amostragem de cerca de 2 kHz, sendo que a partir de um período de análise de 80 ms os resultados são bastante bons com qualquer frequência de amostragem.

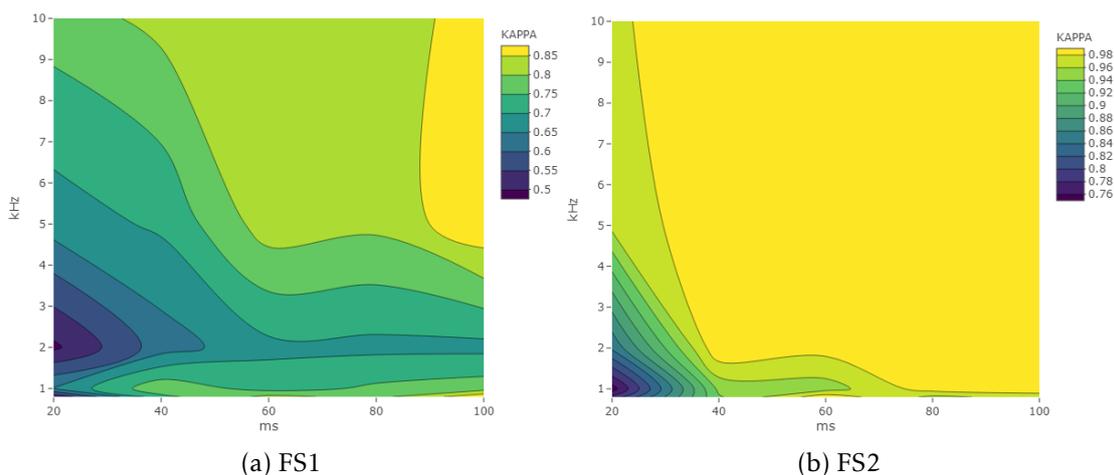


Figura 6.23: Variação do kappa obtido consoante o período de análise e a frequência de amostragem para os feature sets 1 e 2

Ao observar as variações do kappa obtido consoante o período de análise e frequência de amostragem para os *feature sets* 3, 4, 5, 6 e 7, verifica-se que os desempenhos são, no geral, excelentes e que a classificação tende a ser perfeita com qualquer frequência de amostragem a partir de um período de análise de 40 ms ou com uma frequência de amostragem de 5 kHz para um período de análise de 20 ms.

O *feature set* 3, cuja variação do kappa é visível na Figura 6.24a, exibe um kappa na ordem dos 0.97 com o período de análise e frequência de amostragem mínima (20 ms e 0.8 kHz), sendo que os *feature sets* 4, 5, 6 e 7 apresentam nas Figuras 6.24b, 6.25a, 6.25b e 6.26 kappas na ordem os 0.99, 0.98, 0.99 e 0.99, respetivamente, nas mesmas condições. Principalmente em relação aos *feature sets* 4, 5, 6 e 7 é evidente a excelente classificação

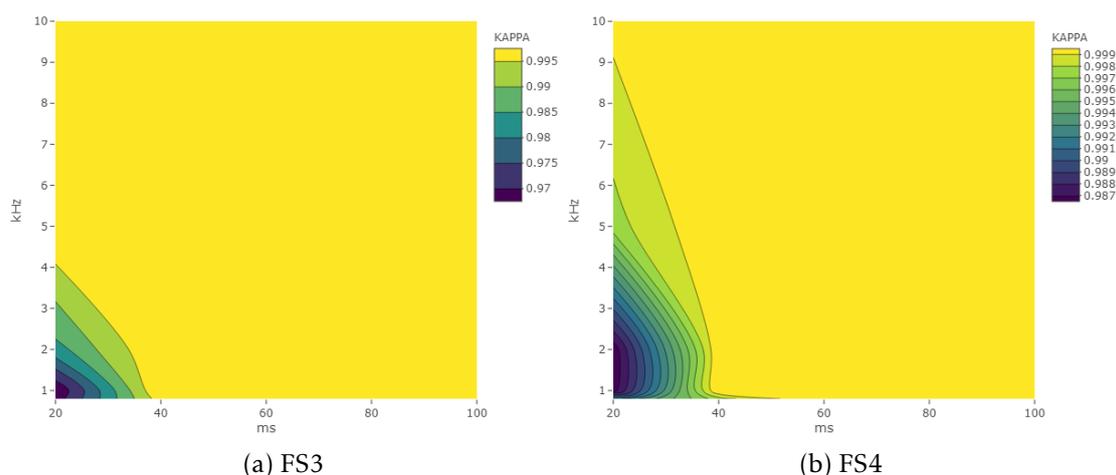


Figura 6.24: Variação do kappa obtido consoante o período de análise e a frequência de amostragem para os feature sets 3 e 4

independentemente das condições em que a análise é feita em termos de tempo e frequência de amostragem, sendo isto visível na própria escala dos gráficos 6.24b, 6.25a, 6.25b e 6.26. Estes gráficos permitem também concluir que os *feature sets* 4, 5, 6 e 7, que são basicamente *features* resultantes da análise espectral da TPE complementados com *features* resultantes de outras análises, parecem apresentar principalmente melhorias nos desempenhos com frequências de amostragem até 2 kHz comparativamente com o *feature set* 3, sendo que os desempenhos com frequências de amostragem superiores são semelhantes. Com um período de análise de 20 ms, os *feature sets* com melhor desempenho para as frequências de amostragem de 0.8 kHz, 1 kHz e 2 kHz foram os *feature sets* 4, 5 e 6, respetivamente, com ligeiras diferenças entre os desempenhos dos mesmos, pelo que nenhum se destaca à partida como sendo o melhor.

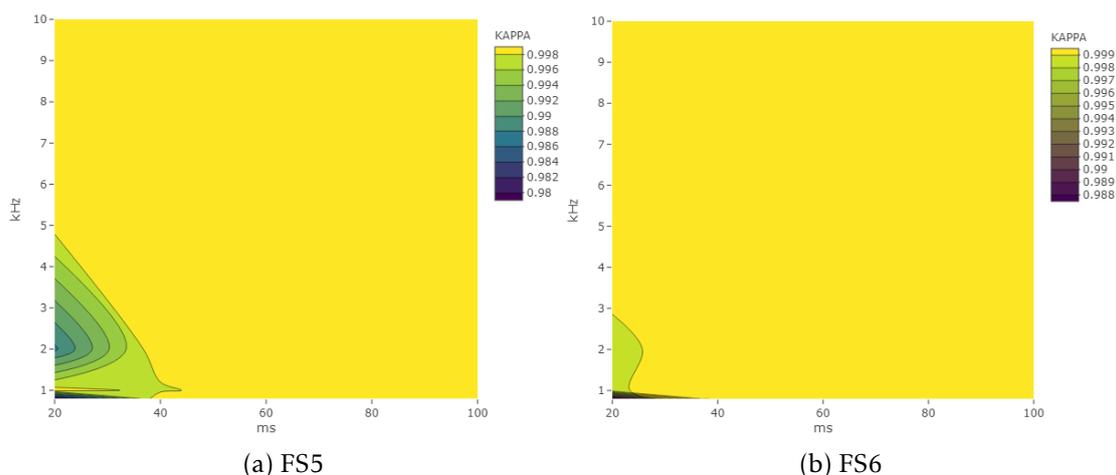


Figura 6.25: Variação do kappa obtido consoante o período de análise e a frequência de amostragem para os feature sets 5 e 6

Apesar de existirem situações em que o *feature set* 2 apresenta bons resultados ao

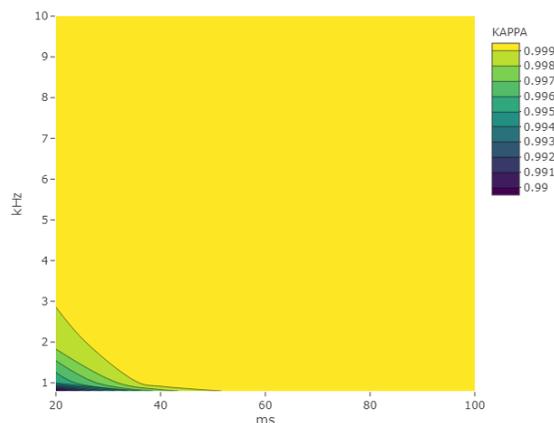


Figura 6.26: Variação do kapa obtido consoante o período de análise e a frequência de amostragem para o feature set 7

observar a variação do kapa obtido consoante o período de análise e a frequência de amostragem do mesmo, ao ser comparado com os restantes concluímos, no entanto, que existem *feature sets* alternativos cujos resultados são melhores com um período de análise e uma frequência de amostragem inferior pelo que o *feature set 2*, juntamente com o *feature set 1*, foram identificados como tendo um poder preditivo inferior aos restantes e descartados de futuras modelações.

Identificados os *feature sets* com maior poder preditivo como sendo os *feature sets 3, 4, 5, 6 e 7*, procedeu-se a uma análise mais pormenorizada dos mesmos. Observando a Figura 6.27, é possível verificar que existe uma distinção, ainda que mínima (eixo das ordenadas começa a partir de um kapa de cerca de 0.96), entre os resultados obtidos pelos mesmos quando utilizando um período de análise de 20 ms, sendo que esta vai naturalmente diminuindo com o aumento deste período de análise. Verifica-se, ainda, que são obtidos resultados perfeitos com todas as frequências de amostragem a partir de um período de análise de 60 ms, com todos os *feature sets* em questão.

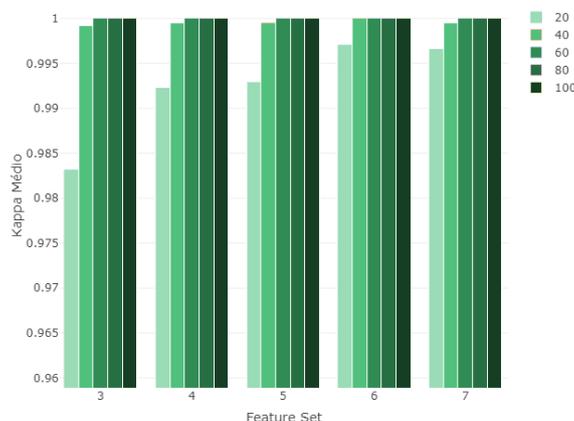


Figura 6.27: Comparação do kapa médio para os features sets com maior poder preditivo com diferentes períodos de análise

No sentido de, não só obter melhores resultados, mas também ter um termo de comparação entre resultados obtidos, foram então avaliados os desempenhos com os 4 algoritmos utilizados nesta dissertação (RF, SVM, ANN e XGBOOST). Esta comparação permite, do mesmo modo, concluir se os resultados se devem ao excelente desempenho de um dado algoritmo ou à qualidade dos *feature sets* disponíveis.

Tabela 6.15: Melhores resultados obtidos com os feature sets com maior poder preditivo para cada frequência de amostragem e período de análise de 20 ms

FS	kHz	Algoritmo	Kappa	Exatidão	VP	FP	VN	FN
3	0.8	xgboost	0.9711	0.9913	2247	8	496	16
3	1	svm	0.9718	0.9918	2301	8	484	15
3	2	xgboost	0.989	0.9967	2000	5	442	3
3	5	rf, xgboost	1	1	2361	0	507	0
3	10	xgboost, svm	1	1	3366	0	897	0
4	0.8	xgboost	0.9916	0.9975	2256	0	504	7
4	1	xgboost	0.9877	0.9964	2312	6	486	4
4	2	svm	0.9905	0.9971	1997	1	446	6
4	5	svm	1	1	2361	0	507	0
4	10	svm	1	1	3366	0	897	0
5	0.8	svm	0.9879	0.9964	2258	5	499	5
5	1	rf	0.9988	0.9996	2315	0	492	1
5	2	rf	0.9876	0.9963	2002	8	439	1
5	5	xgboost	1	1	2361	0	507	0
5	10	rf, xgboost	1	1	3366	0	897	0
6	0.8	svm	0.9915	0.9975	2258	2	502	5
6	1	rf, xgboost, svm	0.9988	0.9996	2315	0	492	1
6	2	rf	0.9986	0.9996	2003	1	446	0
6	5	rf, xgboost, svm	1	1	2361	0	507	0
6	10	rf, svm	1	1	3366	0	897	0
7	0.8	svm	0.9928	0.9978	2257	0	504	6
7	1	rf	0.9951	0.9986	2315	3	489	1
7	2	rf	0.9986	0.9996	2002	0	447	1
7	5	rf, xgboost, svm	1	1	2361	0	507	0
7	10	rf, xgboost	1	1	3366	0	897	0

Como é possível observar na Tabela 6.15, que mostra os resultados obtidos com um período de análise de 20 ms, os resultados são muito bons (com kappas superiores a 0.97) para qualquer um dos *feature sets*, sendo claro um ligeiro melhor desempenho com os *feature sets* 5, 6 e 7. Além de melhores resultados, é também possível observar que esses resultados são obtidos por diversos algoritmos, validando a qualidade do *feature set*. É também perceptível que, com uma frequência de amostragem igual ou superior a 5 kHz, qualquer dos *feature sets* registra um kappa perfeito. Para o período de análise mínimo o melhor resultado com a frequência de amostragem de 0.8 kHz foi obtido com o *feature set* 7, sendo que com uma frequência de amostragem de 1 kHz foi obtido com os *feature sets* 5 e 6 e com uma frequência de amostragem de 2 kHz foi obtido com os *feature sets* 6 e 7.

Tabela 6.16: Melhores resultados obtidos com os feature sets com maior poder preditivo para cada frequência de amostragem e período de análise de 40 ms

FS	kHz	Algoritmo	Kappa	Exatidão	VP	FP	VN	FN
3	0.8	rf, xgboost	0.9976	0.9993	1131	1	251	0
3	1	rf, svm	1	1	1157	0	246	0
3	2	rf, svm	1	1	999	0	222	0
3	5	rf, xgboost, svm	1	1	1176	0	252	0
3	10	svm	1	1	1680	0	447	0
4	0.8	rf, ann, svm	0.9976	0.9993	1131	1	251	0
4	1	rf, xgboost, svm	1	1	1157	0	246	0
4	2	rf	1	1	999	0	222	0
4	5	rf, xgboost, svm	1	1	1176	0	252	0
4	10	rf, xgboost, svm	1	1	1680	0	447	0
5	0.8	rf, xgboost, svm	1	1	1131	0	252	0
5	1	rf, xgboost	0.9975	0.9993	1156	0	246	1
5	2	rf	1	1	999	0	222	0
5	5	rf, xgboost, ann, svm	1	1	1176	0	252	0
5	10	rf, xgboost	1	1	1680	0	447	0
6	0.8	rf, ann, svm	1	1	1131	0	252	0
6	1	rf, xgboost, svm	1	1	1157	0	246	0
6	2	rf, xgboost, svm	1	1	999	0	222	0
6	5	rf, xgboost, ann, svm	1	1	1176	0	252	0
6	10	rf, xgboost, ann	1	1	1680	0	447	0
7	0.8	svm	1	1	1131	0	252	0
7	1	rf, xgboost, svm	1	1	1157	0	246	0
7	2	rf, xgboost, svm	1	1	999	0	222	0
7	5	rf, xgboost, ann, svm	1	1	1176	0	252	0
7	10	rf, xgboost, ann, svm	1	1	1680	0	447	0

Com um período de análise de 40 ms, visível na Tabela 6.16, passamos a verificar que os resultados obtidos são perfeitos com praticamente todos os *feature sets* em praticamente todas as frequências de amostragem. A partir de uma frequência de amostragem mínima de 1 kHz é garantida uma classificação perfeita recorrendo apenas às *features* resultantes da análise estatística ou espectral da TPE, sendo que os *feature sets* 6 e 7 garantem resultados perfeitos independentemente da frequência de amostragem e com diversos algoritmos.

A partir de um período de análise de 60 ms verifica-se que qualquer dos *feature sets* exhibe resultados perfeitos independentemente da frequência de amostragem com diversos algoritmos.

Em termos de classificações perfeitas, é possível observar na Tabela 6.17 que os *feature sets* 5, 6 e 7 apresentam resultados equivalentes com todas as frequências de amostragem utilizadas. Com uma frequência de amostragem até 2 kHz, é necessário analisar dois ciclos de correntes de forma a garantir uma classificação perfeita, sendo que a partir de uma frequência de amostragem de 5 kHz a classificação é perfeita analisando apenas um

ciclo de correntes.

Tabela 6.17: Período de análise mínimo (ms) para atingir uma classificação perfeita para cada *feature set* por frequência de amostragem (kHz)

	Freq. de amostragem				
	0.8	1	2	5	10
<b>1</b>	-	-	-	-	-
<b>2</b>	-	-	-	-	40
<b>3</b>	60	40	40	20	20
<b>FS 4</b>	60	40	40	20	20
<b>5</b>	40	40	40	20	20
<b>6</b>	40	40	40	20	20
<b>7</b>	40	40	40	20	20

Observando os resultados obtidos com os diferentes algoritmos utilizados na Figura 6.28 é possível verificar que todos obtiveram resultados semelhantes com ligeiro destaque negativo para a ANN. Estes desempenhos semelhantes são indicadores de que os resultados se devem maioritariamente à qualidade das *features* e não necessariamente a um algoritmo em concreto.

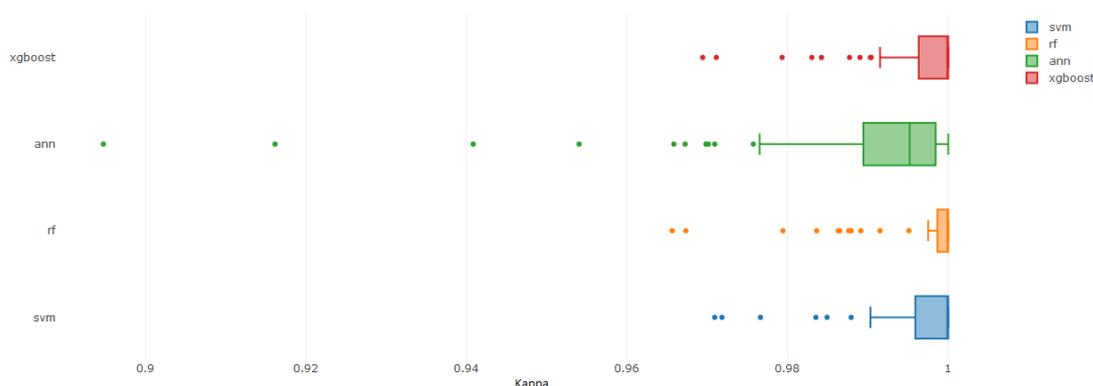


Figura 6.28: Comparação do kappa obtido com os 4 algoritmos nas classificações com os feature sets 3, 4, 5, 6 e 7 com um período de análise entre 20 ms e 60 ms com os dados optisigma

É possível concluir que, em relação à deteção da avaria no rolamento com base na análise das correntes elétricas, conseguimos obter excelentes resultados de classificação analisando apenas um ciclo das correntes elétricas, ou seja 20 ms, registando kappas superiores a 0.99 independentemente da frequência de amostragem, sendo que usando uma frequência de amostragem igual ou superior a 5 kHz a classificação é perfeita. A partir de um período de análise de 40 ms, ou seja, dois ciclos das correntes elétricas, passam a ser obtidos resultados perfeitos ( $kappa = 1$ ) independentemente da frequência de amostragem.

Os resultados completos estão descritos num documento disponível no [repositório gitlab](#) e incluem, para cada modelo, o valor do kappa, exatidão e abrangência obtidos, assim como a matriz de confusão.

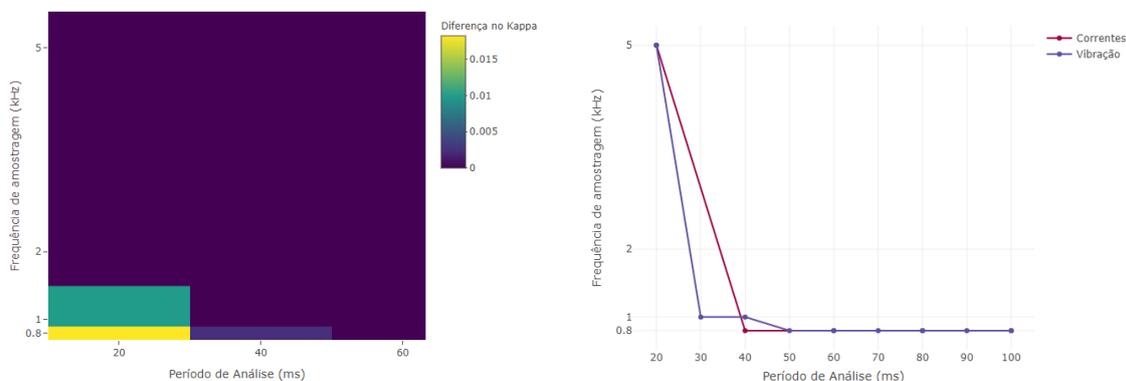
## CONCLUSÃO E TRABALHO FUTURO

### 7.1 Conclusão

O trabalho realizado nesta dissertação mostrou ser possível atingir excelentes resultados na detecção de avarias nos rolamentos de **MITs** utilizando frequências de amostragem baixas e períodos de análises curtos com o uso de técnicas de aprendizagem automática, tendo sido registadas classificações perfeitas com diversos algoritmos através da análise da vibração e das correntes elétricas do motor. De entre as diferentes análises efetuadas destacaram-se a análise espectral a nível da vibração e a análise espectral da **TPE** a nível das correntes.

O estudo da capacidade de detecção da avaria no rolamento com diferentes frequências de amostragem e períodos de análise, realizado dado o evidente interesse económico da indústria na utilização de sensores com a frequência de amostragem mínima necessária, foi algo não observado na literatura estudada e mostrou que, na detecção da avaria através de ambas as grandezas físicas é possível registar classificações perfeitas com qualquer das frequências de amostragem estudadas, sendo que a questão se trata basicamente de um equilíbrio entre o período de análise e a frequência de amostragem utilizados. No uso industrial, a decisão reside sobre o tempo conveniente e adequado para fazer a recolha de dados e o custo monetário dos sensores de cada frequência de amostragem. Numa comparação direta entre a detecção da avaria no rolamento através de cada uma das grandezas físicas em questão, a análise das correntes aparenta oferecer a possibilidade de utilização de uma frequência de amostragem inferior à necessária na análise da vibração para obter o mesmo nível de resultados (não necessariamente perfeitos), como é possível observar na Figura 7.1a, sendo isto esperado dado que a percentagem de sinal perdida na vibração para frequências baixas é superior à do sinal das correntes elétricas. A nível da frequência de amostragem mínima necessária para registar uma classificação perfeita,

o gráfico 7.1b mostra que a análise das correntes elétricas regista estes resultados com frequências de amostragem inferiores e o mesmo período de análise quando comparada com a análise da vibração. Com as frequências de amostragem adequadas, ambas mostram um excelente potencial em termos de classificação.



(a) Diferença no kappa a favor da classificação baseada na análise das correntes elétricas em comparação com a análise da vibração para diferentes frequências de amostragem e períodos de análise

(b) Frequência de amostragem mínima para uma classificação perfeita com cada período de análise

Figura 7.1: Comparação entre a classificação através da análise das correntes elétricas e da vibração

Ao comparar os resultados obtidos nesta dissertação com os observados na literatura descrita no estado da arte do capítulo 4, verifica-se que estes demonstram a capacidade de deteção da avaria nos rolamentos dos motores com o uso de frequências de amostragem e períodos de análise inferiores aos observados na mesma, apresentando também a mais valia da avaliação da capacidade de deteção através da análise de duas grandezas físicas ter sido realizada com a utilização de registos simultâneos da vibração e das correntes elétricas resultantes do mesmo *setup* experimental (evitando variações de resultados causadas por alterações no mesmo).

Em termos da deteção da avaria no rolamento com identificação da localização da mesma, o estudo baseado na análise do sinal de vibração com uma frequência de amostragem de 12 kHz mostrou que a qualidade da classificação apresenta claros benefícios com o aumento do período de análise registando excelentes resultados principalmente a partir de 40 ms. Tal como na deteção da avaria sem discriminação da localização da mesma, a análise espectral da vibração mostrou o maior potencial de classificação, exibindo ligeiras melhorias com a junção de *features* resultantes de análises estatísticas.

Concluindo, a análise de qualquer das grandezas físicas em questão para a deteção de avaria no rolamento de *MEs* mostra resultados notáveis, sendo que a validação dos métodos ilustrados ao longo desta dissertação para a deteção da avaria através da vibração com diferentes *datasets* e para avarias distintas de intensidades mínimas se mostra importante. Apesar de ser mais comum a utilização de medições de grandezas físicas que registam

o movimento mecânico do motor para avarias do foro mecânico e grandezas físicas que registam o comportamento elétrico para avarias elétricas, a utilização dos métodos propostos para a análise das correntes mostra o potencial de ser a opção mais indicada para o uso industrial dada a facilidade da monitorização das correntes de diversos motores através do quadro de distribuição dos motores quando comparada com a necessidade de colocação de acelerómetros na carcaça de cada ME para a monitorização da vibração.

O trabalho realizado nesta dissertação resultou na submissão aceite de um artigo para a *IEEE International Conference on Industrial Technology 2019* sendo que, por motivos de força maior, a sua submissão final e apresentação não foi realizada.

Além da deteção da avaria no rolamento, foi também realizada a identificação do diâmetro da avaria numa perspetiva de regressão com ambas as grandezas físicas do *dataset* optisigma. Os resultados estão disponíveis no [repositório gitlab](#) e, à semelhança do observado na deteção da avaria descrita nesta dissertação, foram excelentes, demonstrando uma diminuição do erro médio absoluto com o aumento da frequência de amostragem e do período de análise para ambas as grandezas físicas.

## 7.2 Trabalho Futuro

O trabalho realizado nesta dissertação, e a comparação entre a utilização de duas grandezas físicas distintas para a deteção de avaria nos rolamentos de ME, deixa diversas portas abertas nomeadamente devido às limitações dos dados de correntes elétricas em comparação com os dados de vibração. Considerando estas limitações, seria interessante testar os métodos de deteção com base na análise das correntes propostos nesta dissertação em avarias de diâmetro menor (possivelmente feitas através do mesmo processo de eletroerosão utilizado experimentalmente nas avarias do *dataset* CWRU), e em avarias em componentes diferentes do rolamento (pista interna e esfera). Além deste ponto, seria de extrema importância ter acesso a dados provenientes de motores diferentes (nomeadamente a nível de potência, velocidade de rotação nominal do rotor, etc.) de modo a avaliar os procedimentos utilizados em condições distintas e, desta forma, possibilitar a criação de modelos mais robustos com uma maior capacidade de generalização.

Além da deteção de avaria no rolamento através das grandezas físicas mencionadas previamente, a utilização de ultra-sons para a realizar também é relativamente frequente e, teoricamente, um melhor indicador que as correntes, pelo que seria útil realizar uma comparação com os resultados obtidos nesta dissertação a nível de frequências de amostragem e períodos de análise necessários para obter excelentes classificações.

No contexto do projecto REARM II da Altran Portugal, dado que foram estudadas avarias nos dois componentes dos MITs em que as falhas são mais frequentes (rolamento e estator), representando cerca de 75% das avarias, seria também pertinente fazer um estudo semelhante para as avarias no rotor que se exhibe como o componente com maior incidência de avarias além dos mencionados.



## BIBLIOGRAFIA

- [1] U4E. *Accelerating the Global Adoption of Energy-efficient Electric Motors and Motor Systems*. United Nations Environment Programme. 2017.
- [2] P. Waide e C. U. Brunner. “Energy-efficiency policy opportunities for electric motor-driven systems”. Em: (2011), pp. 11–17.
- [3] R Saidur. “A review on electrical motors energy use and energy savings”. Em: *Renewable and Sustainable Energy Reviews* 14.3 (2010), pp. 877–898.
- [4] F. J.T. E. Ferreira. “Strategies to improve the performance of three-phase induction motor driven systems”. Tese de doutoramento. 2009.
- [5] F. J.T. E. Ferreira e S. M. A. Cruz. “Visão geral sobre selecção, controlo e manutenção de motores de indução trifásicos”. Em: *Manutenção 101* (2009), pp. 46–53.
- [6] F. J.T. E. Ferreira e S. M. A. Cruz. “Visão geral sobre selecção, controlo e manutenção de motores de indução trifásicos”. Em: *Manutenção 101* (2009), pp. 8–15.
- [7] T. dos Santos. “Machine Learning for On-line Detection of Stator Winding Short-Circuit faults in Induction Motors”. Tese de mestrado. Faculdade de Ciências e Tecnologia - Universidade Nova de Lisboa, mar. de 2017.
- [8] A. T. De Almeida, F. Ferreira, J. Fong e P. Fonseca. “EUP Lot 11 Motors”. Em: *Technical Study for Ecodesign Directive, mandated by European Commission, Coimbra Portugal, April* (2008).
- [9] E. L. Bonaldi, L. E. de Lacerda de Oliveira, J. G. B. da Silva, G. Lambert-Torres e L. E. B. da Silva. *Predictive Maintenance by Electrical Signature Analysis to Induction Motors*. 2012.
- [10] K. Ágoston. “Fault Detection of the Electrical Motors Based on Vibration Analysis”. Em: *Procedia Technology* 19 (2015). 8th International Conference Interdisciplinarity in Engineering, INTER-ENG 2014, 9-10 October 2014, Tirgu Mures, Romania, pp. 547 –553. ISSN: 2212-0173. DOI: <https://doi.org/10.1016/j.protcy.2015.02.078>. URL: <http://www.sciencedirect.com/science/article/pii/S2212017315000791>.
- [11] M. F. Alves. *Abc das máquinas eléctricas*. Mar. de 2003.
- [12] A. E. Fitzgerald, J. Charles Kingsley e S. D. Umans. *Electric Machinery (Sixth Edition)*. 2003. ISBN: 0-07-112193-5.

- [13] B. S. Guru e H. R. Hiziroglu. *Electric Machinery and Transformers*. 2001. ISBN: 978-0-19-513890-0.
- [14] E. Alpaydin. *Introduction to machine learning (Second Edition)*. MIT press, 2014. ISBN: 978-0-262-01243-0.
- [15] S. Marsland. *Machine learning: an algorithmic perspective (Second Edition)*. CRC press, 2015. ISBN: 978-1-4665-8333-7.
- [16] M. V. Guedes. “O Motor de Indução Trifásico”. Em: *DEEC, FEUP* (1994).
- [17] D. Miljković. “Brief Review of Motor Current Signature Analysis”. Em: 5 (jun. de 2015), pp. 14–26.
- [18] C. Cortes e V. Vapnik. “Support-Vector Networks”. Em: *Mach. Learn.* 20.3 (set. de 1995), pp. 273–297. ISSN: 0885-6125. DOI: 10.1023/A:1022627411411. URL: <https://doi.org/10.1023/A:1022627411411>.
- [19] A. Lorena, C. e Cognition, A. Carvalho, D. de Ciências de Computação, I. de Ciências Matemáticas e de Computação e U. “Uma Introdução às Support Vector Machines”. Em: 14 (jan. de 2007).
- [20] L. Breiman. “Random Forests”. Em: *Mach. Learn.* 45.1 (out. de 2001), pp. 5–32. ISSN: 0885-6125. DOI: 10.1023/A:1010933404324. URL: <https://doi.org/10.1023/A:1010933404324>.
- [21] G. Bonaccorso. *Machine Learning Algorithms: A Reference Guide to Popular Algorithms for Data Science and Machine Learning*. Packt Publishing, 2017. ISBN: 1785889621, 9781785889622.
- [22] T. Chen e C. Guestrin. “XGBoost: A Scalable Tree Boosting System”. Em: *Proceedings of the 22Nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. KDD '16. New York, NY, USA: ACM, 2016, pp. 785–794. ISBN: 978-1-4503-4232-2. DOI: 10.1145/2939672.2939785. URL: <http://doi.acm.org/10.1145/2939672.2939785>.
- [23] J. H. Friedman. “Greedy Function Approximation: A Gradient Boosting Machine”. Em: *Annals of Statistics* 29 (2001), pp. 1189–1232.
- [24] R. R. Schoen, T. G. Habetler, F. Kamran e R. G. Bartfield. “Motor bearing damage detection using stator current monitoring”. Em: *IEEE Transactions on Industry Applications* 31.6 (nov. de 1995), pp. 1274–1279. ISSN: 0093-9994. DOI: 10.1109/28.475697.
- [25] M. J. M. Gonçalves. “Técnicas avançadas de processamento de sinal no diagnóstico de avarias em rolamentos de motores de indução trifásicos”. Tese de mestrado. Universidade de Coimbra, set. de 2015.
- [26] M Feldman. “Hilbert transforms”. Em: (2001). DOI: 10.1006/rwvb.2001.0057.

- [27] A. D. Poularikas. *Handbook of Formulas and Tables for Signal Processing*. CRC press, 1998. ISBN: 9780849385797.
- [28] P. Konar e P. Chattopadhyay. “Bearing fault detection of induction motor using wavelet and Support Vector Machines (SVMs)”. Em: *Appl. Soft Comput.* 11.6 (2011), pp. 4203–4211. DOI: [10.1016/j.asoc.2011.03.014](https://doi.org/10.1016/j.asoc.2011.03.014). URL: <https://doi.org/10.1016/j.asoc.2011.03.014>.
- [29] L. Oliveira e A. Cardoso. “Extended Park’s vector approach-based differential protection of three-phase power transformer”. Em: 6 (set. de 2012), pp. 463–472.
- [30] P. K. Kankar, S. C. Sharma e S. P. Harsha. “Vibration-based fault diagnosis of a rotor bearing system using artificial neural network and support vector machine”. Em: *International Journal of Modelling, Identification and Control* 15.3 (2012), pp. 185–198.
- [31] B. Li, M.-Y. Chow, Y. Tipsuwan e J. C. Hung. “Neural-network-based motor rolling bearing fault diagnosis”. Em: *IEEE transactions on industrial electronics* 47.5 (2000), pp. 1060–1069.
- [32] Y. Ming, J. Chen e G. Dong. “Weak fault feature extraction of rolling bearing based on cyclic Wiener filter and envelope spectrum”. Em: *Mechanical Systems and Signal Processing* 25.5 (2011), pp. 1773 –1785. ISSN: 0888-3270. DOI: <https://doi.org/10.1016/j.ymsp.2010.12.002>. URL: <http://www.sciencedirect.com/science/article/pii/S0888327010004267>.
- [33] L. Guo, J. Chen e X. Li. “Rolling Bearing Fault Classification Based on Envelope Spectrum and Support Vector Machine”. Em: *Journal of Vibration and Control* 15.9 (2009), pp. 1349–1363. DOI: [10.1177/1077546308095224](https://doi.org/10.1177/1077546308095224). eprint: <https://doi.org/10.1177/1077546308095224>. URL: <https://doi.org/10.1177/1077546308095224>.
- [34] A. Jawadekar, S. Paraskar, S. Jadhav e G. Dhole. “Artificial neural network-based induction motor fault classifier using continuous wavelet transform”. Em: 2 (dez. de 2014), pp. 684–690.
- [35] R Bandyopadhyay, P. Puhan, P. Konar e P. Chattopadhyay. *A Hybrid Park-ANN approach in fault detection of Induction Motor*. Ago. de 2010.
- [36] J. L. H. Silva e A. J. M. Cardoso. “Bearing failures diagnosis in three-phase induction motors by extended Park’s vector approach”. Em: *31st Annual Conference of IEEE Industrial Electronics Society, 2005. IECON 2005*. Nov. de 2005, 6 pp.–. DOI: [10.1109/IECON.2005.1569315](https://doi.org/10.1109/IECON.2005.1569315).
- [37] B. Corne, B. Vervisch, S. Derammelaere, J. Knockaert e J. Desmet. “The reflection of evolving bearing faults in the stator current’s extended Park vector approach for induction machines”. Em: *Mechanical Systems and Signal Processing* 107 (2018), pp. 168 –182. ISSN: 0888-3270. DOI: <https://doi.org/10.1016/j.ymsp>.

## BIBLIOGRAFIA

---

2017. 12. 010. URL: <http://www.sciencedirect.com/science/article/pii/S0888327017306453>.



## COMPARAÇÃO DE DESEMPENHOS DE DIFERENTES PARAMETRIZAÇÕES DOS ALGORITMOS UTILIZADOS

O *package* *caret* permite a personalização de parâmetros dos algoritmos que disponibiliza, sendo também possível deixar esta a cargo do próprio *package*. Neste sentido, é aqui descrita uma pequena comparação entre estes dois tipos de otimização utilizando um *feature set* de referência (*feature set 7* da análise das correntes dos dados Optisigma), sendo testados os diferentes algoritmos em todas as frequências de amostragem disponíveis e com períodos de análise de 20 ms, 40 ms e 60 ms. Para a personalização manual foram utilizados os seguintes parâmetros:

---

### **SVM - Support Vector Machine (Radial Basis Function Kernel)**

`C = (0.25, 0.5, 1, 2, 4, 8, 16, 32, 64, 128, 512, 1000)`

`sigma = (0.0025, 0.005, 0.01, 0.015, 0.02, 0.03, 0.04, 0.06, 0.08, 0.1)`

### **ANN - Artificial Neural Network**

`size = (1, 2, 3, 4, 5, 6, 7, 8, 9, 10)`

`decay = (0.1, 0.2, 0.3, 0.4, 0.5)`

### **RF - Random Forests**

`mtry = (1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25)`

### **XGB - eXtreme Gradient Boosting**

`eta = (0.05, 0.075, 0.1)`

`nrounds = (50, 75, 100)`

`max_depth = (6, 7, 8)`

`min_child_weight = (2.0, 2.25, 2.5)`

`colsample_bytree = (0.3, 0.4, 0.5)`

`gamma = 0`

`subsample = 1`

---

## APÊNDICE A. COMPARAÇÃO DE DESEMPENHOS DE DIFERENTES PARAMETRIZAÇÕES DOS ALGORITMOS UTILIZADOS

Como é possível observar na Figura A.1 e na Tabela A.1 (*tunned* indica a versão parametrizada manualmente), a média de resultados obtida mostra uma melhoria considerável com o algoritmo SVM quando utilizados os parâmetros de otimização mostrados acima, sendo o desempenho bastante semelhante quando comparados os algoritmos ANN, RF e XGBOOST. Apesar de semelhantes, os melhores resultados foram registados com os parâmetros descritos acima para os algoritmos ANN, SVM e XGBOOST, sendo que o RF registou melhores resultados com a parametrização automática do *package caret*.

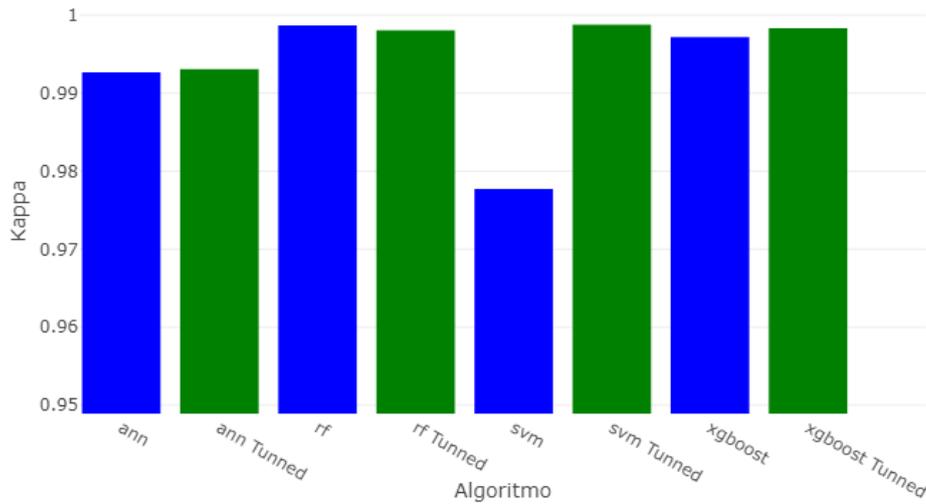


Figura A.1: Comparação da média do kappa obtido para cada parametrização de cada algoritmo utilizado

Tabela A.1: Média do kappa obtido para cada parametrização de cada algoritmo utilizado

Algoritmo	Média do Kappa Obtido
ann	0.9927
ann Tunned	0.9931
rf	0.9987
rf Tunned	0.9981
svm	0.9777
svm Tunned	0.9988
xgboost	0.9972
xgboost Tunned	0.9983

A tabela A.2 descreve os resultados completos (incluindo o kappa, a exatidão e a matriz de confusão para cada um dos casos testados).

Tabela A.2: Resultados completos da comparação de desempenhos de diferentes parametrizações dos algoritmos utilizados

ms	kHz	Algoritmo	Kappa	Exatidão	Precisão	VP	FP	VN	FN
20	0.8	ann	0.9601	0.9881	0.9627	490	19	2244	14
20	0.8	ann Tunned	0.9757	0.9928	0.9821	493	9	2254	11

---

20	0.8	rf	0.9891	0.9967	0.994	498	3	2260	6
20	0.8	rf Tunned	0.9927	0.9978	0.996	500	2	2261	4
20	0.8	svm	0.903	0.9718	0.9513	449	23	2240	55
20	0.8	svm Tunned	0.9928	0.9978	0.9882	504	6	2257	0
20	0.8	xgboost	0.9951	0.9986	0.996	502	2	2261	2
20	0.8	xgboost Tunned	0.9915	0.9975	0.996	499	2	2261	5
20	1	ann	0.9665	0.9904	0.9794	475	10	2306	17
20	1	ann Tunned	0.9765	0.9932	0.9856	480	7	2309	12
20	1	rf	0.9951	0.9986	0.998	489	1	2315	3
20	1	rf Tunned	0.9901	0.9972	0.9979	485	1	2315	7
20	1	svm	0.9488	0.9854	0.9747	463	12	2304	29
20	1	svm Tunned	0.9938	0.9982	0.998	488	1	2315	4
20	1	xgboost	0.9963	0.9989	0.998	490	1	2315	2
20	1	xgboost Tunned	0.9926	0.9979	0.998	487	1	2315	5
20	2	ann	0.9836	0.9951	0.9866	441	6	1997	6
20	2	ann Tunned	0.9876	0.9963	0.9955	440	2	2001	7
20	2	rf	0.9986	0.9996	0.9978	447	1	2002	0
20	2	rf Tunned	0.9932	0.998	0.9911	446	4	1999	1
20	2	svm	0.9462	0.9841	0.9658	423	15	1988	24
20	2	svm Tunned	0.9959	0.9988	0.9978	445	1	2002	2
20	2	xgboost	0.9959	0.9988	0.9933	447	3	2000	0
20	2	xgboost Tunned	0.9932	0.998	0.9911	446	4	1999	1
20	5	ann	0.9988	0.9997	1	506	0	2361	1
20	5	ann Tunned	0.9988	0.9997	1	506	0	2361	1
20	5	rf	1	1	1	507	0	2361	0
20	5	rf Tunned	0.9976	0.9993	1	505	0	2361	2
20	5	svm	0.9892	0.9969	0.9882	504	6	2355	3
20	5	svm Tunned	1	1	1	507	0	2361	0
20	5	xgboost	1	1	1	507	0	2361	0
20	5	xgboost Tunned	1	1	1	507	0	2361	0
20	10	ann	0.9972	0.9991	0.9989	894	1	3365	3
20	10	ann Tunned	0.9979	0.9993	0.9989	895	1	3365	2
20	10	rf	1	1	1	897	0	3366	0
20	10	rf Tunned	1	1	1	897	0	3366	0
20	10	svm	0.9972	0.9991	1	893	0	3366	4
20	10	svm Tunned	0.9993	0.9998	0.9989	897	1	3365	0
20	10	xgboost	1	1	1	897	0	3366	0
20	10	xgboost Tunned	1	1	1	897	0	3366	0
40	0.8	ann	0.9951	0.9986	1	250	0	1131	2
40	0.8	ann Tunned	0.9951	0.9986	1	250	0	1131	2

APÊNDICE A. COMPARAÇÃO DE DESEMPENHOS DE DIFERENTES  
PARAMETRIZAÇÕES DOS ALGORITMOS UTILIZADOS

40	0.8	rf	0.9976	0.9993	1	251	0	1131	1
40	0.8	rf Tunned	0.9976	0.9993	1	251	0	1131	1
40	0.8	svm	0.9803	0.9942	1	244	0	1131	8
40	0.8	svm Tunned	1	1	1	252	0	1131	0
40	0.8	xgboost	0.9927	0.9978	0.9921	251	2	1129	1
40	0.8	xgboost Tunned	0.9976	0.9993	0.996	252	1	1130	0
40	1	ann	0.9926	0.9979	0.9959	244	1	1156	2
40	1	ann Tunned	0.9951	0.9986	0.9959	245	1	1156	1
40	1	rf	1	1	1	246	0	1157	0
40	1	rf Tunned	1	1	1	246	0	1157	0
40	1	svm	0.9801	0.9943	0.9958	239	1	1156	7
40	1	svm Tunned	1	1	1	246	0	1157	0
40	1	xgboost	0.9975	0.9993	0.996	246	1	1156	0
40	1	xgboost Tunned	1	1	1	246	0	1157	0
40	2	ann	1	1	1	222	0	999	0
40	2	ann Tunned	0.9889	0.9967	1	218	0	999	4
40	2	rf	1	1	1	222	0	999	0
40	2	rf Tunned	1	1	1	222	0	999	0
40	2	svm	0.9917	0.9975	1	219	0	999	3
40	2	svm Tunned	1	1	1	222	0	999	0
40	2	xgboost	1	1	1	222	0	999	0
40	2	xgboost Tunned	1	1	1	222	0	999	0
40	5	ann	1	1	1	252	0	1176	0
40	5	ann Tunned	1	1	1	252	0	1176	0
40	5	rf	1	1	1	252	0	1176	0
40	5	rf Tunned	1	1	1	252	0	1176	0
40	5	svm	0.9976	0.9993	1	251	0	1176	1
40	5	svm Tunned	1	1	1	252	0	1176	0
40	5	xgboost	1	1	1	252	0	1176	0
40	5	xgboost Tunned	1	1	1	252	0	1176	0
40	10	ann	1	1	1	447	0	1680	0
40	10	ann Tunned	1	1	1	447	0	1680	0
40	10	rf	1	1	1	447	0	1680	0
40	10	rf Tunned	1	1	1	447	0	1680	0
40	10	svm	1	1	1	447	0	1680	0
40	10	svm Tunned	1	1	1	447	0	1680	0
40	10	xgboost	1	1	1	447	0	1680	0
40	10	xgboost Tunned	1	1	1	447	0	1680	0
60	0.8	ann	0.9964	0.9989	1	167	0	753	1
60	0.8	ann Tunned	0.9927	0.9978	1	166	0	753	2

---

60	0.8	rf	1	1	1	168	0	753	0
60	0.8	rf Tunned	1	1	1	168	0	753	0
60	0.8	svm	0.9779	0.9935	1	162	0	753	6
60	0.8	svm Tunned	1	1	1	168	0	753	0
60	0.8	xgboost	1	1	1	168	0	753	0
60	0.8	xgboost Tunned	1	1	1	168	0	753	0
60	1	ann	1	1	1	162	0	766	0
60	1	ann Tunned	1	1	1	162	0	766	0
60	1	rf	1	1	1	162	0	766	0
60	1	rf Tunned	1	1	1	162	0	766	0
60	1	svm	0.9773	0.9935	0.9937	157	1	765	5
60	1	svm Tunned	1	1	1	162	0	766	0
60	1	xgboost	0.9889	0.9968	0.9818	162	3	763	0
60	1	xgboost Tunned	1	1	1	162	0	766	0
60	2	ann	1	1	1	147	0	663	0
60	2	ann Tunned	0.9916	0.9975	1	145	0	663	2
60	2	rf	1	1	1	147	0	663	0
60	2	rf Tunned	1	1	1	147	0	663	0
60	2	svm	0.9832	0.9951	1	143	0	663	4
60	2	svm Tunned	1	1	1	147	0	663	0
60	2	xgboost	0.9958	0.9988	1	146	0	663	1
60	2	xgboost Tunned	1	1	1	147	0	663	0
60	5	ann	1	1	1	167	0	781	0
60	5	ann Tunned	0.9964	0.9989	1	166	0	781	1
60	5	rf	1	1	1	167	0	781	0
60	5	rf Tunned	1	1	1	167	0	781	0
60	5	svm	1	1	1	167	0	781	0
60	5	svm Tunned	1	1	1	167	0	781	0
60	5	xgboost	1	1	1	167	0	781	0
60	5	xgboost Tunned	1	1	1	167	0	781	0
60	10	ann	1	1	1	297	0	1116	0
60	10	ann Tunned	1	1	1	297	0	1116	0
60	10	rf	1	1	1	297	0	1116	0
60	10	rf Tunned	1	1	1	297	0	1116	0
60	10	svm	0.9936	0.9979	1	294	0	1116	3
60	10	svm Tunned	1	1	1	297	0	1116	0
60	10	xgboost	0.9957	0.9986	1	295	0	1116	2
60	10	xgboost Tunned	1	1	1	297	0	1116	0

---



## RESULTADOS DA CALIBRAÇÃO DA ANÁLISE ESPECTRAL DA TRANSFORMADA DE PARK ESTENDIDA

Tabela B.1: Resultados obtidos segundo a variação do número de picos de frequência analisados no espectro da TPE e da frequência de amostragem

Nº de picos	kHz	Kappa	Exatidão	Precisão	VP	FP	VN	FN
1	0.8	0.5913	0.8797	0.6748	330	159	2104	174
1	1	0.5598	0.8771	0.6637	298	151	2165	194
1	2	0.7103	0.9131	0.7577	344	110	1893	103
1	5	0.652	0.9003	0.7269	354	133	2228	153
1	10	0.8015	0.9343	0.8478	752	135	3231	145
2	0.8	0.948	0.9845	0.9546	484	23	2240	20
2	1	0.9187	0.9761	0.9159	468	43	2273	24
2	2	0.9591	0.9878	0.9623	434	17	1986	13
2	5	0.9904	0.9972	0.9941	502	3	2358	5
2	10	0.9986	0.9995	0.9989	896	1	3365	1
3	0.8	0.971	0.9913	0.9724	494	14	2249	10
3	1	0.9462	0.9843	0.9462	475	27	2289	17
3	2	0.9713	0.9914	0.9754	437	11	1992	10
3	5	1	1	1	507	0	2361	0
3	10	0.9993	0.9998	1	896	0	3366	1
4	0.8	0.977	0.9931	0.9783	496	11	2252	8
4	1	0.9626	0.9893	0.9853	469	7	2309	23
4	2	0.9781	0.9935	0.98	440	9	1994	7

APÊNDICE B. RESULTADOS DA CALIBRAÇÃO DA ANÁLISE ESPECTRAL DA TRANSFORMADA DE PARK ESTENDIDA

---

4	5	1	1	1	507	0	2361	0
4	10	1	1	1	897	0	3366	0
5	0.8	0.9817	0.9946	0.9939	492	3	2260	12
5	1	0.9718	0.9918	0.9718	483	14	2302	9
5	2	0.9822	0.9947	0.9865	440	6	1997	7
5	5	0.9988	0.9997	0.998	507	1	2360	0
5	10	1	1	1	897	0	3366	0
6	0.8	0.9707	0.9913	0.9858	487	7	2256	17
6	1	0.9754	0.9929	0.9777	483	11	2305	9
6	2	0.9781	0.9935	0.98	440	9	1994	7
6	5	1	1	1	507	0	2361	0
6	10	0.9993	0.9998	0.9989	897	1	3365	0
7	0.8	0.9707	0.9913	0.9858	487	7	2256	17
7	1	0.9826	0.995	0.9959	480	2	2314	12
7	2	0.9864	0.9959	0.9845	444	7	1996	3
7	5	0.9976	0.9993	1	505	0	2361	2
7	10	0.9986	0.9995	1	895	0	3366	2
8	0.8	0.9757	0.9928	0.984	492	8	2255	12
8	1	0.9754	0.9929	0.9797	482	10	2306	10
8	2	0.9824	0.9947	0.9759	445	11	1992	2
8	5	0.9988	0.9997	1	506	0	2361	1
8	10	1	1	1	897	0	3366	0
9	0.8	0.9659	0.9899	0.9779	487	11	2252	17
9	1	0.9864	0.9961	0.9938	484	3	2313	8
9	2	0.9863	0.9959	0.9888	442	5	1998	5
9	5	0.9952	0.9986	1	503	0	2361	4
9	10	1	1	1	897	0	3366	0

---

## RESULTADOS DA RECURSIVE FEATURE ELIMINATION DA ANÁLISE DA VIBRAÇÃO E DAS CORRENTES ELÉTRICAS

### C.1 Recursive Feature Elimination da Análise da Vibração

Tabela C.1: Resultados RFE da análise da vibração (2 Classes)

Variáveis	Exatidão	Kappa	Desvio Padrão Exatidão	Desvio Padrão Kappa
2	0.9991	0.9978	9e-04	0.0022
3	0.9999	0.9997	2e-04	5e-04
4	0.9998	0.9994	3e-04	7e-04
5	0.9998	0.9995	2e-04	5e-04
6	0.9998	0.9994	3e-04	8e-04
7	0.9998	0.9996	2e-04	5e-04
8	1	0.9999	1e-04	3e-04
9	1	0.9999	1e-04	3e-04
10	1	0.9999	1e-04	3e-04
11	1	0.9999	1e-04	3e-04
12	1	0.9999	1e-04	3e-04
13	1	1	0	0
14	1	1	0	0
15	1	1	0	0
16	1	0.9999	1e-04	3e-04
17	1	0.9999	1e-04	3e-04
18	1	1	0	0

APÊNDICE C. RESULTADOS DA RECURSIVE FEATURE ELIMINATION DA ANÁLISE DA VIBRAÇÃO E DAS CORRENTES ELÉTRICAS

19	1	0.9999	1e-04	3e-04
20	1	0.9999	1e-04	3e-04
21	1	0.9999	1e-04	3e-04
22	1	0.9999	1e-04	3e-04
23	1	0.9999	1e-04	3e-04
24	1	0.9999	1e-04	3e-04
25	1	0.9999	1e-04	3e-04
26	1	0.9999	1e-04	3e-04
27	1	0.9999	1e-04	3e-04
28	1	0.9999	1e-04	3e-04
29	1	0.9999	1e-04	3e-04
30	1	0.9999	1e-04	3e-04
31	1	0.9999	1e-04	3e-04
32	1	0.9999	1e-04	3e-04
33	1	0.9999	1e-04	3e-04
34	1	0.9999	1e-04	3e-04
35	1	0.9999	1e-04	3e-04
36	1	0.9999	1e-04	3e-04
37	1	0.9999	1e-04	3e-04
38	1	0.9999	1e-04	3e-04
39	1	0.9999	1e-04	3e-04
40	1	0.9999	1e-04	3e-04
41	1	0.9999	1e-04	3e-04
42	1	0.9999	1e-04	3e-04
43	1	0.9999	1e-04	3e-04
44	1	0.9999	1e-04	3e-04
45	1	0.9999	1e-04	3e-04
46	1	0.9999	1e-04	3e-04

Tabela C.2: Resultados RFE da análise da vibração (4 Classes)

Variáveis	Exatidão	Kappa	Desvio Padrão Exatidão	Desvio Padrão Kappa
2	0.841	0.7877	0.0154	0.0205
3	0.8848	0.8462	0.0069	0.0093
4	0.9015	0.8685	0.0053	0.0071
5	0.9186	0.8913	0.0061	0.0082
6	0.9304	0.9071	0.0038	0.0051
7	0.9405	0.9205	0.0039	0.0053
8	0.9432	0.9241	0.0035	0.0047
9	0.9437	0.9248	0.0042	0.0056
10	0.9452	0.9268	0.0039	0.0052

---

C.1. RECURSIVE FEATURE ELIMINATION DA ANÁLISE DA VIBRAÇÃO

---

11	0.9469	0.9291	0.0041	0.0055
12	0.9456	0.9273	0.0031	0.0041
13	0.9452	0.9268	0.004	0.0053
14	0.9547	0.9395	0.0075	0.0101
15	0.9585	0.9446	0.0083	0.011
16	0.9647	0.9529	0.0078	0.0104
17	0.9756	0.9675	0.0037	0.005
18	0.9787	0.9715	0.0029	0.0039
19	0.9784	0.9712	0.003	0.004
20	0.9787	0.9716	0.0032	0.0043
21	0.9782	0.9709	0.0037	0.0049
22	0.978	0.9706	0.0037	0.0049
23	0.9779	0.9705	0.0036	0.0048
24	0.9777	0.9702	0.0027	0.0036
25	0.9775	0.9699	0.0036	0.0048
26	0.9776	0.9701	0.0033	0.0044
27	0.9776	0.97	0.0032	0.0043
28	0.9774	0.9698	0.0029	0.0039
29	0.9767	0.9689	0.0035	0.0046
30	0.9766	0.9688	0.0032	0.0042
31	0.976	0.9679	0.0035	0.0046
32	0.9762	0.9682	0.0033	0.0044
33	0.9754	0.9671	0.0037	0.005
34	0.9754	0.9671	0.0039	0.0051
35	0.9752	0.9668	0.004	0.0053
36	0.9754	0.9671	0.0039	0.0052
37	0.9752	0.9669	0.0039	0.0052
38	0.9748	0.9664	0.0036	0.0048
39	0.9747	0.9662	0.0036	0.0048
40	0.974	0.9653	0.004	0.0053
41	0.9741	0.9654	0.0041	0.0055
42	0.9746	0.966	0.0035	0.0047
43	0.9745	0.9659	0.0038	0.0051
44	0.974	0.9653	0.0037	0.0049
45	0.974	0.9653	0.004	0.0054
46	0.9738	0.965	0.0037	0.0049
47	0.9741	0.9654	0.0036	0.0048
48	0.9738	0.9651	0.0039	0.0052
49	0.9742	0.9656	0.0038	0.0051

---

## C.2 Recursive Feature Elimination da Análise das Correntes

Tabela C.3: Resultados RFE da análise das correntes elétricas

Variáveis	Exatidão	Kappa	Desvio Padrão Exatidão	Desvio Padrão Kappa
2	0.9738	0.9223	0.0058	0.017
3	0.9869	0.9604	0.0096	0.029
4	0.9993	0.9979	8e-04	0.0024
5	0.9994	0.9983	6e-04	0.0019
6	0.9996	0.9989	5e-04	0.0015
7	0.9997	0.9992	5e-04	0.0015
8	0.9997	0.9992	5e-04	0.0015
9	0.9998	0.9994	5e-04	0.0014
10	0.9998	0.9994	5e-04	0.0014
11	0.9998	0.9994	5e-04	0.0014
12	0.9998	0.9994	5e-04	0.0014
13	0.9998	0.9994	5e-04	0.0014
14	0.9999	0.9996	4e-04	0.0013
15	0.9998	0.9994	5e-04	0.0014
16	0.9998	0.9994	5e-04	0.0014
17	0.9999	0.9996	3e-04	9e-04
18	0.9998	0.9994	5e-04	0.0014
19	0.9999	0.9998	2e-04	7e-04
20	0.9999	0.9996	3e-04	9e-04
21	0.9999	0.9996	3e-04	9e-04
22	0.9999	0.9998	2e-04	7e-04



## MATRIZES DE CONFUSÃO RESULTANTES DA IDENTIFICAÇÃO DA LOCALIZAÇÃO DA AVARIA NO ROLAMENTO

		Classe Verdadeira			
		S	PI	PE	E
Classe Prevista	S	2120	0	0	0
	PI	0	1767	28	9
	PE	0	29	1796	3
	E	0	27	2	1810

Tabela D.1: Melhor resultado obtido com um período de análise de 20 ms (*feature set 8* com algoritmo **XGBOOST**)

		Classe Verdadeira			
		S	PI	PE	E
Classe Prevista	S	1414	0	0	0
	PI	0	1187	13	1
	PE	0	6	1199	2
	E	0	19	3	1210

Tabela D.2: Melhor resultado obtido com um período de análise de 30 ms (*feature set 8* com algoritmo **XGBOOST**)

APÊNDICE D. MATRIZES DE CONFUSÃO RESULTANTES DA IDENTIFICAÇÃO DA LOCALIZAÇÃO DA AVARIA NO ROLAMENTO

		Classe Verdadeira			
		S	PI	PE	E
Classe Prevista	S	1060	0	0	0
	PI	0	895	6	0
	PE	0	0	903	0
	E	0	10	0	907

Tabela D.3: Melhor resultado obtido com um período de análise de 40 ms (*feature set 8* com algoritmo **XGBOOST**)

		Classe Verdadeira			
		S	PI	PE	E
Classe Prevista	S	846	0	0	1
	PI	0	715	6	0
	PE	0	1	717	0
	E	0	5	0	720

Tabela D.4: Melhor resultado obtido com um período de análise de 50 ms (*feature set 8* com algoritmo **XGBOOST**)

		Classe Verdadeira			
		S	PI	PE	E
Classe Prevista	S	705	0	0	0
	PI	0	598	3	3
	PE	0	1	600	0
	E	0	2	0	598

Tabela D.5: Melhor resultado obtido com um período de análise de 60 ms (*feature set 8* com algoritmo **XGBOOST**)

		Classe Verdadeira			
		S	PI	PE	E
Classe Prevista	S	529	0	0	0
	PI	0	448	0	0
	PE	0	1	452	0
	E	0	0	1	451

Tabela D.6: Melhor resultado obtido com um período de análise de 80 ms (*feature set 7* com algoritmo **SVM** e *feature set 8* com algoritmo **RF**)

		Classe Verdadeira			
		S	PI	PE	E
Classe Prevista	S	469	0	0	0
	PI	0	396	0	0
	PE	0	0	395	1
	E	0	0	1	395

Tabela D.7: Melhor resultado obtido com um período de análise de 90 ms (*feature set 8* com algoritmo **RF**)

---

		<b>Classe Verdadeira</b>			
		S	PI	PE	E
<b>Classe Prevista</b>	S	422	0	0	0
	PI	0	358	0	3
	PE	0	2	360	0
	E	0	0	0	357

Tabela D.8: Melhor resultado obtido com um período de análise de 100 ms (*feature set 8* com algoritmo RF)