



UNIVERSIDADE D
COIMBRA

João Luís Ferreira Filipe

**REDES NEURONAIS CONVOLUCIONAIS NO
DIAGNÓSTICO DE FALHAS EM ROLAMENTOS DE
MOTORES DE INDUÇÃO**

Dissertação no âmbito do Mestrado em Engenharia Eletrotécnica e de Computadores, Ramo de Especialização em Energia orientada pelo Professor Doutor Sérgio Manuel Ângelo da Cruz e apresentada ao Departamento de Engenharia Eletrotécnica e de Computadores da Faculdade de Ciências e Tecnologia

Fevereiro de 2023



FACULDADE DE
CIÊNCIAS E TECNOLOGIA
UNIVERSIDADE DE
COIMBRA

Faculdade de Ciências e Tecnologia da Universidade de Coimbra
Departamento de Engenharia Eletrotécnica e de Computadores

REDES NEURONAIS CONVOLUCIONAIS NO DIAGNÓSTICO DE FALHAS EM ROLAMENTOS DE MOTORES DE INDUÇÃO

João Luís Ferreira Filipe

Membros do Júri:

Presidente: Rui Pedro Duarte Cortesão

Orientador: Professor Doutor Sérgio Manuel Ângelo da Cruz

Vogal: Cristiano Premebida

Coimbra, fevereiro de 2023

Agradecimentos

Primeiramente, gostaria de expressar minha mais profunda gratidão, ao professor Sérgio Cruz, pela sua dedicação e apoio incansáveis ao longo da realização da dissertação, a sua persistência, orientação e sentido crítico foram fundamentais para a conclusão desta.

À minha família que me deu o incentivo, o apoio e as condições necessárias a que pudesse concretizar esta etapa da minha vida académica.

Aos amigos que fiz ao longo do curso, e que em particular aos que me acompanharam durante a realização desta dissertação, com as pausas para almoço ou um simples café. Agradeço a amizade, palavras sinceras e a alegria dos momentos passados em conjunto que tornaram mais fáceis as fases mais complicadas.

A ti Inês pelo companheirismo, momentos de alegria e de partilha. O teu incentivo, ouvido amigo e conforto foram um dos fatores cruciais à concretização deste projeto.

Por último e sem menosprezar, agradeço à Faculdade de Ciências e Tecnologia da Universidade de Coimbra, em especial ao Departamento de Engenharia Eletrotécnica e de Computadores e ao Instituto de Telecomunicações, pela disponibilização dos meios laboratoriais necessários à concretização das atividades experimentais que sem os quais o trabalho desenvolvido nesta dissertação não seria possível.

Resumo

Os métodos de diagnóstico de falhas para sistemas eletromecânicos são de grande relevância para a indústria no século XXI. Com o diagnóstico precoce de falhas obtemos um impacto econômico importante, é possível reduzir o tempo em que um dado sistema está inativo, bem como melhorar a segurança do meio envolvente, pois podem ser evitadas falhas perigosas para os utilizadores.

Tendo como base as tensões induzidas diferenciais, o trabalho nesta dissertação consistiu na proposição de um novo método de classificação de falhas em rolamentos de motores de indução trifásicos, com a aplicação de uma Rede Neuronal de Convolução na identificação destas. As tensões induzidas diferenciais têm a capacidade de detetar anomalias no campo magnético presentes no entreferro aquando da ocorrência de falhas nos rolamentos, falhas no estator e rotor, e excentricidades no motor, devido à alta sensibilidade deste às pequenas oscilações provocadas pelas falhas. A obtenção destas tensões é realizada através da colocação de seis boninas de teste nas ranhuras do estator. Uma das mais valias deste novo método é a eliminação de conhecimento especializado na identificação das diferentes características das falhas permitindo assim facilmente estender este método a díspares tipos motores.

O objetivo principal desta dissertação é a identificação por parte de uma rede neuronal convolucional dos vários padrões característicos, de cada uma das falhas em enrolamentos, presentes nas tensões induzidas diferenciais, demonstrando assim a grande utilidade da introdução de algoritmos de inteligência artificial no diagnóstico de falhas em motores.

Palavras-chave: Motores de Indução Trifásicos, Inteligência Artificial, Diagnóstico de Falhas, Falhas em Rolamentos, Aprendizagem Computacional, Aprendizagem Profunda, Redes Neurais Convolucionais.

Abstract

Diagnostic methods for electromechanical systems are highly relevant for the 21st century industry. With early fault detection, we achieve an important economic impact, reducing the time a given system is inactive and improving the safety of the surrounding environment by avoiding dangerous failures for the users.

Based on differential induced tensions, the work in this thesis consisted in proposing a new method of classifying faults in bearings of three-phase induction motors, using a convolutional neural network for their identification. Differential induced tensions have the ability to detect anomalies in the magnetic field present in the air gap when bearing faults, stator and rotor faults, and eccentricities in the motor occur, due to their high sensitivity to small oscillations caused by those faults. These tensions are obtained by placing six test probes in the stator slots. One of the advantages of this new method is the elimination of specialized knowledge in the identification of different failure characteristics, thus allowing this method to be easily extended to different types of motors.

The main objective of this thesis is the identification by a convolutional neural network of the various characteristic patterns in each of the failures on bearings, present in the differential induced tensions, demonstrating the great utility of introducing artificial intelligence algorithms in the diagnosis of faults in motors.

Keywords: Three-phase Induction Motors, Artificial Intelligence, Fault Diagnosis, Bearing Faults, Machine Learning, Deep Learning, Convolutional Neural Network

Índice

Agradecimentos	i
Resumo	ii
Abstract.....	iii
Índice	iv
Índice de Figuras	vi
Índice de Tabelas	ix
1. Introdução	1
1.1. Enquadramento e Motivação	1
1.2. Objetivos	2
2. Estado da Arte Sobre Falhas em Motores de Indução	3
2.1. Tipos de Falhas em Motores de Indução	3
2.2. Métodos de Diagnóstico de Falhas em Rolamentos	6
2.2.1. Detecção de Falhas	7
2.2.2. Técnicas Baseadas na Análise de Sinais	8
2.2.2.1. Análise no Domínio da Frequência	8
2.2.2.2. Análise no Domínio do Tempo-Frequência	9
2.2.3. Técnicas Baseadas em Modelos.....	10
2.2.4. Técnicas Baseadas em Inteligência Artificial	11
2.2.4.1. Primeiras Abordagens	12
2.2.4.2. Aprendizagem Profunda.....	13
2.2.4.3. Transferência de Conhecimento.....	15
3. Nova Estratégia de Diagnóstico Proposta.....	16
3.1. Tensões Induzidas Diferenciais	16
3.2. Rede Neuronal Convolutacional.....	19
3.3. Transformação Direta do Sinal em Imagens.....	23

3.4.	Métodos de Processamento de Sinal.....	25
3.4.1.	Transformada de Onduleta Discreta	26
3.4.2.	Transformada de <i>Stockwell</i>	29
4.	Análise e Discussão dos Resultados	32
4.1.	Descrição da Montagem Experimental	32
4.2.	Treino da Rede Neuronal	37
4.3.	Transformação Direta do Sinal em Imagens.....	39
4.4.	Métodos de Processamento de Sinal.....	42
4.4.1.	Transformada de Onduleta Discreta	43
4.4.2.	Transformada de <i>Stockwell</i>	46
5.	Conclusão e Trabalho Futuro.....	54
5.1.	Conclusão.....	54
5.2.	Trabalho Futuro	56
	Bibliografia.....	57
	Anexo I – Comparação entre Redes de Aprendizagem Profunda	61
	Anexo 2 – Componentes Harmónicas	63
	Anexo 3 – Características das Máquinas Eléctricas Utilizadas na Montagem Laboratorial	
	64	
	Bibliografia Anexos.....	65

Índice de Figuras

Figura 1 – Principais fontes de falhas em motores de indução [14].	3
Figura 2 – a) Resultado do estudo do IEEE sobre falhas em motores de indução [15] e b) Resultado do estudo do EPRI sobre falhas em motores de indução [15].	4
Figura 3 – i) Estrutura de um rolamento ii) Cenários mais comuns que podem causar falhas nos rolamentos: a) desalinhamento, b) deflexão do eixo, c) pista externa inclinada e d) pista interna inclinada [16].	4
Figura 4 – Tipos de excentricidade de um motor: a) excentricidade estática, b) excentricidade dinâmica e c) excentricidade mista [10, 21].	5
Figura 5 – Tipos diferentes de avarias nos enrolamentos estatóricos [14].	6
Figura 6 – Diferentes métodos de diagnóstico de falhas em motores.	7
Figura 7 – Esquemático do diagnóstico de falhas baseado num modelo [48].	10
Figura 8 – a) Esquema representativo dos subconjuntos de IA [50] e b) Esquema do diagnóstico de falhas com motores de indução usando algoritmos de IA [51].	11
Figura 9 – a) Arquitetura de uma ANN [51], b) Ilustração do algoritmo KNN e c) Separação em duas classes por uma SVM [55].	12
Figura 10 – a) Arquitetura de um AE [56], b) RBM integrante de uma DBN [60] e c) Esquema de um GAN [57].	14
Figura 11 – Estrutura de adaptação de domínio proposta para o modelo WDCNN [60].	15
Figura 12 – Localização das bobinas de teste no estator de um motor de indução trifásico tetrapolar [12].	17
Figura 13 – FFTs da tensão diferencial induzida nas bobinas de prova da fase R (figura superior) e da soma de todas as tensões diferenciais (figura inferior).	18
Figura 14 – Convolução de um filtro a um excerto da tabela de entrada e o seu resultado, quadrado central [50].	19
Figura 15 – Exemplo com Padding à direita e sem o mesmo à esquerda [50].	20
Figura 16 - Exemplo de Stride com n igual a 2 [50].	20
Figura 17 – Exemplo de Max-Pooling e Average-Pooling [50].	21
Figura 18 – CNN LeNet-5 utilizada em [72].	22

Figura 19 – CNN utilizada na classificação de imagens.....	22
Figura 20 – Processo de conversão do sinal numa imagem em escala de cinzentos [72].	23
Figura 21 – Comparação entre o espectro da soma das tensões diferenciais do motor saudável e com uma falha de 4mm no anel externo do rolamento do lado do ventilador.	25
Figura 22 – Decomposição do sinal, segundo a MRA em 3 níveis e respectivas gamas de frequência [74]......	28
Figura 23 – Diagrama da decomposição do sinal em 3 níveis e suas gamas de frequência, utilizando o WPT [40].	28
Figura 24 – Representação de um sinal no domínio do tempo-frequência utilizando a S-Transform standard e a S-Transform otimizada [75].....	30
Figura 25 –Histogramas das tensões diferenciais resultantes do pré-processamento: a) utilizando o sinal original; b) usando um filtro passa-alto de 4ª ordem, do tipo Butterworth.....	30
Figura 26 – Diagrama da montagem laboratorial [10]......	32
Figura 27 – Rolamentos com falhas, do lado esquerdo: furo de 4mm no anel externo do lado do ventilador e do lado direito: furo de 4mm no anel interno do lado do ventilador.	33
Figura 28 – Montagem experimental.	35
Figura 29 – Terminais para a aquisição das tensões induzidas.....	36
Figura 30 – a) Montagem laboratorial para a aquisição e acondicionamento das diferentes variáveis do motor e a alimentação do motor. b) Controlador cRIO-9066. ...	36
Figura 31 – Divisão do conjunto de dados global para efeitos de treino, validação e teste da rede neuronal.	38
Figura 32 – Gráficos de treino, validação e função de perdas durante o treino da rede neuronal e matriz de confusão das imagens de teste com o conjunto de dados de transformação direta 32x32 px.	41
Figura 33 – Gráficos de treino, validação e função de perdas durante o treino da rede neuronal e matriz de confusão das imagens de teste com o conjunto de dados de transformação direta 64x64 px.	42

Figura 34 – Gráficos de treino, validação e função de perdas durante o treino da rede neuronal e matriz de confusão das imagens de teste com conjunto de dados onde é aplicada uma DWT 16x16 px.	45
Figura 35 – Gráficos de treino, validação e função de perdas durante o treino da rede neuronal e matriz de confusão das imagens de teste com o conjunto de dados onde é aplicada uma DWT 32x32 px.	45
Figura 36 – Gráficos de treino, validação e função de perdas durante o treino da rede neuronal e matriz de confusão das imagens de teste com o conjunto de dados onde é aplicada uma S-Transform 32x32 px.	49
Figura 37 – Gráficos de treino, validação e função de perdas durante o treino da rede neuronal e matriz de confusão das imagens de teste com o conjunto de dados onde é aplicada uma S-Transform 64x64 px.	49
Figura 38 – Gráficos de treino, validação e função de perdas durante o treino da rede neuronal e matriz de confusão das imagens de teste com o conjunto de dados onde é aplicada uma S-Transform 64x64 px com a adição de dois ensaios.	50
Figura 39 – Gráficos de treino, validação e função de perdas durante o treino da rede neuronal e matriz de confusão das imagens de teste com o conjunto de dados onde é aplicada uma S-Transform 64x64 px com aumento de dados por sobreposição de imagens.	51
Figura 40 – Gráficos de treino, validação e função de perdas durante o treino da rede neuronal com o conjunto de dados com o motor em funcionamento em vazio, a 50% e 100% da carga nominal a e matriz de confusão das imagens de teste com o conjunto de dados com o motor em funcionamento a 25% e 75% da carga nominal.	52
Figura 41 – Gráficos de treino, validação e função de perdas durante o treino da rede neuronal com o conjunto de dados com o motor em funcionamento em vazio, a 25%, 75% e 100% da carga nominal a e matriz de confusão das imagens de teste com o conjunto de dados com o motor em funcionamento a 50% da carga nominal.	53

Índice de Tabelas

Tabela 1 – Composição da CNN utilizada na classificação de imagens.....	22
Tabela 2 – Posição dos rolamentos com as várias falhas para cada um dos ensaios.	34
Tabela 3 – Dimensão dos Rolamentos.....	34
Tabela 4 – Velocidade para diferentes níveis de carga.....	34
Tabela 5 – Bases de dados utilizadas para cada caso de treino em cada iteração do método de diagnóstico.....	38
Tabela 6 – Exemplo de imagens do conjunto de dados obtidas através da transformação direta do sinal em escala de cinzento com tamanho 32x32 px.....	39
Tabela 7 - Exemplo de imagens do conjunto de dados obtidas através da transformação direta em escala de cinzento com tamanho 64x64 px.....	40
Tabela 8 – Conjuntos de dados para o caso de treino realizado nesta iteração do método de diagnóstico.....	40
Tabela 9 – Imagens obtidas depois de aplicada uma DWT de nível 3 com tamanho 16x16 px.....	43
Tabela 10 – Imagens obtidas depois de aplicada uma DWT de nível 3 com tamanho 32x32 px.....	44
Tabela 11 – Conjuntos de dados para o caso de treino realizado nesta iteração do método de diagnóstico.....	44
Tabela 12 – Imagens obtidas depois de aplicada uma S-Transform.....	47
Tabela 13 – Conjuntos de dados para os diferentes casos de treino realizados nesta iteração do método de diagnóstico.....	48
Tabela 14 – Sumário de diferentes arquiteturas de aprendizagem profunda [1]...	61
Tabela 15 – Comparação da precisão da classificação com a base de dados da CWRU em diferentes algoritmos [1].....	62
Tabela 16 – Frequências características com maior amplitude.....	63
Tabela 17 – Características do Motor de Indução Trifásico.....	64
Tabela 18 – Características da Máquina de Corrente Contínua.....	64

1. Introdução

1.1. Enquadramento e Motivação

A ampla utilização de motores de indução trifásicos, por exemplo em sistemas de bombagem, de tração e acionamentos industriais, deve-se sobretudo às suas vantagens em termos de simplicidade dos componentes usados no seu fabrico mas também à flexibilidade de adaptação a um qualquer tipo de aplicação, aos seus índices de fiabilidade e ao seu custo reduzido em comparação com outros tipos de motor [1].

Apesar dos elevados índices de fiabilidade que apresentam, podem, no entanto, ocorrer determinadas falhas nos motores de indução conducentes a períodos de tempo em que os mesmos estão inoperacionais ou, pelo menos, a funcionar aquém do seu potencial máximo. Por esse motivo, a existência de sistemas de diagnóstico que possam prever antecipadamente essas falhas revestem-se de grande importância para a monitorização constante do estado do motor permitindo, para além do mais, o aperfeiçoamento desses mesmos índices [2].

As falhas mais comuns em motores de indução têm como origem a degradação dos rolamentos, contabilizando até 50% do total das falhas [3-6], não obstante existem ainda falhas relacionadas com a excentricidade, barras do rotor e nos enrolamentos do rotor e estator [7].

Nos sistemas de diagnóstico de falhas são normalmente analisados sinais provenientes, por exemplo, das vibrações da carcaça do motor medidos através de sensores adequados ou sinais elétricos medidos no sistema de alimentação. Preferencialmente utilizam-se os sinais elétricos pois estes não implicam a adição de sensores ao motor, fazendo deste um método não invasivo. Nestes métodos mais tradicionais de diagnóstico de falhas são utilizadas técnicas de processamento de sinal, onde os sinais adquiridos são tratados e analisados visando um posterior diagnóstico da falha [8].

Métodos convencionais têm como base a observação e interpretação posterior das variáveis recolhidas por parte do conhecimento humano. Por outro lado, uma das vantagens dos métodos baseados em algoritmos de inteligência artificial é eliminar a necessidade de conhecimento especializado, uma vez que este tem a capacidade de aprender as características de cada falha, podendo ainda estar a classificar dados ao mesmo tempo que o motor está em funcionamento e assim identificar falhas quando estas estão em fases iniciais.

Nos últimos anos, os algoritmos de inteligência artificial têm sido adotados em diversas áreas, nomeadamente no diagnóstico de falhas em máquinas elétricas, onde os resultados têm-se revelado muito positivos. De facto, esses algoritmos apresentam grande capacidade de adaptação a diferentes cenários e maior imunidade a ruídos exteriores [8, 9]. Alguns dos algoritmos de inteligência artificial conseguem atingir taxas de sucesso muito próximas do pleno no que concerne à classificação das falhas que podem ocorrer no motor [8, 9].

1.2. Objetivos

Esta dissertação tem por objetivo o desenvolvimento e implementação de um método de diagnóstico com base em inteligência artificial. O diagnóstico é realizado através da utilização de tensões induzidas diferenciais, calculadas a partir de tensões induzidas recolhidas através de bobinas de prova instaladas no estator do motor, sendo que as bobinas se encontram alinhadas com cada um dos grupos de bobinas estatóricas deste, com um desfasamento de 360 graus elétricos. Como foi demonstrado em [10], as tensões induzidas diferenciais permitem a identificação de falhas em rolamentos de motores, apresentado ainda elevado potencial no diagnóstico de falhas no estator e no rotor destes [11, 12].

Esta dissertação pressupõe os seguintes objetivos:

- A análise das tensões induzidas diferenciais nas bobinas de prova instaladas no estator do motor de indução trifásico, em várias situações de funcionamento e condições de carga.
- Comparação da amplitude das componentes harmónicas das tensões induzidas diferenciais simples e a soma das mesmas.
- Treino de uma rede neuronal convolucional com imagens geradas a partir dos dados recolhidos nos ensaios realizados em ambiente laboratorial.
- Perceber a viabilidade do método de diagnóstico para a classificação de falhas com o motor em funcionamento a uma condição de carga desconhecida.

2. Estado da Arte Sobre Falhas em Motores de Indução

2.1. Tipos de Falhas em Motores de Indução

O estado de manutenção interna ou externa de um motor de indução trifásico pode influenciar o aparecimento de falhas. Externamente estas podem ser classificadas de acordo com a sua origem e desse modo podemos considerar a existência de falhas mecânicas, elétricas ou no ambiente circundante. Internamente, as falhas podem surgir associadas a problemas em partes mecânicas ou nos circuitos elétricos [13]. Na Figura 1 está representado um diagrama com a representação das principais fontes de falhas em motores de indução.

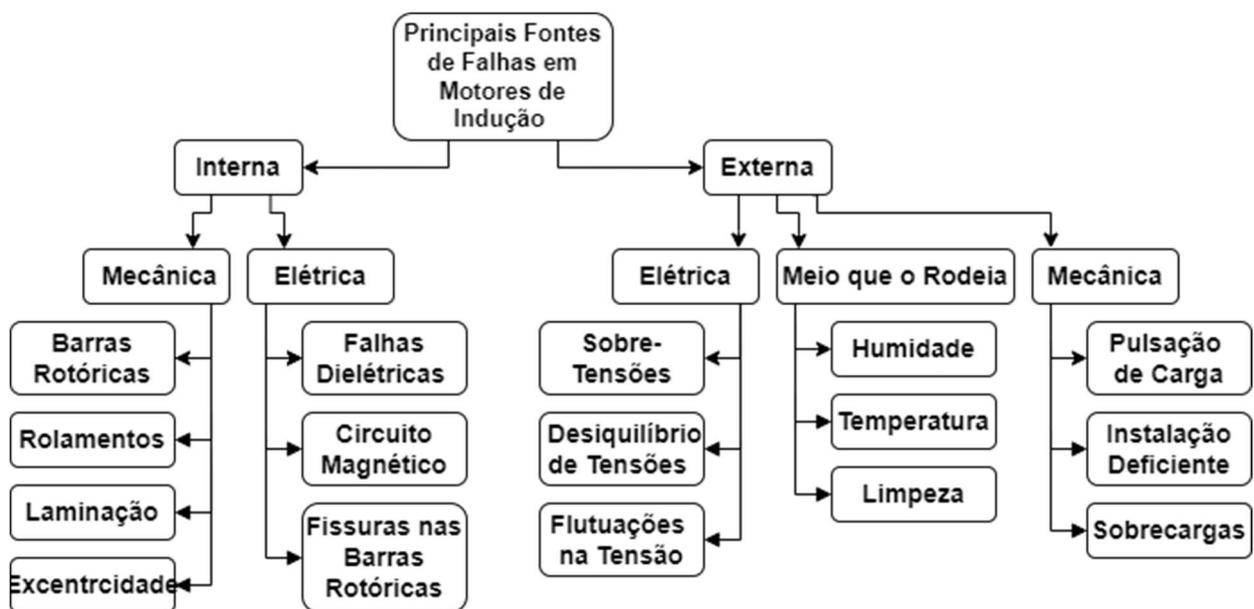


Figura 1 – Principais fontes de falhas em motores de indução [14].

Para uma melhor compreensão dos componentes mais suscetíveis a falhas num motor de indução são analisados estudos de duas agências diferentes: IEEE e EPRI, representados nos gráficos da Figura 2. Ambos os estudos englobam dados reportados por diferentes fabricantes de motores [15]. Com os resultados destes dois estudos, podemos concluir que as falhas mais reportadas estão relacionadas com rolamentos (mais de 40%), seguindo-se as falhas que ocorrem no estator (aproximadamente 30%). Por fim, as falhas ocorridas no rotor (cerca de 9%) [14].

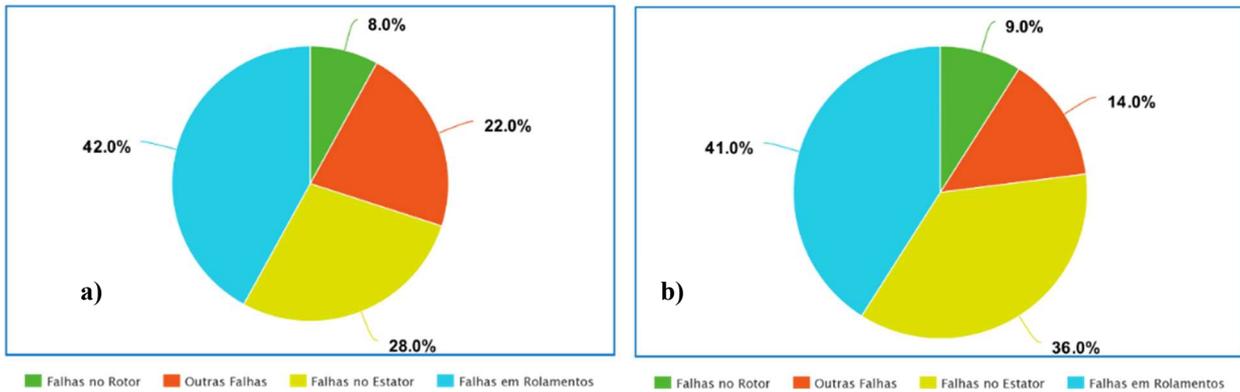


Figura 2 – a) Resultado do estudo do IEEE sobre falhas em motores de indução [15] e b) Resultado do estudo do EPRI sobre falhas em motores de indução [15].

Os rolamentos são compostos por um anel externo e um interno, um em contacto com a carcaça do motor e outro fixo ao veio do motor, e por um conjunto de elementos rolantes (esferas ou rolos), presentes entre os dois anéis que possibilitam a rotação independente destes, e uma gaiola para a manutenção da distância entre os elementos rolantes, Figura 3-i) [14].

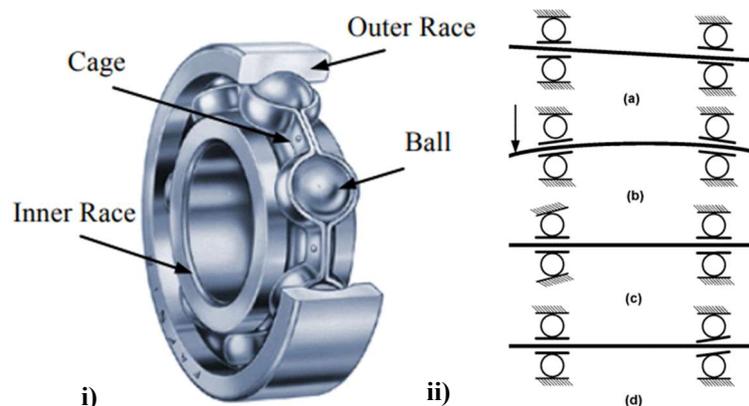


Figura 3 – i) Estrutura de um rolamento ii) Cenários mais comuns que podem causar falhas nos rolamentos: a) desalinhamento, b) deflexão do eixo, c) pista externa inclinada e d) pista interna inclinada [16].

Os motores de indução operam frequentemente em condições extremas onde estão expostos a ambientes severos durante longas horas sem interrupção, muitas vezes em contacto com corpos estranhos como água, ácidos e humidades. Acontecimentos como estes podem levar ao desgaste prematuro dos rolamentos e consequentemente à ocorrência precoce de falhas [16, 17]. A lubrificação inadequada dos rolamentos, tanto em excesso como em escassez, pode provocar o aquecimento excessivo dos mesmos resultando na aceleração do seu desgaste.

Muitas destas falhas são também resultado de forças aplicadas inapropriadamente ao veio ou na ranhura de fixação à carcaça do motor, onde o anel do rolamento é danificado na forma de pequenas indentações que diminuem a sua vida útil. O desalinhamento do rolamento é o resultado mais habitual da instalação defeituosa de rolamentos, cenários de desalinhamentos mais comuns estão descritos na Figura 3- ii) [16].

Algumas falhas em rolamentos têm causas elétricas, embora numa escala mais reduzida. Estas ocorrem aquando da circulação de correntes pelos rolamentos, principalmente em motores alimentados por conversores de frequência [16].

Fenómenos de excentricidade do motor, quando a uniformidade e simetria no comprimento radial do entreferro não se verifica, decorrem, frequentemente, das falhas em rolamentos. Cerca de 80% das avarias mecânicas em motores de indução levam à ocorrência de excentricidade, podendo também ter origem em erros no processo de fabrico ou montagem [18]. A excentricidade pode ser dividida em três tipos, como podemos observar na Figura 4. Assim, a excentricidade estática, verifica-se quando o centro geométrico do rotor não está coincidente com o centro geométrico do estator. Por sua vez, a excentricidade dinâmica, ocorre quando o centro geométrico do rotor não é o centro de rotação. E por fim, a excentricidade mista decorre quando o centro do rotor não coincide com o centro de rotação e está ao mesmo tempo deslocado do centro do estator [1, 19, 20].

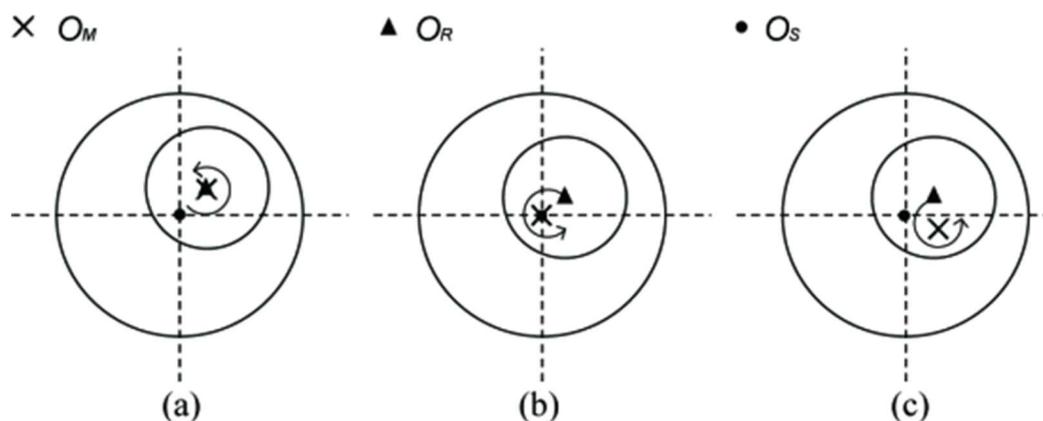


Figura 4 – Tipos de excentricidade de um motor: a) excentricidade estática, b) excentricidade dinâmica e c) excentricidade mista [10, 21].

As falhas que se desenvolvem no estator representam mais de 30% da totalidade das falhas em motores de indução. Nestas destacam-se as falhas nos enrolamentos, sendo as mais frequentes os circuitos abertos e os curtos-circuitos entre bobinas da mesma fase, entre espiras de fases

diferentes e entre enrolamentos, podendo também estar relacionadas com o circuito magnético ou com a carcaça do motor [1, 22], como pode ser observado na Figura 5.

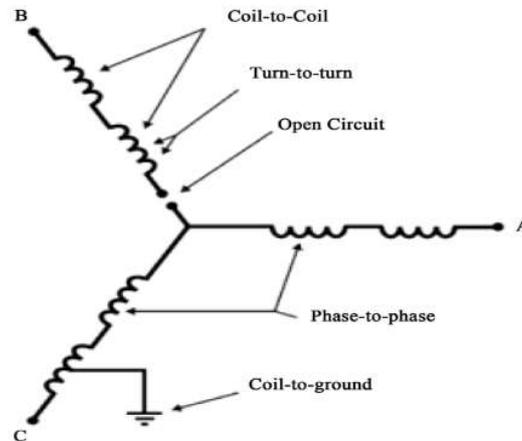


Figura 5 – Tipos diferentes de avarias nos enrolamentos estatóricos [14].

As falhas no rotor representam cerca de 10% das falhas em motores de indução, e são compostas por defeitos ou fraturas nas barras do rotor ou no veio. Estas falhas podem ser provocadas por defeitos de fabrico, como bolhas de ar, ligas metálicas com impurezas e pontos fracos nas barras. Podem também ser causadas por razões externas, como sobrecargas e arranques frequentes [1, 6, 22].

2.2. Métodos de Diagnóstico de Falhas em Rolamentos

Atualmente diferentes técnicas são utilizadas no diagnóstico de falhas em rolamentos, uma vez que a deteção de falhas continua a ser um grande desafio para a comunidade científica. Algumas destas técnicas podem ser baseadas em técnicas avançadas de processamento de sinal, assente em modelos computacionais de máquinas elétricas, verificando-se nos últimos anos um aumento de técnicas baseadas em inteligência artificial [8, 9]. Na Figura 6 encontram-se representados alguns dos métodos mais utilizados no diagnóstico de falhas, métodos estes agrupados em três grandes áreas: baseados em processamento de sinal, em modelos e em inteligência artificial.

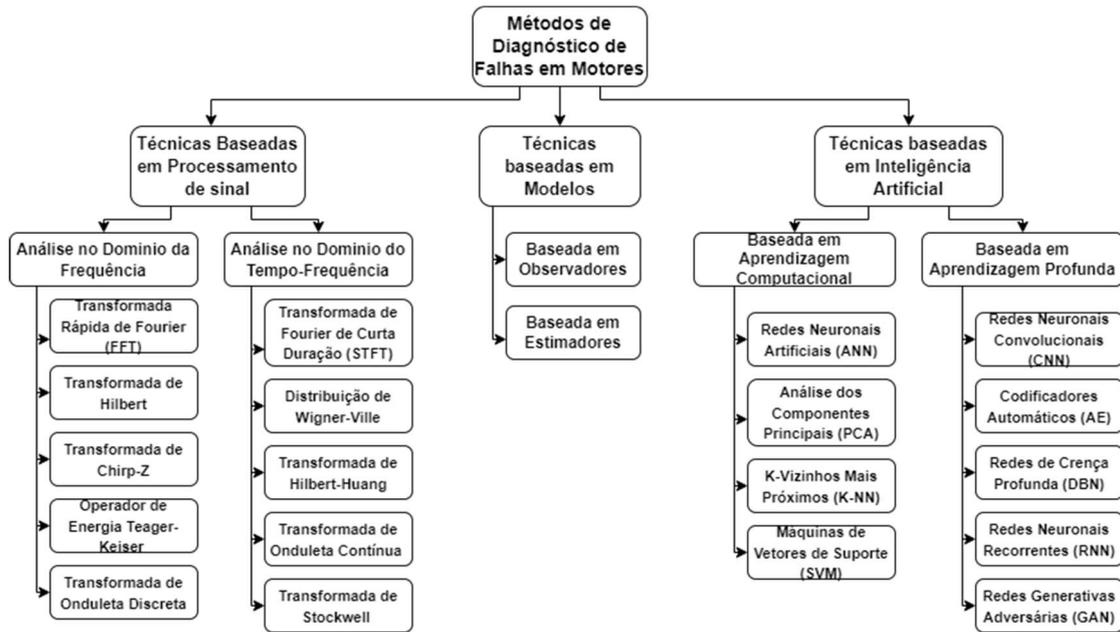


Figura 6 – Diferentes métodos de diagnóstico de falhas em motores.

2.2.1. Detecção de Falhas

Uma das formas mais comuns de detecção de falhas em rolamentos consiste no estudo dos sinais de vibração da carcaça do motor, pois uma das consequências desse tipo de falha é o aumento do nível de vibração no sistema. Para a aquisição desta variável utiliza-se habitualmente um acelerómetro ou sensor de vibração montado na carcaça do motor, o qual mede as vibrações presentes nesta ao longo dos três eixos. Os diferentes tipos de falhas em rolamentos reproduzem diferentes frequências características nos sinais de vibração adquiridos, o que possibilita a sua detecção a partir da sua análise. Os sinais de vibração são um indicador robusto para avarias e defeitos nos rolamentos desde que seja efetuado um processamento adequado dos sinais [23]. Contudo, o custo elevado dos sensores, a sua falta de durabilidade e a dificuldade de diferenciação de avarias em ambientes muito ruidosos são um revés na sua utilização [24].

Tendo em vista a realização do diagnóstico de falhas e considerando que por vezes o acesso ao local onde os motores estão instalados é difícil, a implementação de sistemas de monitorização de sinais elétricos é atrativa. Esta alternativa também acarreta vantagens económicas pois muitos destes sinais já são medidos pelos sistemas de proteção e nos conversores de eletrónica de potência que integram o acionamento onde o motor de indução está inserido. Estas variáveis elétricas dão também a possibilidade de identificar outros tipos de falhas em motores de indução [24]. O processo de análise dos sinais elétricos é idêntico ao dos sinais de vibração, sendo necessária a

determinação das frequências características para os diferentes tipos de falhas [2, 10]. A principal desvantagem deste método está relacionada com as ténues variações nos sinais introduzidas pelas falhas dos rolamentos, sendo mais difícil a identificação dessas variações para avarias generalizadas [24]. As frequências características das componentes espectrais criadas pelas falhas derivam da constituição física de cada máquina e vão aumentando ao longo do tempo [25].

O fluxo magnético é também uma das grandezas utilizadas em diagnóstico de falhas em motores de indução. Existem dois tipos de análise: a do fluxo de fugas, com bobinas de prova instaladas no exterior do motor, onde se analisa o fluxo presente no exterior do motor [26-28], e a do fluxo principal do motor, este com bobinas de prova instaladas no interior do estator, monitorizando o campo magnético no interior do motor [11, 29, 30]. Uma melhor exposição sobre este tipo de monitorização será efetuada no Capítulo 3.

Outras formas de deteção de falhas englobam a análise química do lubrificante do rolamento [24], a análise térmica do rolamento [31, 32], a análise acústica do funcionamento do motor [33], a análise da pressão sonora do ruído emitido pelo rolamento [34] e a análise do movimento do rolamento por laser [35].

2.2.2. Técnicas Baseadas na Análise de Sinais

2.2.2.1. Análise no Domínio da Frequência

Embora a utilização da transformada rápida de Fourier (FFT) possa ser localizada em trabalhos não publicados de Gauss, foi exposta uma versão mais generalizada por Cooley e Tukey na década de 1960. Esta versão consiste num algoritmo para eficientemente realizar a computação da transformada discreta de Fourier. A expressão para o cálculo de uma FFT de um sinal discreto, para N amostras, é dada por:

$$X[n] = \sum_{k=0}^{N-1} x[k] e^{-j\frac{2\pi nk}{N}}, n = 1, \dots, N-1 \quad (1)$$

A utilização de uma FFT, permite que se reduza as operações aritméticas de N^2 para $N \log N$ operações, possibilitando a redução acentuada no tempo de cálculo para valores de N elevados.

Técnicas de diagnóstico baseadas em FFTs, são muito comuns para a deteção de quase todas as falhas em máquinas elétricas (à exceção das relacionadas com o estator), desde que a máquina esteja a operar em regime permanente e em que as condições de operação sejam estáveis.

Normalmente são analisadas por esta técnica os sinais de corrente, fluxo, vibração, binário e velocidade [36].

Outros métodos de processamento de sinal utilizados no diagnóstico de avarias, englobam a transformada de Hilbert [37, 38], a transformada de Chirp-Z [39], o operador de energia Teager-Keiser [40-42] e a transformada de onduleta discreta, esta última exposta no capítulo 3 como iteração do método de diagnóstico proposto, aplicadas aos vários sinais enumerados no parágrafo anterior.

2.2.2.2. Análise no Domínio do Tempo-Frequência

A transformada de Fourier de curta duração (STFT) é baseada na transformada de Fourier, tendo como princípio de funcionamento a subdivisão do sinal em blocos com a mesma janela temporal, aplicando a cada um desses blocos uma FFT [43]. Deste modo, pode-se observar, em simultâneo, a evolução do sinal no domínio do tempo e da frequência. A STFT é definida matematicamente através de:

$$STFT_x(t, \omega) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{+\infty} x(\tau)h(\tau - t)e^{-j\omega t} d\tau \quad (2)$$

onde ω corresponde à frequência angular (rad/s) e $h(\tau)$ à função da janela espectral [44].

A utilização de uma STFT exige a definição de uma janela espectral para o espectrograma resultante, na qual se escolhe a resolução nos eixos da frequência e do tempo. A janela espectral mais utilizada é a de *Hanning*, $w(k)$, que privilegia uma maior resolução da frequência em detrimento da precisão da amplitude do sinal, e é caracterizada pela seguinte expressão [40]:

$$w(k) = 0.5 \left(1 - \cos\left(\frac{2\pi k}{W_1}\right) \right), 0 \leq k \leq W_1 \quad (3)$$

onde W_1 corresponde ao comprimento da janela espectral.

Para além do diagnóstico de avarias [45], esta técnica tem outras aplicações, entre elas a análise de sinais acústicos, sísmicos, e biométricos entre outros [40].

Outras técnicas de processamento de sinal no domínio do tempo-frequência, são a distribuição de Wigner-Ville [46], a transformada de Hilbert-Huang [47], a transformada de onduleta contínua e a transformada de Stockwell, estas últimas expostas no capítulo 3, aplicadas aos diversos sinais expressos no ponto anterior.

2.2.3. Técnicas Baseadas em Modelos

As técnicas de diagnóstico baseadas em modelos foram criadas por Richard Beard no início da década de 1970, com a intenção de substituir a redundância de hardware por redundância analítica. Nestas técnicas, os modelos de processos industriais ou os de sistemas físicos têm de estar presentes, pois os algoritmos de diagnóstico baseados nesses mesmos modelos são desenvolvidos para supervisionar a diferença entre os valores do sistema real e os estimados pelo modelo. Apresenta-se na Figura 7 um exemplo de esquema de uma técnica de diagnóstico baseada em observadores, incluindo a detecção, isolamento e identificação de falhas [48].

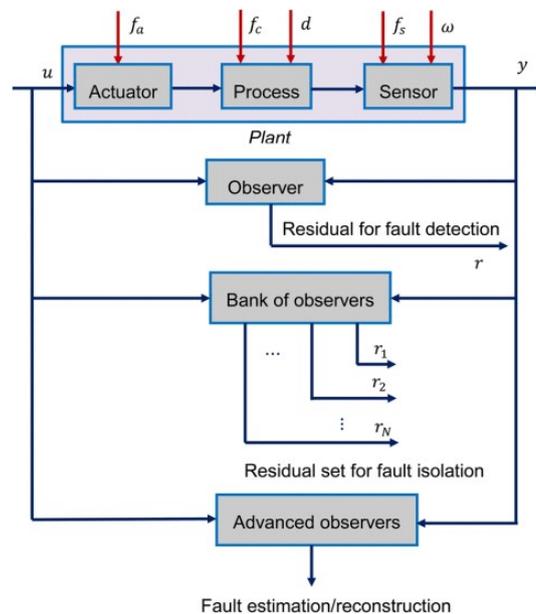


Figura 7 – Esquemático do diagnóstico de falhas baseado num modelo [48].

Nos modelos determinísticos, os observadores têm o papel principal de monitorizar o sistema caracterizado. Para o isolamento de falhas é utilizado um banco de observadores residuais, e para a identificação de falhas são utilizados vários métodos como observadores PI, PMI, adaptativos, entre outros.

Nos modelos estocásticos, um dos métodos mais importantes é a estimação de parâmetros [49], onde se assume que as falhas vão ser refletidas nos parâmetros do sistema. A ideia básica deste método de detecção é a identificação dos parâmetros do sistema em funcionamento e a comparação com os parâmetros de referência, obtidos com o sistema a funcionar em condições saudáveis [48].

2.2.4. Técnicas Baseadas em Inteligência Artificial

A inteligência artificial (IA) é um ramo da ciência computacional no qual o comportamento inteligente é simulado por computadores cujo programa “consegue” sentir, pensar, agir e adaptar. O termo IA é aplicado quando uma máquina consegue reproduzir as funções cognitivas de um ser humano, como aprender e resolver problemas. Dentro dos programas de IA existem algoritmos de aprendizagem computacional, onde estes aprendem padrões à medida que são expostos a mais informação. Ainda dentro dos últimos, existem algoritmos de aprendizagem profunda onde se utilizam modelos de redes neurais profundas, com a capacidade de determinar as melhores representações da informação fornecida sem a interferência humana. Na Figura 8 - a), estão representados os diferentes subconjuntos que compõem a IA [50].

Para o diagnóstico de avarias em motores de indução, em que são utilizados algoritmos de IA, são usados esquemas idênticos aos da Figura 8 - b). Nesses algoritmos é feita uma aquisição de dados, esses dados passam por um extrator e um selecionador de características e em seguida a rede é treinada e testada, culminando na obtenção de um prognóstico [51].

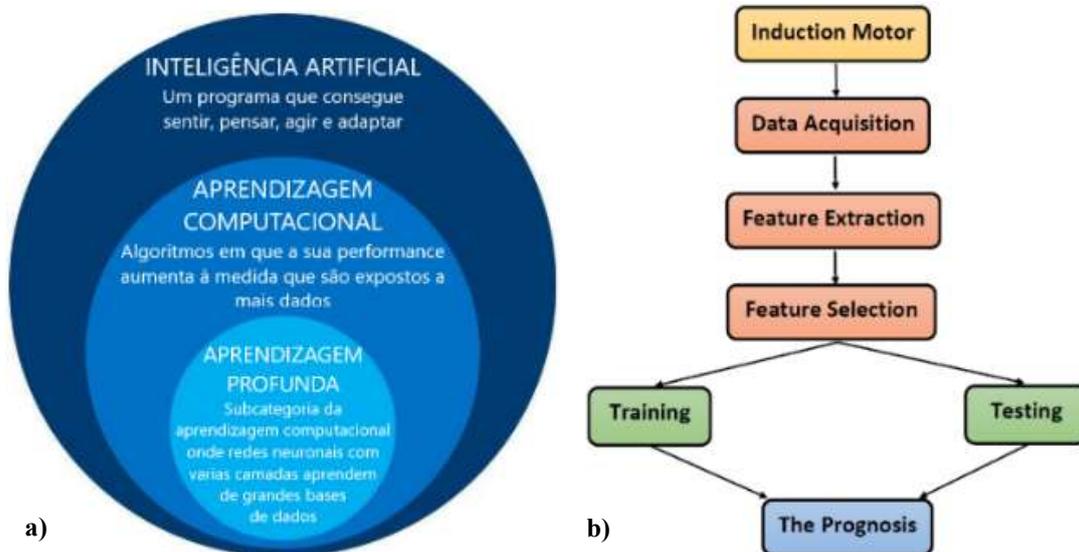


Figura 8 – a) Esquema representativo dos subconjuntos de IA [50] e b) Esquema do diagnóstico de falhas com motores de indução usando algoritmos de IA [51].

2.2.4.1. Primeiras Abordagens

As primeiras abordagens com a aplicação de algoritmos de IA na deteção de falhas em motores de indução trifásicos, surgiram nos anos 80 e recaíam sobretudo na aplicação de algoritmos de aprendizagem computacional [52, 53], contudo sem grandes taxas de sucesso.

No entanto, nos últimos anos os algoritmos de IA têm conseguido dar provas de grande sucesso no diagnóstico de avarias, devido principalmente ao grande avanço no poder computacional e na acessibilidade a bases de dados [8, 54]. A aplicação de algoritmos de aprendizagem computacional requer conhecimentos especializados e recursos complexos para a extração das características, onde primeiramente é efetuada uma análise profunda na base de dados. Posteriormente são utilizadas técnicas para redução da dimensão dos dados de onde são extraídas as características e por fim as características mais representativas são introduzidas no algoritmo de aprendizagem computacional [9].

A base de conhecimento para diferentes motores e aplicações é díspar e requer conhecimento especializado acerca do seu funcionamento em cada aplicação. Este facto leva a que estes modelos não possam ser treinados em determinada máquina e generalizados ou transferidos para outras em contextos e configurações diferentes [8].

Alguns dos algoritmos e ferramentas de aprendizagem computacional empregues, com resultados satisfatórios no diagnóstico de avarias em rolamentos são as redes neuronais artificiais (ANN), a análise de componentes principais (PCA), os K-vizinhos mais próximo (K-NN), a máquina de vetores de suporte (SVM), entre outras, [8, 9]. Na Figura 9 estão ilustrados alguns destes algoritmos.

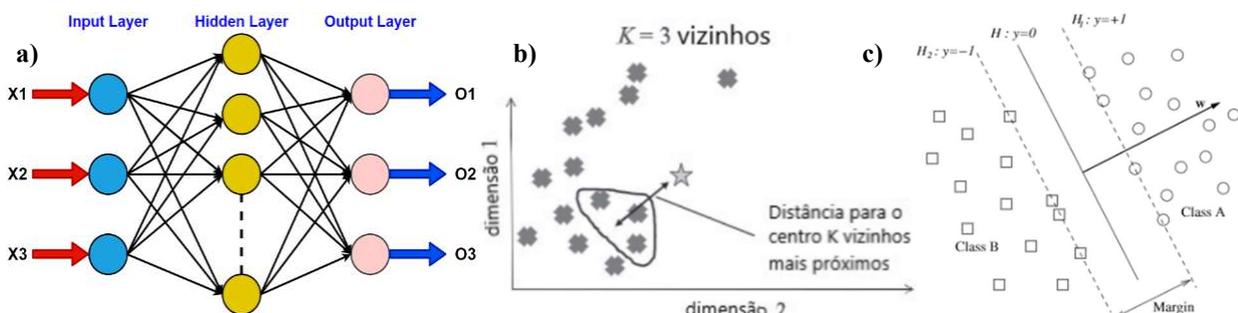


Figura 9 – a) Arquitetura de uma ANN [51], b) Ilustração do algoritmo KNN e c) Separação em duas classes por uma SVM [55].

Para determinar, por exemplo, avarias em rolamentos os algoritmos de aprendizagem computacional utilizam características da frequência de avarias que são calculadas com base na velocidade do rotor e na geometria dos rolamentos, sendo essas frequências usadas como as características das avarias.

Estas técnicas de diagnóstico encontram muitos desafios que comprometem a taxa de sucesso da classificação, tais como o deslize do rolamento na carcaça do motor, interações entre frequências características, ruído externo e dificuldades na observação dos efeitos de algumas falhas. Os resultados derivados desta abordagem podem ser de difícil interpretação e alguns podem ser incorretamente classificados [8, 9].

2.2.4.2. Aprendizagem Profunda

A aprendizagem profunda é um ramo da aprendizagem computacional que consegue alcançar grandes taxas de sucesso ao aprender autonomamente a representar o mundo como uma rede hierárquica de conceitos. Cada conceito é definido por conceitos mais simples e representações mais abstratas, calculadas a partir de representações menos abstratas.

A escolha de algoritmos de aprendizagem profunda em detrimento de algoritmos de aprendizagem computacional, está relacionada sobretudo com o aumento exponencial dos dados disponíveis, evolução dos algoritmos, evolução do *hardware*, extração automática das características e a sua capacidade de transferência de conhecimento. Assim sendo temos assistido a uma transição para os algoritmos de aprendizagem profunda e um aumento exponencial na sua utilização, tanto para a monitorização regular do funcionamento dos motores como para o diagnóstico de avarias [8, 9].

Alguns dos estudos onde são aplicados algoritmos de aprendizagem profunda utilizam redes neuronais convulsionais (CNN), codificadores automáticos (AE), redes de crença profunda (DBN), redes neuronais recorrentes (RNN), redes generativas adversárias (GAN), entre outros [8, 9]. Na Figura 10 estão representados alguns destes algoritmos.

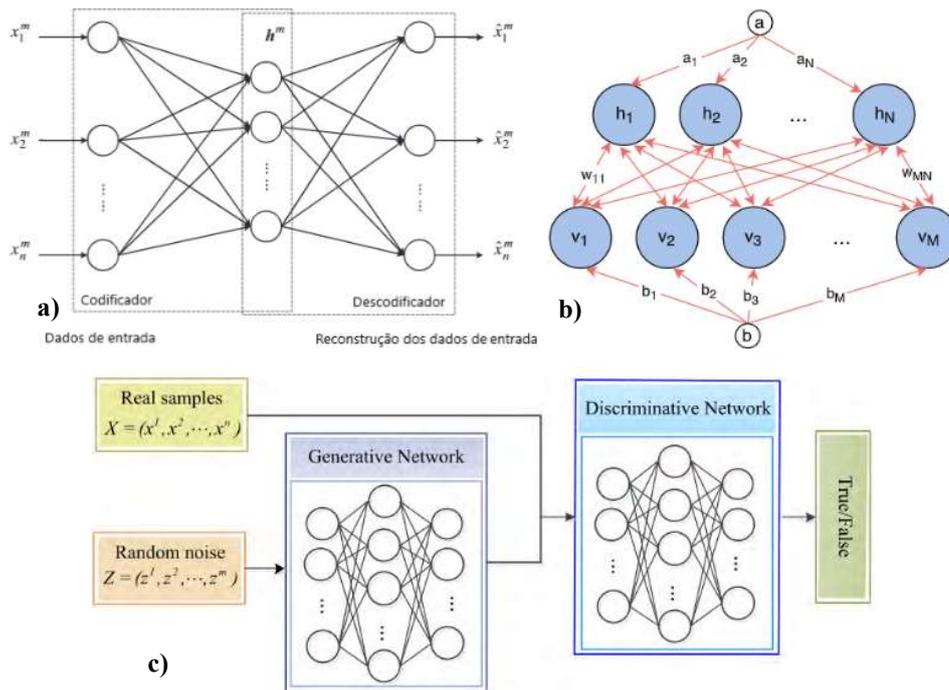


Figura 10 – a) Arquitetura de um AE [56], b) RBM integrante de uma DBN [60] e c) Esquema de um GAN [57].

Contrariamente aos algoritmos de aprendizagem computacional, os algoritmos de aprendizagem profunda têm a capacidade de extrair automaticamente as características de cada falha, pois não requerem experiência humana ou conhecimento prévio do problema. Sendo nesse sentido uma vantagem para o diagnóstico de avarias em rolamentos onde, por vezes, é difícil de determinar os aspetos das características acertadamente. Estes algoritmos aprendem as características com dados não tratados e classificam-nos simultânea e entrelaçadamente [8, 9].

Embora estes algoritmos alcancem resultados muito satisfatórios, ainda existem alguns desafios a ultrapassar, tais como a transferência de conhecimento dos laboratórios para o mundo real, uma vez que a grande parte dos estudos são feitos em laboratório, a atribuição do momento de começo da falha, os desequilíbrios e ruídos nos dados, entre outros [8, 9].

O repositório de falhas em rolamentos da universidade de *Case Western Reserve (CWRU)* [58], tem sido amplamente utilizado como base de dados a fornecer a diferentes algoritmos de aprendizagem profunda, servindo como uma boa base de comparação entre estes. No Anexo I está representada a tabela comparativa entre os diferentes algoritmos. Tendo em conta a referida comparação, foi escolhida uma Rede Neuronal Convolutiva para a consecução do objetivo pretendido nesta dissertação, devido principalmente às boas taxas de classificação e a um tempo de treino reduzido.

2.2.4.3. Transferência de Conhecimento

O sucesso no diagnóstico de falhas ao adotar algoritmos de aprendizagem computacional e profunda está alicerçado nas grandes quantidades de dados disponíveis relacionados com essas falhas, recolhidos em ambiente laboratorial. No que diz respeito a aplicações no mundo real, não é viável a recolha de dados devido às possíveis consequências que resultam de ter máquinas a funcionar em condições anormais, ao elevado tempo de funcionamento até que ocorra uma avaria ou o princípio de uma, e à quantidade de diferentes condições de velocidade e carga a que pode estar a operar [8]. Como resultado, temos uma divergência natural na precisão de classificação quando os algoritmos são aplicados a dados oriundos do mundo real [8, 9].

Os algoritmos de transferência de conhecimento são concebidos com o objetivo de eliminar as discrepâncias das taxas de classificação obtidas com dados laboratoriais e do mundo real (industrial). Muitos dos algoritmos identificados são adaptações e conjugações de CNNs com outros métodos [59, 60]. Na Figura 11 é apresentado um exemplo de uma CNN adaptada com vista à transferência de conhecimento.

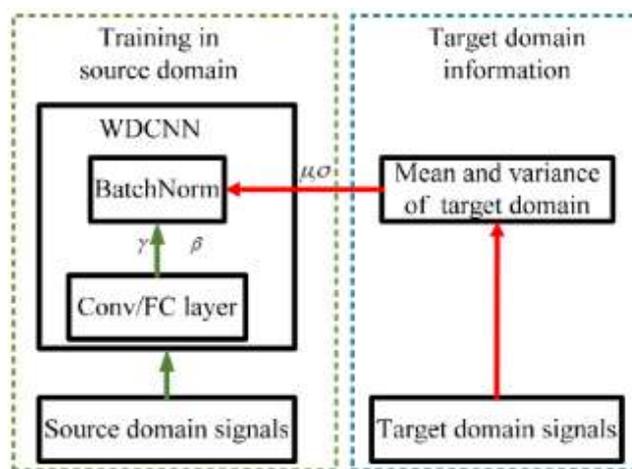


Figura 11 – Estrutura de adaptação de domínio proposta para o modelo WDCNN [60].

3. Nova Estratégia de Diagnóstico Proposta

A nova estratégia de diagnóstico de falhas em motores implementada, propõe a utilização do fluxo magnético do motor aliado à capacidade de reconhecimento de padrões dos algoritmos de inteligência artificial. O fluxo magnético é obtido através de bobinas de prova instaladas no estator do motor, os dados recolhidos com o motor em funcionamento com diferentes falhas são posteriormente transformados em imagens. Posteriormente, a rede neuronal convolucional é treinada com as imagens anteriores sendo o objetivo identificar as alterações nos padrões de funcionamento do motor com diferentes falhas.

3.1. Tensões Induzidas Diferenciais

O método para a detecção de falhas em rolamentos proposto nesta dissertação analisa o fluxo magnético do motor, através da medição das tensões induzidas diferenciais obtidas por bobinas de prova, que se encontram colocadas no estator do motor. As tensões induzidas diferenciais são calculadas através da diferença entre os dois valores medidos pelas bobinas de prova posicionadas com um desfasamento de 360° elétricos entre si e alinhadas com os polos magnéticos correspondentes. Com a ocorrência de uma avaria num dos componentes do motor, temos uma perturbação na região onde ocorre essa avaria, o que resulta em diferentes medições de tensão diferenciais em relação ao funcionamento do motor sem falhas.

Na Figura 12 está representada a distribuição das bobinas de prova ao longo do estator para um motor tetrapolar. Não obstante, existe generalizações desta técnica para outros tipos de configuração, de modo a estarem alinhadas com o respetivo par de polos, ou seja, alinhadas geometricamente com o centro do campo magnético do estator, e assim, é possível a observação do campo magnético relativo a cada fase de alimentação. Deste modo, a variação da amplitude do campo magnético acima referido tem influência direta nas tensões medidas nas bobinas de prova, conseguindo-se assim obter-se informação sobre as condições de funcionamento do motor [10-12].

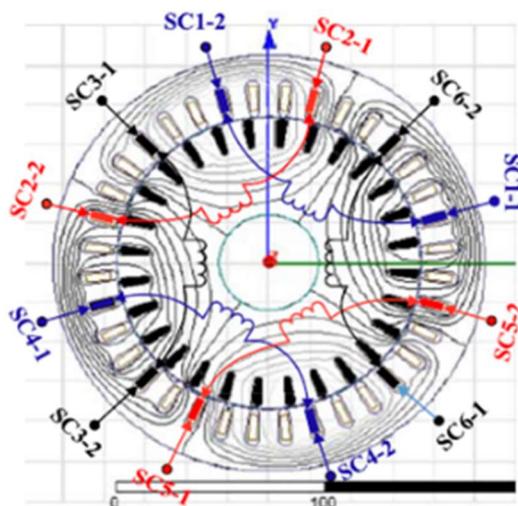


Figura 12 – Localização das bobinas de teste no estator de um motor de indução trifásico tetrapolar [12].

Para a obtenção das tensões induzidas diferenciais, foi subtraída à tensão presente na bobina de prova de uma das fases, a tensão da bobina de prova com um desfasamento de 180° mecânicos referente à mesma fase, sendo estas dadas por:

$$\Delta E_R = E_{SC11-12} - E_{SC41-42} \quad (4)$$

$$\Delta E_S = E_{SC21-} - E_{SC51-} \quad (5)$$

$$\Delta E_T = E_{SC31-12} - E_{SC41-42} \quad (6)$$

Num motor ideal, as equações acima descritas resultariam em tensões induzidas diferenciais nulas. Tal facto ocorreria devido à ausência de qualquer perturbação no campo magnético nas regiões onde as bobinas de prova estão instaladas e à simetria do motor. A não verificação destas condições num motor real deve-se a fatores como excentricidades intrínsecas e a imperfeições no circuito magnético que levam a desequilíbrios nas tensões induzidas nos diferentes pares de bobinas de prova.

Com este facto em mente, é necessária a implementação de um método que nos permita remover estas pequenas diferenças entre as tensões diferenciais recolhidas [11]. Posteriormente à recolha dos sinais é efetuada uma comparação das tensões induzidas diferenciais individuais e normalizadas através da seguinte formula:

$$E'_j(t) = \frac{\max(E_{k,FC,HC})}{E_{j,FC,HC}(t)} * E_j(t) = K_j * E_j(t), j = 1, 2, \dots, 6 \quad (7)$$

onde $E'_j(t)$ corresponde à tensão induzida j após a normalização, $E_j(t)$ é a tensão induzida real na bobina, e K_j é uma constante de normalização para a tensão induzida j . É importante notar que

as constantes K_j devem ser relativas ao funcionamento motor sem falhas, para que deste modo sejam apenas eliminados os efeitos das assimetrias intrínsecas do próprio motor e não aquelas provocadas pelas diferentes falhas no rolamento.

Com o objetivo de obter uma imagem com as características mais perceptíveis, são obtidos os espectros relativos a cada uma das fases das tensões induzidas diferenciais e à soma das mesmas, aplicando uma FFT. Após a análise comparativa das componentes dos espectros obtidos, concluiu-se que, com a soma das tensões as componentes espectrais das frequências características de cada falha têm uma maior amplitude, e tornam-se conseqüentemente mais evidentes, o que permite uma aprendizagem mais fácil dessas por uma rede neuronal. Na Figura 13 está apresentado um exemplo desta comparação.

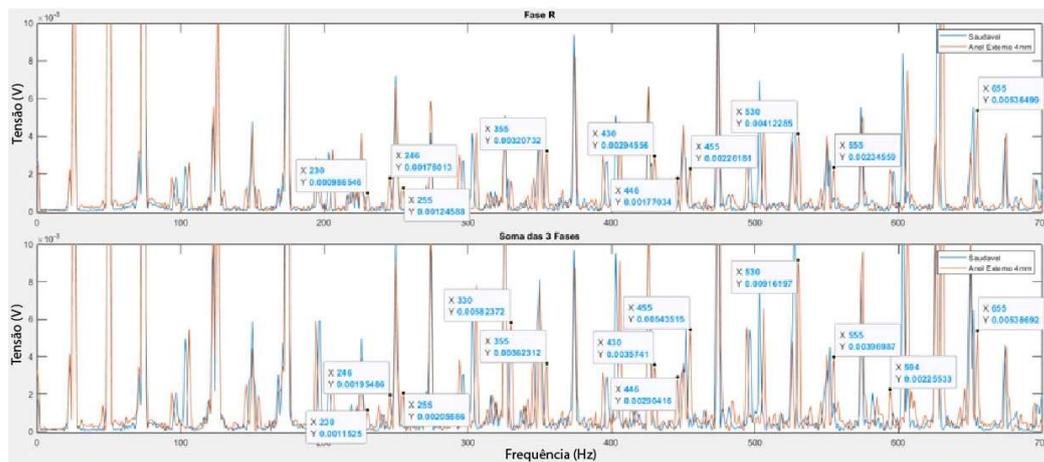


Figura 13 – FFTs da tensão diferencial induzida nas bobinas de prova da fase R (figura superior) e da soma de todas as tensões diferenciais (figura inferior).

Apresenta-se, de seguida, a escolha do algoritmo utilizado na classificação de falhas em rolamentos a partir das tensões induzidas diferenciais. Após uma ampla pesquisa sobre as diferentes redes apresentadas em diversos estudos nos últimos anos, a escolha recaiu nas Redes Neurais de Convolução devido às boas taxas de classificação e a um tempo de treino reduzido.

3.2. Rede Neuronal Convolutacional

Uma rede neuronal convolutacional é um algoritmo de aprendizagem profunda baseado no sistema visual dos seres vivos. As primeiras utilizações remontam aos anos 80, mas só nos últimos anos têm sido aplicadas a diferentes áreas de estudo [61], com o aumento do poder de computação a ser um dos maiores contribuintes para este aumento na sua utilização. Nos anos que se seguiram muitos artigos têm surgido com arquiteturas distintas, contribuindo assim para uma maior eficiência e desempenho no diagnóstico de avarias [62-70].

A CNN é composta por várias camadas de três categorias diferentes, agrupadas de maneiras distintas dependendo do objetivo e da informação fornecida à rede [50, 71]. Sendo estas a camada de convolução, a camada de *Pooling* e a Camada *FullyConnected*.

Camada de Convolução:

É a camada mais importante de toda a CNN, pois é onde ocorre a extração das características dos dados fornecidos. Esta camada utiliza um conjunto de *kernels* ou filtros para obter um mapa de características, onde o peso de cada pixel do filtro é multiplicado com o pixel da imagem onde está sobreposto e somado, resultando num valor que fica no pixel central do filtro ($\sum_{p=1}^p W_p \cdot pixel_p$) (Figura 14). Desta forma, estes filtros permitem desfocar ou aperfeiçoar uma imagem, detetar arestas e outras superfícies, ou relevos presentes nas imagens.

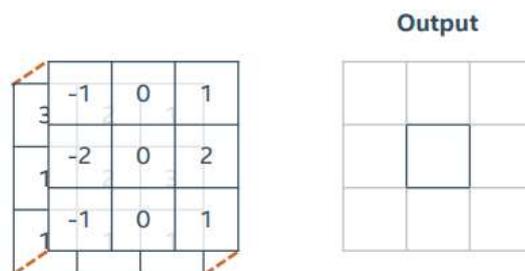


Figura 14 – Convolução de um filtro a um excerto da tabela de entrada e o seu resultado, quadrado central [50].

Dentro desta camada está presente um conjunto de hiperparâmetros que definem o tamanho da informação que sai da mesma, sendo eles:

- Tamanho do filtro: equivale ao número de pixels que o filtro vê nas imagens fornecidas à rede a cada iteração, identificando as características destas dentro das camadas de convolução. Tipicamente, estes filtros têm um tamanho de 3x3 ou 5x5;

- *Padding*: a utilização direta de filtros resulta num efeito específico nas arestas da imagem, onde os pixéis das mesmas não irão ser utilizados como “pixéis centrais”, por não existirem pixéis suficientes na sua proximidade. O *Padding* adiciona pixéis, normalmente com o valor zero, à volta do bordo da imagem original, para que cada pixel desta possa ser um pixel central à medida que o filtro varre a imagem (na Figura 15 está representado um exemplo de *Padding*);

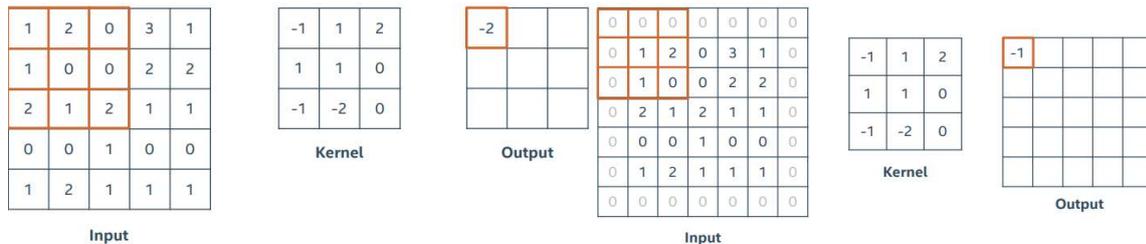


Figura 15 – Exemplo com *Padding* à direita e sem o mesmo à esquerda [50].

- Passo ou *Stride*, equivale ao tamanho do salto que o filtro realiza aquando do varrimento da imagem, e normalmente é igual tanto na vertical como na horizontal. Quando o valor deste é maior que 1, é obtida na saída uma imagem de menor tamanho do que na entrada (na Figura 16 encontra-se um exemplo de *Stride*);

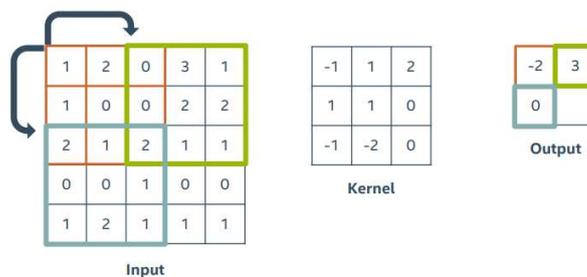


Figura 16 - Exemplo de *Stride* com n igual a 2 [50].

- Profundidade, ou *Depth*, do filtro pode ter dois conceitos: um que corresponde aos canais da imagem, dependendo do valor de profundidade das cores que a imagem inicial tenha, e outro com o número de filtros presentes numa camada de convolução.

Camada de *Pooling*:

Aparece, geralmente, a seguir à camada de convolução e tem como objetivo a redução da dimensão do mapa de características. Esta redução é realizada através de uma subamostragem do resultado obtido pela camada de convolução. Com a redução de dimensão, é conseguido um mapa de características mais robusto, sendo que outra vantagem é a redução do poder computacional

necessário, o que resulta num menor tempo de execução requerido para a execução da camada seguinte. Geralmente são utilizados dois tipos de *Pooling*, exemplificados na Figura 17:

- *Max-Pool* – seleciona o valor máximo de cada janela com um tamanho pré-definido, ao longo do mapa de características fornecido pela camada de convolução;
- *Average-Pool* – similar ao *Max-Pool*, mas ao invés de selecionar o valor máximo, efetua a média dos valores presentes na janela ao longo do mapa de características.

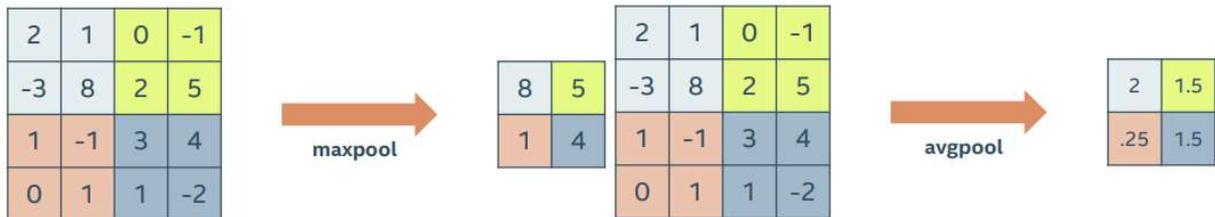


Figura 17 – Exemplo de Max-Pooling e Average-Pooling [50].

Camada *FullyConnected*:

Utilizada para a classificação das imagens fornecidas à rede, para isso baseia-se nos mapas de características extraídos pelas camadas anteriores. A camada *FullyConnected* une os vetores de alto nível dos mapas de características a um classificador, que é normalmente a função de regressão *Softmax*.

A função *Softmax* normaliza os vetores dos mapas de características numa distribuição probabilística, isto é, antes de aplicada a função, alguns componentes dos vetores podem ser negativos, maiores que um, e ainda o resultado da sua soma não ser unitário. Após a sua aplicação cada componente vai estar no intervalo (0,1), e a sua soma irá ser um, podendo estes resultados ser interpretados como probabilidades. A equação standard pode ser dada por:

$$\sigma(z)_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \text{ para } i = 1, \dots, K \text{ e } z = (z_1, \dots, z_k) \in \mathbb{R} \quad (8)$$

A seleção do algoritmo de aprendizagem profunda a utilizar na classificação das imagens recaiu numa rede neuronal convolucional devido aos melhores resultados de classificação, comparativamente com outras redes. Especificamente, nesta comparação, as redes baseadas na LeNet-5 demonstram boas taxas de classificação e um tempo de treino mais reduzido.

Como base, é utilizada a rede presente em [72], sendo a mesma denominada rede LeNet-5, a qual foi desenvolvida no final da década de 80 do século XX para o reconhecimento de números escritos à mão. A LeNet-5 é composta por quatro camadas de convolução, cada uma delas seguida de uma camada de *Pooling* e duas camadas *FullyConnected* antes da saída (Figura 18).

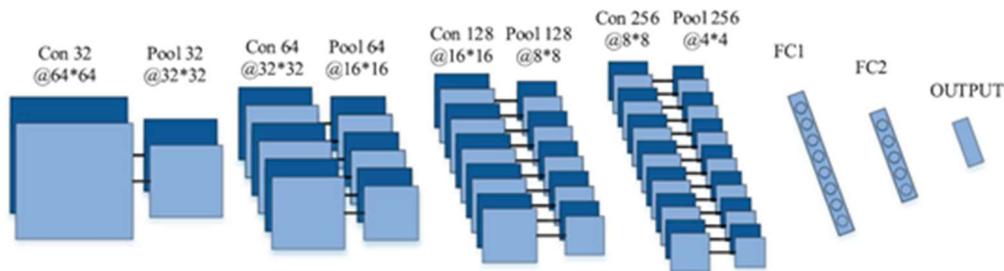


Figura 18 – CNN LeNet-5 utilizada em [72].

Depois de vários testes, sempre com o mesmo conjunto de imagens, simplificou-se a rede neuronal de modo a não afetar a taxa de classificação e conseguir tempos de treino menores. Os resultados destes conduziram a uma rede com três camadas de convolução, seguidas cada uma de uma Camada de *Pooling* e uma Camada *FullyConnected* - Figura 19 e Tabela 1.

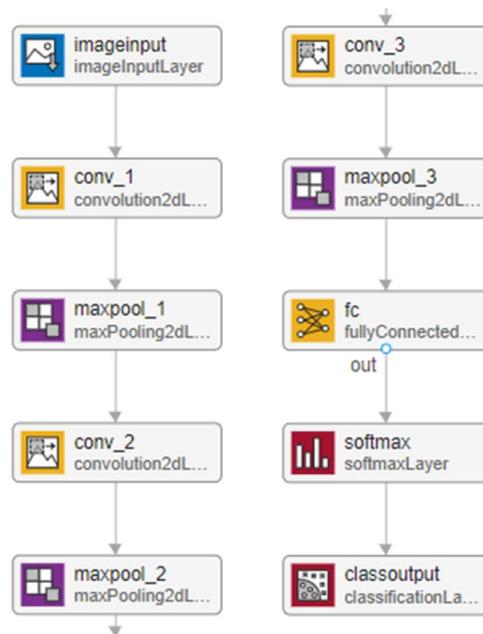


Figura 19 – CNN utilizada na classificação de imagens.

Tabela 1 – Composição da CNN utilizada na classificação de imagens.

Nº da Camada	Tipo de Camada
L1	Convolução(5x5x32)
L2	Maxpool(2x2)
L3	Convolução(5x5x64)
L4	Maxpool(2x2)
L5	Convolução(5x5x128)
L6	Maxpool(2x2)
L7	FullyConnected

3.3. Transformação Direta do Sinal em Imagens

Após a seleção do algoritmo a utilizar no método de diagnóstico, é necessário ainda a escolha da forma de criar imagens que serão fornecidas a este, a quantidade de canais de cor que a imagem possa ter (podendo ter um canal, em imagens em escala de cinzentos, ou até três ou mais em imagens a cores) e a sua dimensão, que no diagnóstico de falhas em rolamentos são normalmente de 16x16 px, 32x32 px ou 64x64 px [8, 9].

Devido à maior dificuldade das redes neuronais serem treinadas com dados temporais, ou seja, o sinal corrido numa só coluna em ordem ao tempo, é necessário encontrar forma de transformar o sinal em várias imagens distintas e assim possibilitar a extração das características das diferentes falhas ao longo do sinal recolhido.

Como abordagem inicial foi proposta a transformação direta das tensões induzidas diferenciais em imagens em escala de cinzentos. Em [72], foi desenvolvido um método de conversão do sinal no domínio do tempo em imagens. A ilustração do método de conversão pode ser visualizada na Figura 20.

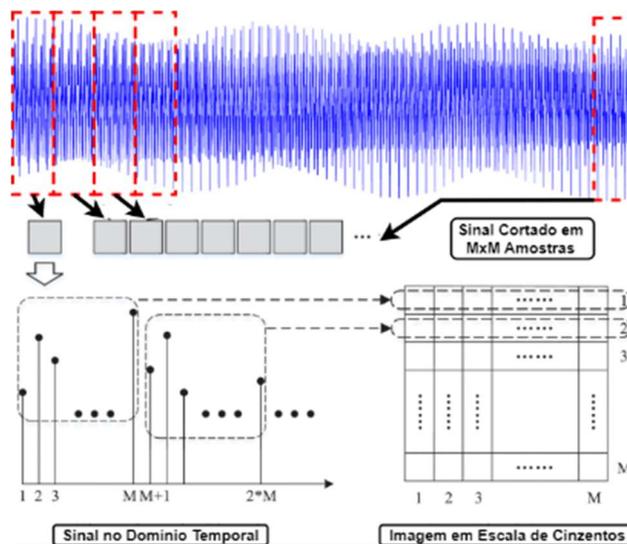


Figura 20 – Processo de conversão do sinal numa imagem em escala de cinzentos [72].

Para obter uma imagem do tamanho $M \times M$, um segmento do sinal original com tamanho M^2 é obtido e representado por $L(i), i = 1, \dots, M^2$. $P(j, k), j e k = 1, \dots, M$ denota a intensidade de cada pixel na imagem. Podemos visualizar na equação abaixo descrita [72].

$$P(j, k) = \text{round} \left\{ \frac{L(j-1) \times M + k - \text{Min}(L)}{\text{Max}(L) - \text{Min}(L)} \times 255 \right\} \quad (9)$$

A função $\text{round}(\blacksquare)$ é a função de arredondamento para a normalização do valor dos pixels de 0 a 255, que denomina a intensidade dos pixels das imagens em escala de cinzentos.

Com a vasta utilização de filtros com dimensão 2×2 px nas camadas de *polling* da rede utilizada, as dimensões das camadas de características irão ser reduzidas para metade e por isso as dimensões recomendadas para a variável M é 2^n , como 16, 32, 64, 128 [72].

As diferentes frequências de amostragem a que os dados do motor foram recolhidos, ou alteradas pela aplicação de diferentes métodos de processamento de sinal, têm influência no número de valores que se pode introduzir numa imagem. Pretende-se que pelo menos uma volta mecânica do motor, correspondente a dois períodos do sinal, esteja presente em cada imagem, devido ao facto das avarias em rolamentos se manifestarem de forma cíclica. Para se chegar ao tamanho ideal das imagens utilizou-se a seguinte expressão:

$$n = \sqrt{p * \frac{1}{f_{source}} * f_{sampling}}; n = 2, 4, 8, 16, 32, 64 \quad (10)$$

onde n é arredondado para o valor 2^k mais próximo. A variável f_{source} corresponde à frequência de alimentação do motor, $f_{sampling}$ à frequência de amostragem do sinal a transformar e p ao número de pares de polos presentes no motor.

Algumas das vantagens do treino da rede com imagens provenientes deste método de conversão são a capacidade de oferecer uma forma de explorar as características 2-D de um sinal e ainda habilidade de treino sem quaisquer parâmetros predefinidos sobre as diferentes falhas, reduzindo assim ao máximo a necessidade de conhecimento especializado [72].

Como será exposto no Capítulo 4, os resultados de treino e de teste com imagens onde os sinais extraídos foram diretamente convertidos para escala de cinzentos, não possibilitaram uma boa extração de características ficando assim comprometida a obtenção de taxas de validação aceitáveis, taxas essas abaixo dos 15%.

3.4. Métodos de Processamento de Sinal

Com a escassez de resultados satisfatórios ao transformar os sinais amostrados diretamente em imagens em escala de cinzentos, foi necessário efetuar uma análise das componentes espectrais para localizar a gama de frequências onde as falhas nos rolamentos do motor testado se manifestam com maior predominância.

Aos sinais adquiridos com o motor em funcionamento normal e com as diferentes falhas foi aplicada uma FFT, sendo depois sobrepostos os espectros relativos ao motor saudável e com os diferentes tipos de falha nos rolamentos. Desta comparação resulta uma gama de frequências onde existe diferença na amplitude das componentes características bem como na sua localização. Nesse sentido a gama de frequências onde as diferenças são mais notórias é designada de gama de interesse, a qual pode ser visualizada na Figura 21.

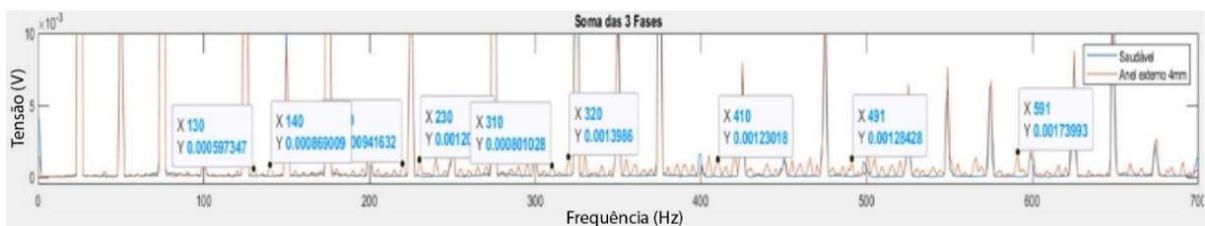


Figura 21 – Comparação entre o espectro da soma das tensões diferenciais do motor saudável e com uma falha de 4mm no anel externo do rolamento do lado do ventilador.

Com a análise das componentes espectrais dos sinais das tensões diferenciais retirados do mesmo motor, tal como efetuada em [10] e corroborada pelos sinais utilizados nesta dissertação, concluiu-se que as falhas manifestam-se nas componentes de média frequência, entre os 100 Hz e os 700 Hz.

3.4.1. Transformada de Onduleta Discreta

A transformada de onduleta contínua, em inglês *continuous wavelet transform* (CWT), foi desenvolvida por Jean Morlet no final da década de 70 como alternativa à STFT, estando o seu desenvolvimento associado à análise de sinais sísmicos. Desde a década de 90, é utilizada no diagnóstico de falhas em máquinas elétricas, maioritariamente na análise de sinais de vibração. Está definida por:

$$CWT(a, b; \psi) = a^{-\frac{1}{2}} \int x(t) \psi^* \left(\frac{t - b}{a} \right) dt \quad (11)$$

onde a é o parâmetro de escala e b é o parâmetro de tempo, ψ é a onduleta que analisa e $\psi^*(\blacksquare)$ o seu complexo conjugado.

Por outro lado, a transformada de onduleta discreta, *discrete wavelet transform* (DWT), foi concebida por Alfréd Haar no início do século XX, pois a derivada que desenvolveu enquadra-se na mesma família de onduletas, $\psi^{a,b}$, derivada da onduleta-mãe, ψ , definida respetivamente para sinais contínuos e discretos por:

$$\psi^{a,b}(s) = |a|^{-1/2} \psi \left(\frac{s - b}{a} \right) \quad (12)$$

$$\psi_{m,n}(s) = |a|^{-m/2} \psi \left(\frac{x - na_0^m b_0}{a_0^m} \right) = |a|^{-m/2} \psi(a_0^m x - nb_0) \quad (13)$$

A DWT teve diversas evoluções ao longo das últimas décadas. Em meados da década de 80, um método de análise de multiresolução (MRA) foi desenvolvido por Stéfane Mallat e Yves Meyer, o qual proporcionou a criação de transformada de onduleta rápida. Mais tarde, na década de 90, Meyer em conjunto com Coifman e Wickerhauser, criaram uma transformada de onduleta por pacotes (WPT), uma extensão da última. A WPT ao invés de só decompor o coeficiente de aproximação, como na MRA, decompõe ambos os coeficientes resultantes de cada nível de decomposição [40].

Esta transformada, a par com a CWT, tem diversas aplicações no nosso dia a dia, como por exemplo na codificação de sinais, em algoritmos de conversão de imagens e nas ciências biomédicas.

Os parâmetros a e b para a DWT são definidos como $a = a_0^m$ e $b = na_0^m b_0$, $j, k \in \mathbb{Z}$. Com esta alteração a DWT é definida por:

$$DWT(m, n; \psi) = a_0^{-\frac{m}{2}} \sum_k x(k) \psi(a_0^m k - nb_0) \quad (14)$$

onde m é o nível de decomposição e n a janela de translação. Para melhor eficiência computacional os parâmetros a_0 e b_0 são usualmente tidos com o valor 2 e 1. Nesta situação esta transformada é designada de transformada de onduleta ortonormal diática [73].

O MRA proporciona, de uma forma construtiva e eficaz, a implementação de uma DWT, ao relacionar os coeficientes das onduletas na transição de diferentes níveis ao filtrar o sinal recebido com filtros passa-baixo e passa-alto. A bidirecionalidade deste método permite tanto a decomposição como a reconstrução do sinal em vários níveis.

Com a possibilidade de decomposição de um sinal discreto, $x[k]$, obtemos

$$x[n] = \sum_k a_{j_0,k} \phi_{j_0,k}[n] + \sum_{j=j_0}^{J-1} \sum_k d_{j,k} \psi_{j,k}[n] \quad (15)$$

onde $a_{j_0,k}$ é o coeficiente de aproximação e $d_{j,k}$ o coeficiente de detalhe, $\phi_{j_0,k}[n]$ e $\psi_{j,k}[n]$ são respetivamente a função escala e onduleta-mãe definidas a uma escala de $a = 2^{j_0}$ e $a = 2^j$ respetivamente, com um fator de deslocamento k , e são definidas por:

$$\phi_{j_0,k}[n] = 2^{\frac{j_0}{2}} \phi(2^{j_0}n - k) \quad (15)$$

$$\psi_{j,k}[n] = 2^{\frac{j}{2}} \psi(2^j n - k), j = 1, \dots, J, k = 1, \dots, N/2^j \quad (16)$$

onde $\phi[n]$ é a função escala e $\psi[n]$ é a ondulentina-mãe. J corresponde ao número de níveis, definido pelo utilizador e N ao número de amostras do sinal [73].

Os coeficientes resultantes dos filtros passa-baixo e passa-alto são designados de coeficientes de aproximação, “cA_x”, e de detalhe, “cD_x”. Esta decomposição em diferentes coeficientes é determinada pelas seguintes expressões:

$$a_{j_0,k} = \sum_k h[k - 2m] a_{j_0-1,k} \quad (17)$$

$$d_{j,k} = \sum_k g[k - 2m] a_{j-1,k} \quad (18)$$

onde $h[n]$ e $g[n]$, correspondem respetivamente aos filtros passa-baixo e passa-alto.

Na Figura 22 está representada a decomposição MRA do sinal, com os diversos filtros passa-baixo e passa-alto, e as gamas de frequência cobertas pelos diferentes coeficientes.

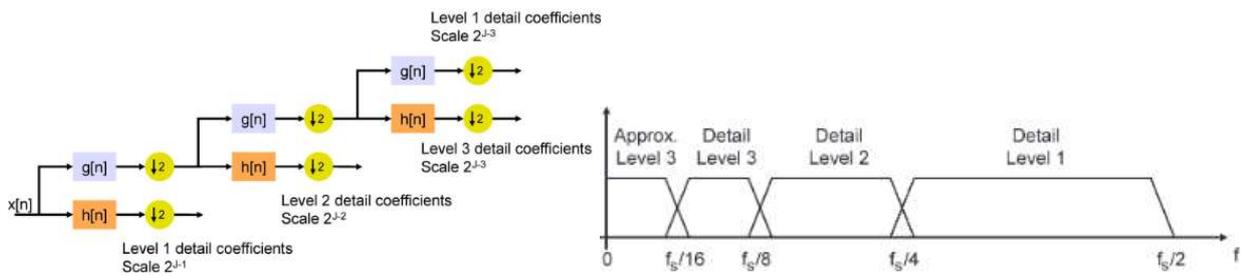


Figura 22 – Decomposição do sinal, segundo a MRA em 3 níveis e respectivas gamas de frequência [74].

Com um princípio de funcionamento semelhante ao da MRA, a WPT decompõe todas as componentes do sinal na sua respetiva banda de frequências, isto é, os coeficientes de detalhe são também decompostos para que todos os coeficientes tenham a mesma banda de frequências. É possível visualizar a árvore de decomposição e a suas bandas de frequência na Figura 23.

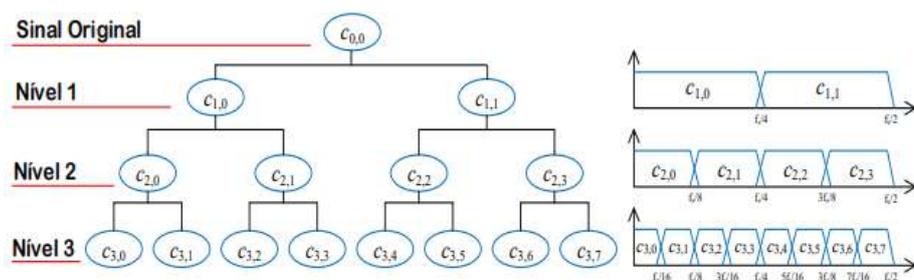


Figura 23 – Diagrama da decomposição do sinal em 3 níveis e suas gamas de frequência, utilizando o WPT [40].

A escolha neste trabalho recaiu na DWT devido à possibilidade de isolar uma gama de frequências mais baixa nos sinais originais, mais próximas das frequências características das avarias nas tensões induzidas diferenciais, que se localizam abaixo de 1 kHz, eliminando assim as componentes de alta frequência dos sinais.

A introdução de imagens em escala de cinzentos (convertidas através do mesmo método de conversão presente na secção anterior) a partir do sinal processado por uma DWT na rede, não obteve os resultados pretendidos, sendo difícil a extração das características das falhas por parte da rede.

Atendendo ao descrito anteriormente, avançou-se para uma análise no domínio do tempo-frequência dos sinais. Uma vez que é pretendida a criação de imagens onde a escala da frequência seja linear para obter uma melhor extração das pequenas características das falhas por parte da rede, a CWT não é a melhor opção, devido ao facto do domínio desta não ser linear no eixo da frequência.

3.4.2. Transformada de *Stockwell*

A técnica tempo-frequência selecionada para aplicar aos sinais recolhidos foi a transformada de *Stockwell* devido à sua melhor definição e à fácil seleção da gama de frequências que se pretende visualizar, podendo assim extrair-se a gama de valores de frequência onde estão presentes as falhas.

A transformada de *Stockwell*, *S-Transform* (equação), é uma generalização da STFT, estendendo-a à transformada contínua de onduleta e ultrapassando algumas das suas desvantagens. A mesma tem ganho popularidade na comunidade de processamento de sinal devido à sua fácil implementação e rápida computação. Esta técnica tem tido grandes desempenhos na classificação e na resolução de problemas de extração de características aplicados a sinais não estacionários, como o batimento cardíaco, sinais de qualidade de potência, sinais EEG, etc. [75].

Genericamente a *S-Transform* utiliza uma janela Gaussiana, cujo desvio padrão varia com a frequência. Entretanto para o sinal a ser analisado, o comprimento dessa janela vai diminuir à medida que a frequência aumenta, produzindo uma maior definição do espectrograma a baixas frequências e uma maior resolução de tempo a altas frequências [75].

A *S-Transform* pode ser obtida pela seguinte equação:

$$S_x(\tau, f) = \int_{-\infty}^{+\infty} x(\tau) |f| e^{-\pi(\tau-t)^2 f^2} e^{-j2\pi f t} dt \quad (19)$$

Uma nova otimização da *S-Transform* foi apresentada em [75], com o objetivo de melhorar a sua resolução tempo-frequência. A metodologia é baseada numa nova janela gaussiana híbrida com parâmetros a controlar a largura.

A introdução dos parâmetros m , p , k e r , dão uma maior flexibilidade à janela Gaussiana. Assim, a *S-Transform* utilizada é dada por:

$$S_x^{m,p,k,r}(\tau, f) = \int_{-\infty}^{+\infty} x(t) \frac{|f|^r}{(mf^p + k)\sqrt{2\pi}} e^{\frac{-(\tau-t)^2 f^{2r}}{2(mf^p+k)^2}} e^{-j2\pi f t} dt \quad (20)$$

Podemos visualizar esta otimização na Figura 24, estabelecendo a comparação entre a *S-transform* standard e a otimização proposta. É possível verificar que a otimização proposta apresenta uma maior definição do sinal no domínio do tempo-frequência.

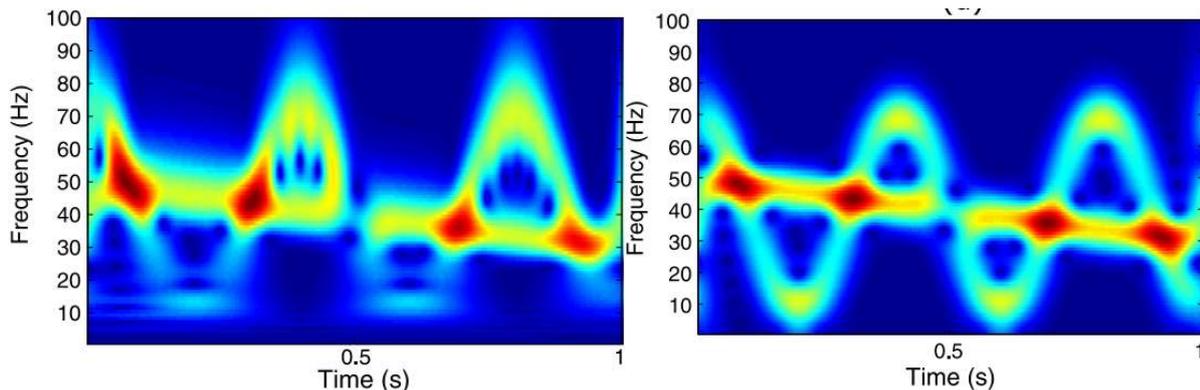


Figura 24 – Representação de um sinal no domínio do tempo-frequência utilizando a *S-Transform* standard e a *S-Transform* otimizada [75].

O treino da rede neuronal com os histogramas resultantes da aplicação da *S-Transform* otimizada, resultou em taxas de classificação conforme o objetivo desta dissertação, estando estes resultados estão expostos no Capítulo 4.

Para melhor identificação das falhas na gama de interesse, foram eliminadas as componentes harmônicas de baixa frequência relacionadas com o funcionamento do motor. Estas componentes surgem devido a desalinhamentos da carga com o veio do motor e a harmônicos intrínsecos ao funcionamento do motor. Para esse efeito aplicou-se um filtro passa-alto *Butterworth* com uma frequência de corte de 125Hz ao sinal recolhido antes da aplicação da *S-Transform*, dando origem a imagens onde as componentes da gama de interesse estão mais salientes. Na Figura 25 são apresentadas as imagens com e sem a aplicação do filtro passa-alto.

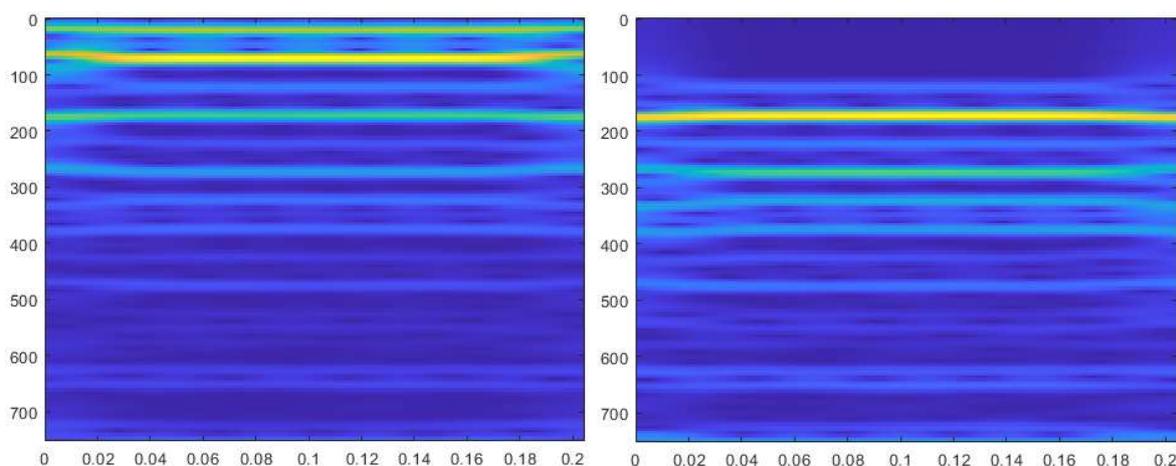


Figura 25 –Histogramas das tensões diferenciais resultantes do pré-processamento: a) utilizando o sinal original; b) usando um filtro passa-alto de 4ª ordem, do tipo *Butterworth*.

Com a gama de interesse localizada até aos 700Hz, muito abaixo do máximo atingível com uma frequência de amostragem de 20 kHz onde o espectro apresenta valores até 10kHz, foi realizada uma subamostragem do sinal onde a cada quatro valores é recolhido um, resultando numa frequência de amostragem equivalente de 5 kHz com valores no espectro até 2.5 kHz. Resulta assim num processo de conversão de imagens que requer menos poder computacional ao aplicar a nova otimização da *S-Transform*.

4. Análise e Discussão dos Resultados

Com o intuito de testar a possível aplicabilidade da estratégia de diagnóstico proposta, foram realizados diversos ensaios experimentais para a obtenção de várias grandezas do motor, tais como os sinais de vibração na carcaça do motor e de alimentação do mesmo, bem como as tensões induzidas no motor. Os ensaios foram realizados com o motor em funcionamento com diferentes falhas nos seus rolamentos e a diversos níveis de carga. Seguidamente são apresentados a montagem experimental e os resultados obtidos de maior relevância.

4.1. Descrição da Montagem Experimental

Para validar a metodologia de diagnóstico proposta nesta dissertação, foi utilizada a montagem laboratorial apresentada na Figura 26.

O objetivo destes ensaios foi o de adquirir os sinais das tensões induzidas em cada bobina de prova, que possibilitaram a obtenção das tensões diferenciais, que foram posteriormente analisadas pelas diferentes iterações/versões do método de diagnóstico proposto no capítulo anterior. O sistema de aquisição de dados está também equipado com um acelerômetro para a aquisição dos sinais de vibração da carcaça do motor, sendo que também foram adquiridas ainda as tensões e correntes de alimentação do motor.

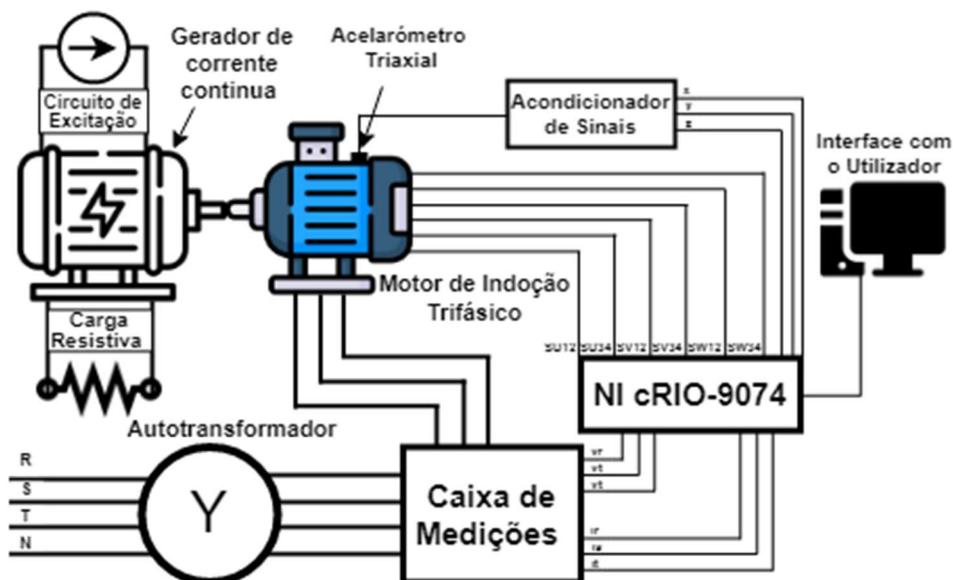


Figura 26 – Diagrama da montagem laboratorial [10].

O motor de indução trifásico (MIT) usado nos ensaios experimentais tem uma potência nominal de 3 kW, Anexo 3. Apresenta os enrolamentos estatóricos ligados em triângulo, sendo os mesmos alimentados com uma tensão composta de 360 V, 50 Hz, através de um autotransformador ligado à rede de 400 V. Foram ainda efetuados ensaios com o motor alimentado por um conversor de frequência, sendo neste caso alimentado a diferentes frequências.

O MIT foi acoplado mecanicamente a um gerador de corrente contínua de 4 kW, que alimentava uma carga resistiva variável e funcionava com um circuito de excitação separado. Através da regulação da corrente de excitação do gerador, foi possível analisar o comportamento do motor para diferentes níveis de carga (vazio, 0%, 25%, 50%, 75% e 100%), caracterizados pela velocidade de rotação do grupo motor/gerador.

De modo a classificar os diferentes tipos de falhas que podem ocorrer nos rolamentos, recorreu-se a rolamentos previamente danificados em laboratório, sendo estes caracterizados segundo a localização da falha e o grau de severidade da mesma [17].

Deste modo foram utilizados rolamentos do lado do ventilador com furos únicos de 2 e 4 mm de diâmetro nos anéis interno e externo e com uma das suas 9 esferas danificadas, e um rolamento do lado do ataque com estriamentos generalizados em ambos os anéis (para simular esta falha fez-se circular uma corrente elétrica de elevado valor através do rolamento durante várias horas), um exemplo com duas falhas é apresentado na Figura 27. É possível observar na Tabela 2 que rolamentos foram utilizados em cada ensaio.



Figura 27 – Rolamentos com falhas, do lado esquerdo: furo de 4mm no anel externo do lado do ventilador e do lado direito: furo de 4mm no anel interno do lado do ventilador.

Tabela 2 – Posição dos rolamentos com as várias falhas para cada um dos ensaios.

Ensaio	Rolamento do Lado do Ataque (6206)	Rolamento do Lado do Ventilador (6205)
1	Saudável	Anel Externo 2mm
2	Saudável	Anel Externo 4mm
3	Saudável	Anel Interno 2mm
4	Saudável	Anel Interno 4mm
5	Saudável	Esferas
6	Estriamento Generalizado	Saudável
7	Saudável	Saudável

As falhas foram maioritariamente introduzidas nos rolamentos do lado do ventilador, à exceção do rolamento com estriamentos generalizados, estando este do lado do ataque. Acrescenta-se que do lado oposto aos rolamentos com falhas estão rolamentos saudáveis.

De acordo com as indicações do fabricante do motor, os rolamentos pertencem à série 6206 no lado do ataque e 6205 do lado do ventilador e são compostos por 9 esferas. As dimensões dos rolamentos encontram-se descritas na Tabela 3.

Tabela 3 – Dimensão dos Rolamentos.

Dimensões	6205	6206
Anel Externo	52 mm	62 mm
Anel Interno	25 mm	30 mm
Nº Esferas	9	9

Aquando da aquisição dos sinais, para cada uma das situações de funcionamento, foram efetuados ensaios com o motor alimentado pela rede a 50 Hz e por um conversor de frequência, com frequências de saída dos 10 Hz até os 50 Hz em intervalos de 10 Hz. Para cada uma destas situações foram aplicados 6 níveis de carga (motor desacoplado, acoplado com a excitação do MCC desligada, 25%, 50%, 75% e à carga nominal). Os sinais foram adquiridos a uma frequência de amostragem de 20 kHz durante 5 segundos, o que perfaz um total de 100 mil pontos por cada ensaio. Na Tabela 4 estão representadas as velocidades de rotação do motor para os diversos níveis de carga com o MIT alimentado a 50 Hz.

Tabela 4 – Velocidade para diferentes níveis de carga.

Nível de Carga	Desacoplado	Vazio	25%	50%	75%	100%
Velocidade de Rotação (rpm)	≈1500	1497	1489	1478	1467	1456

Os sinais das correntes e tensões das três fases de alimentação do motor foram obtidos através de sensores de efeito Hall presentes na caixa de medições por onde passa o cabo de alimentação do mesmo. Nestas medições é necessário ter em conta as razões de transformação dos sensores, sendo estas de 3:1 para a corrente e de 65:1 para as tensões. Por outro lado, os sinais de vibração foram adquiridos por um acelerómetro triaxial, que permite a captação das vibrações da carcaça do motor ao logo de três eixos - direção tangencial (eixo do x), direção axial (eixo do y) e direção radial (eixo do z). De modo a garantir um contacto firme e estável o acelerómetro está fixado à carcaça do motor através de um parafuso, possibilitando assim a aquisição de sinal a altas frequências com menor risco de perturbações associadas a um mau contacto com a carcaça.

Os sinais de vibração e de alimentação foram adquiridos, mas, no entanto, não foram utilizados na presente dissertação. A montagem experimental está presente na Figura 28.

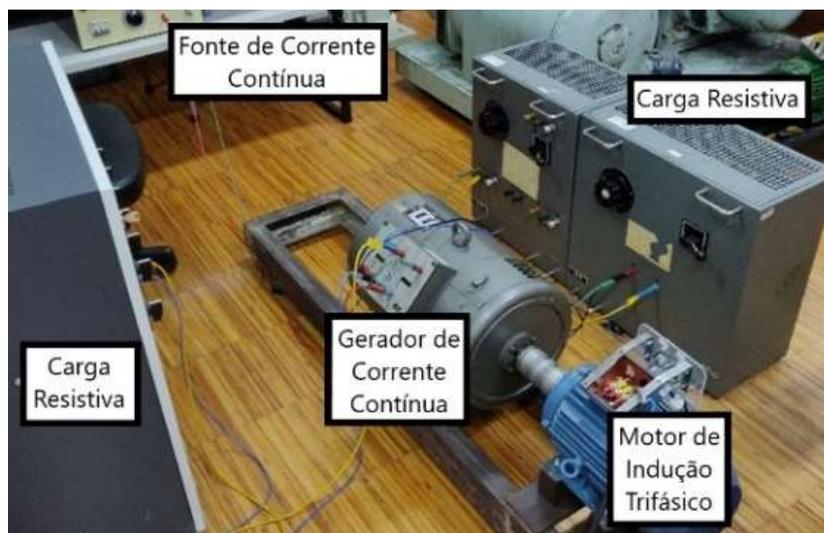


Figura 28 – Montagem experimental.

As tensões induzidas são adquiridas por via de 6 bobinas de prova colocadas no estator do motor, como foi anteriormente referido no capítulo 4. As bobinas são compostas por duas espiras cada, de forma a que as medições efetuadas sejam compatíveis com os níveis de sinal dos módulos de entrada do cRIO-9066 sem serem necessários transformadores externos. As 6 medições resultantes foram posteriormente processadas, resultando nas 3 tensões induzidas diferenciais, uma por cada fase do motor. É possível observar os terminais para aquisição das tensões induzidas na Figura 29.



Figura 29 – Terminais para a aquisição das tensões induzidas.

Os valores medidos são recolhidos por um controlador cRIO-9066 da National Instruments (NI). Este controlador é a combinação de uma FPGA e de um processador onde ocorre um sistema de controlo em tempo real. Para a aquisição dos sinais analógicos, foram utilizados 4 módulos NI 9215 com 4 terminais BNC cada. Na Figura 30 está presente a montagem laboratorial para a aquisição e acondicionamento das diferentes variáveis recolhidas, assim como a alimentação do motor e o controlador cRIO.

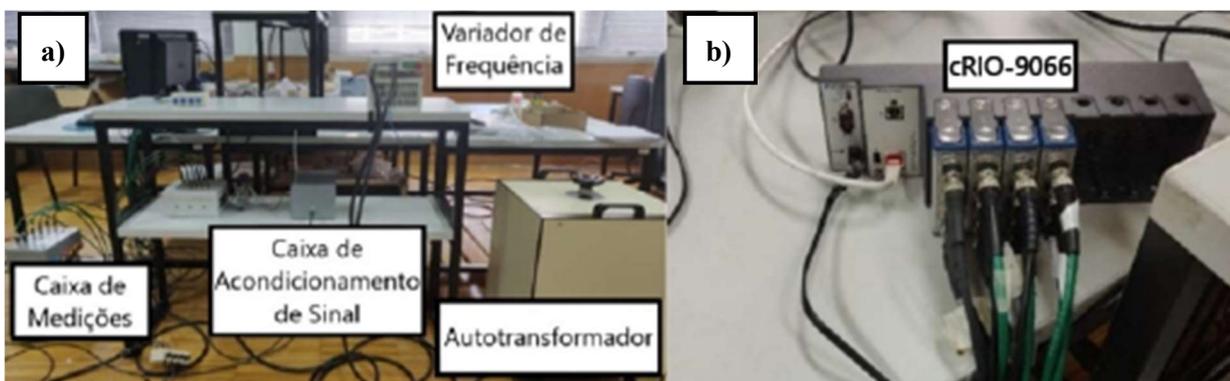


Figura 30 – a) Montagem laboratorial para a aquisição e acondicionamento das diferentes variáveis do motor e a alimentação do motor. b) Controlador cRIO-9066.

A interface com o utilizador é efetuada através de uma aplicação desenvolvida em ambiente LabView, que nos permite definir a frequência de amostragem e o número de pontos e amostras recolhidas em cada ensaio.

4.2. Treino da Rede Neuronal

Com o objetivo de atingir uma taxa de validação mais elevada e um tamanho de imagem ideal, foram testados diferentes casos de treino. Para cada iteração, correspondente a cada uma das abordagens na transformação dos dados em imagens, foram escolhidos inicialmente dois tamanhos diferentes de imagem, conforme a equação 10, para que na imagem com menor dimensão esteja representada pelo menos uma volta mecânica completa do rotor. Os tamanhos de imagens testados são de 16x16 px, 32x32 px e 64x64 px.

As dimensões das imagens usadas no método de diagnóstico foram selecionadas através dos resultados obtidos no caso de treino inicial (caso 1 da Tabela 5). O tamanho da imagem que obtiver melhores taxas de classificação sem que o tempo de treino seja excessivamente prolongado, será o tamanho adotados nos casos seguintes.

Ao iniciar o treino da rede neuronal com um conjunto de imagens reduzido, sem um aumento de dados¹ (caso 1 da Tabela 5), fica-se a perceber se as características de cada falha presentes nas imagens do conjunto de dados são bem identificadas pela rede neuronal. Se os resultados no caso inicial de treino não forem os expectáveis, ou seja, se a rede apresenta dificuldades em extrair as características das imagens, conduzindo a valores de validação baixos, o método de diagnóstico é repensado, ou seja, efetuada uma nova pesquisa onde se encontra o método que poderá obter melhores resultados com a informação retirada pela iteração anterior, e avança-se para a iteração seguinte.

Deste modo, caso as taxas de classificação obtidas com o conjunto de dados reduzido sejam superiores a 90%, prosseguimos a mesma iteração do método de diagnóstico com um aumento do conjunto de dados (aumento de dados). O aumento do conjunto de dados é efetuado primeiramente com a adição de outros dois testes laboratoriais obtidos nas mesmas condições (caso 2 de Tabela 5) e posteriormente por via da sobreposição da imagem seguinte com parte da anterior (caso 3 da Tabela 5).

Por último, se os resultados de validação e teste forem os pretendidos, o método de diagnóstico é aplicado a valores cegas onde a rede não foi previamente treinada (caso 4 e 5 da Tabela 5), onde a rede é treinada e validada em certas condições de carga e testada noutras. Os casos de treino usados estão descritos na Tabela 5.

¹ Aumento de dados – técnica utilizada para aumentar a qualidade da base de dados adicionando cópias ligeiramente modificadas de dados já existentes.

Tabela 5 – Bases de dados utilizadas para cada caso de treino em cada iteração do método de diagnóstico.

Caso de Treino	Conjunto de Dados de Treino e Validação	Conjunto de Dados de Teste
1	Todas as cagas de um teste	Todas as cagas de um teste
2	Aumento do conjunto de dados com os outros dois testes	Aumento do conjunto de dados com os outros dois testes
3	Aumento do conjunto de dados com sobreposição de imagens	Aumento do conjunto de dados com sobreposição de imagens
4	Vazio-50%-100%	25%-75%
5	Vazio-25%-75%-100%	50%

O conjunto de dados completo é dividido aleatoriamente em 2 grupos, com imagens distintas, um com 90% do total das imagens para treino e validação da rede e 10% para testar a rede depois do treino. Aquando da etapa de treino, o grupo com 90% das imagens é ainda subdividido em duas partes: uma delas, com 80% do total de imagens do grupo que irá ser utilizado para o treino efetivo da rede e os restantes 20% serão usados para a validação da mesma ao longo do treino. Uma representação desta divisão é ilustrada na Figura 31.

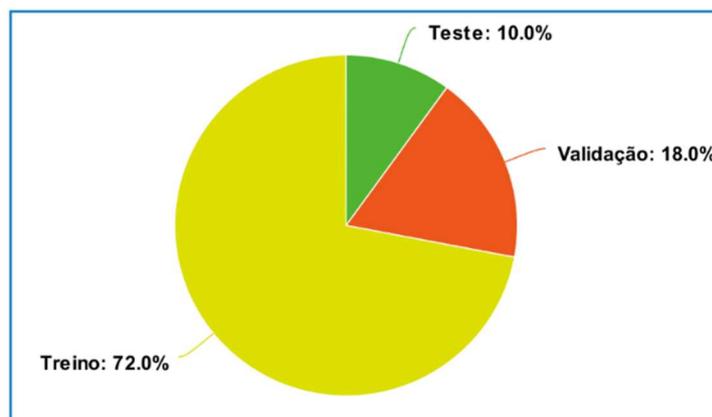


Figura 31 – Divisão do conjunto de dados global para efeitos de treino, validação e teste da rede neuronal.

O *solver* definido para o treino da rede foi o algoritmo de otimização *Adam* (*adaptive moment*), que é uma extensão do método estocástico de gradiente descente. Durante a realização da pesquisa, foi possível verificar que este *solver* foi recorrentemente utilizado e exposto como o mais célere a proporcionar resultados satisfatórios.

Com vista ao projeto e desenho da rede neuronal, bem como à realização do seu respetivo treino e validação, foi utilizada a ferramenta *Deep Learning Designer*, presente na *Deep Learning*

Toolbox do *MATLAB*. Após encontradas as opções de treino ideais para cada conjunto de dados, foram efetuados 10 treinos onde foram anotadas as respectivas taxas de validação, as taxas de teste e os tempos de treino da rede. A média destes treinos corresponde aos resultados finais de classificação para o respetivo conjunto de dados.

4.3. Transformação Direta do Sinal em Imagens

A transformação direta da soma das tensões diferenciais induzidas diferenciais, em imagens em escala de cinzentos, foi efetuada conforme os procedimentos descritos no capítulo 3. O tamanho ideal das imagens foi escolhido conforme a equação 10, sendo este 32x32 px. Para efeitos de comparação, foi também selecionado o tamanho seguinte - 64x64 px.

A transformação originou as imagens de tamanho 32x32 px que estão presentes na Tabela 6, e as de tamanho 64x64 px apresentadas na Tabela 7.

Nestas imagens, cada pixel corresponde a um valor de um ponto do sinal normalizado entre 0 e 255. Os valores mais elevados correspondem a tons mais claros e os valores mais baixos a tons mais escuros. As imagens apresentam características distintas dependendo da condição de carga a que está a operar o motor e ao tipo de falha presente. As características poderão ou não ser distinguíveis o suficiente para que a rede neuronal as consiga detetar.

Tabela 6 – Exemplo de imagens do conjunto de dados obtidas através da transformação direta do sinal em escala de cinzento com tamanho 32x32 px.

Situação	Condição de Carga					
	Desacoplado	Vazio	25%	50%	75%	100%
Anel Externo 2mm						
Anel Externo 4mm						
Anel Interno 2mm						
Anel Interno 4mm						
Esferas						
Estriamento Generalizado						
Saudável						

Tabela 7 - Exemplo de imagens do conjunto de dados obtidas através da transformação direta em escala de cinzento com tamanho 64x64 px.

Situação	Condição de Carga					
	Desacoplado	Vazio	25%	50%	75%	100%
Anel Externo 2mm						
Anel Externo 4mm						
Anel Interno 2mm						
Anel Interno 4mm						
Esferas						
Estriamento Generalizado						
Saudável						

Os conjuntos de dados utilizados no caso de treino realizado nesta iteração do método de diagnóstico estão descritos de forma sucinta na Tabela 8.

Tabela 8 – Conjuntos de dados para o caso de treino realizado nesta iteração do método de diagnóstico.

Caso de Treino	Conjunto de Dados de Treino e Validação	Tamanho (px)	Nº de Imagens		Conjunto de Dados de Teste	Nº de Imagens
			Treino	Validação		
1	Todas as cagas de um teste	32x32	2934	734	Todas as cagas de um teste	406
		64x63	726	181		91

A primeira iteração do método de diagnóstico proposto foi efetuada com o treino da CNN com o conjunto de dados com imagens transformadas diretamente em escalas de cinzentos, de tamanho 32x32 px. O conjunto de dados é constituído por 97 imagens por condição de carga e por

cada situação de funcionamento do motor, perfazendo um total de 4074 imagens. No entanto o conjunto de dados é dividido em grupos distintos com diferentes propósitos, sendo que 2934 imagens são para treino, 734 imagens para validação e 406 imagens para teste.

Os gráficos de treino e validação da rede estão presentes na Figura 32, onde a linha azul representa a percentagem de treino e os pontos a preto representam a validação da mesma. Ainda na Figura 32, a linha a laranja representa a função de perdas, correspondente à confiança que a rede tem no resultado que apresenta.

Do lado direito da Figura 32 é ilustrada uma matriz de confusão, com os resultados de teste obtidos e a sua verdadeira classe. Muito sucintamente, a situação ideal da matriz de confusão ocorre quando não existe classificações fora da diagonal principal da mesma.

Após os 10 treinos com as opções de treino que obtiveram as melhores taxas de classificação, a média dos resultados de validação no final do treino foi de **13,53%** e a de teste fora da plataforma de treino foi de **12,36%**, resultados muito aquém do pretendido. Para o tempo de treino obteve-se uma média de **1 minuto e 33 segundos**.

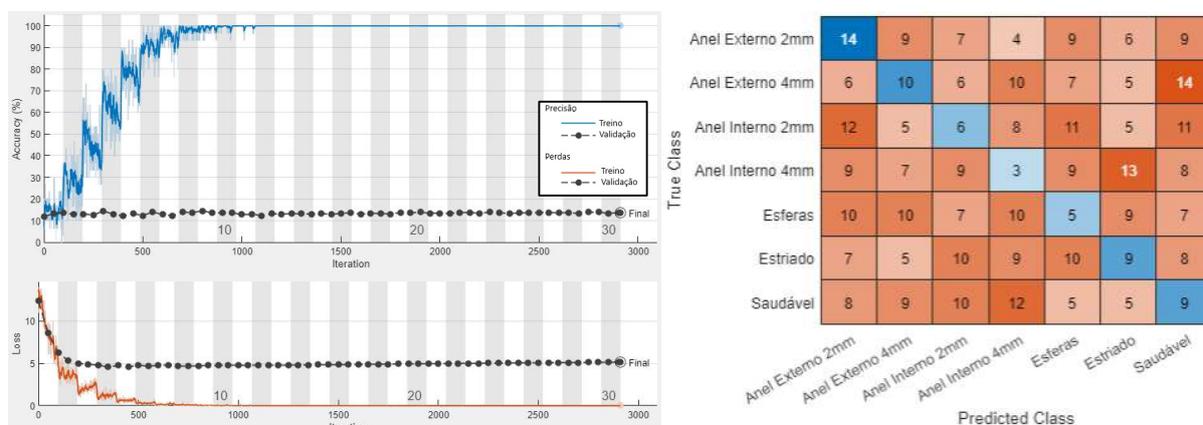


Figura 32 – Gráficos de treino, validação e função de perdas durante o treino da rede neuronal e matriz de confusão das imagens de teste com o conjunto de dados de transformação direta 32x32 px.

Seguidamente, avançou-se com o treino da CNN com um conjunto de dados de tamanho 64x64 px. O conjunto de dados é constituído por 24 imagens por condição de carga e por cada situação de funcionamento do motor, perfazendo um total de 1008 imagens. Tal como na situação anterior o conjunto de dados foi dividido em grupos, onde 726 imagens são para treino, 181 imagens para validação e 91 imagens para o teste.

Depois de efetuados 10 treinos com as opções de treino que obtiveram as melhores taxas de classificação, a média dos resultados de validação final foi de **11,21%** e a de teste, com as mesmas

redes fora da plataforma de treino, foi de **12,25%**. Quanto ao tempo de treino das redes obteve-se uma média de **1 minuto e 21 segundos**. Na Figura 33, está presente o gráfico de treino, validação e de perdas, e ainda a matriz de confusão para o conjunto de dados de tamanho 64x64 px.

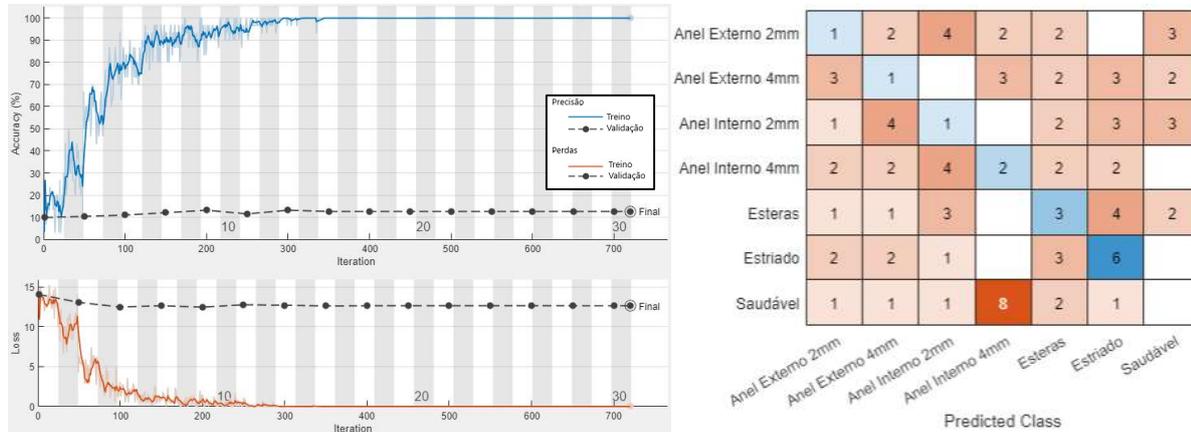


Figura 33 – Gráficos de treino, validação e função de perdas durante o treino da rede neuronal e matriz de confusão das imagens de teste com o conjunto de dados de transformação direta 64x64 px.

Ao analisar os resultados de validação e de teste, tanto para o conjunto de dados com imagens de tamanho 32x32 px como para a de 64x64 px, verifica-se que a rede neuronal não tem a capacidade para identificar as características subtis que as falhas manifestam numa imagem proveniente de uma transformação direta dos sinais. Desse modo, é possível verificar que os resultados apresentam taxas de teste muito aquém do pretendido.

4.4. Métodos de Processamento de Sinal

Devido à falta de resultados positivos na primeira iteração do método, foram utilizadas várias técnicas de processamento de sinal. O uso destas técnicas teve como objetivo isolar a gama de frequências de interesse onde estão localizadas as frequências características das falhas.

Como exposto no Capítulo 3, a gama de frequências onde as falhas se manifestam está localizada entre os 150 Hz e os 750 Hz, na qual é observada uma maior amplitude nas componentes do espectro de frequência bem como uma maior diferença na comparação com a situação saudável.

Nas próximas iterações do método de diagnóstico, aplicaram-se métodos de processamento de sinal à soma das tensões diferenciais, primeiramente métodos no domínio da frequência e depois no domínio do tempo-frequência, DWT e *S-Transform*, respetivamente.

4.4.1. Transformada de Onduleta Discreta

Nesta iteração do método de diagnóstico foi aplicada à soma das tensões diferenciais uma DWT de nível 3. Foi escolhido o nível 3, pois este dá origem ao coeficiente de aproximação mais perto da gama de frequências de interesse com a frequência de amostragem do sinal inicial. Neste caso, o coeficiente de aproximação do nível 3, cA_3 , comporta valores de frequência entre 0 e 1250 Hz, onde se encontra a gama de frequências de interesse. Desse modo as componentes de frequências mais elevadas presentes nos sinais são eliminadas e, por conseguinte, eliminada uma grande parte do ruído presente nas imagens das bases de dados anteriores.

Ao aplicarmos a equação 10, verifica-se que o tamanho ideal para as imagens é de 16x16 px, para que esteja representada numa imagem única pelo menos uma volta mecânica do rotor, como foi referido anteriormente. Para efeitos de comparação foi também escolhido o tamanho 32x32 px.

Nestas imagens, tal como nas imagens da iteração anterior, cada pixel corresponde a um valor de um ponto do sinal normalizado entre 0 e 255, onde as amplitudes mais elevadas do sinal correspondem a tons mais claros e as mais baixas a tons mais escuros.

A transformação originou as imagens de tamanho 16x16 px que estão presentes na Tabela 9, e as de tamanho 32x32 px, apresentadas na Tabela 10.

Tabela 9 – Imagens obtidas depois de aplicada uma DWT de nível 3 com tamanho 16x16 px.

Situação	Condição de Carga					
	Desacoplado	Vazio	25%	50%	75%	100%
Anel Externo 2mm						
Anel Externo 4mm						
Anel Interno 2mm						
Anel Interno 4mm						
Esferas						
Estiramento Generalizado						
Saudável						

Tabela 10 – Imagens obtidas depois de aplicada uma DWT de nível 3 com tamanho 32x32 px.

Situação	Condição de Carga					
	Desacoplado	Vazio	25%	50%	75%	100%
Anel Externo 2mm						
Anel Externo 4mm						
Anel Interno 2mm						
Anel Interno 4mm						
Esferas						
Estiramento Generalizado						
Saudável						

Os conjuntos de dados utilizados no caso de treino realizado nesta iteração do método de diagnóstico estão descritos de forma sucinta na Tabela 11.

Tabela 11 – Conjuntos de dados para o caso de treino realizado nesta iteração do método de diagnóstico.

Caso de Treino	Conjunto de Dados de Treino e Validação	Tamanho (px)	Nº de Imagens		Conjunto de dados de Teste	Nº de Imagens
			Treino	Validação		
1	Todas as cagas de um teste	16x16	1451	363	Todas as cagas de um teste	202
		32x32	302	76		42

O conjunto de dados com imagens de tamanho 16x16 px geradas depois de aplicada uma DWT de nível 3, é constituída por 48 imagens por condição de carga e por cada situação de funcionamento do motor, o que equivale a um total de 2016 imagens. Com a respetiva divisão nos diferentes grupos, obtemos 1451 imagens para treino, 363 imagens para validação da rede durante o treino e 202 imagens para o teste.

Depois de efetuado o treino, por 10 vezes, com as mesmas opções de treino que resultaram nas melhores taxas de classificação, a média dos resultados de validação final foi de **20,58%** e a de teste, fora da plataforma de treino, foi de **20,05%**. Em relação ao tempo de treino destas redes obteve-se uma média de **1 minuto e 40 segundos**. Na Figura 34, está presente o gráfico de treino, validação e de perdas, e ainda a matriz de confusão para o conjunto de dados de tamanho 16x16 px.

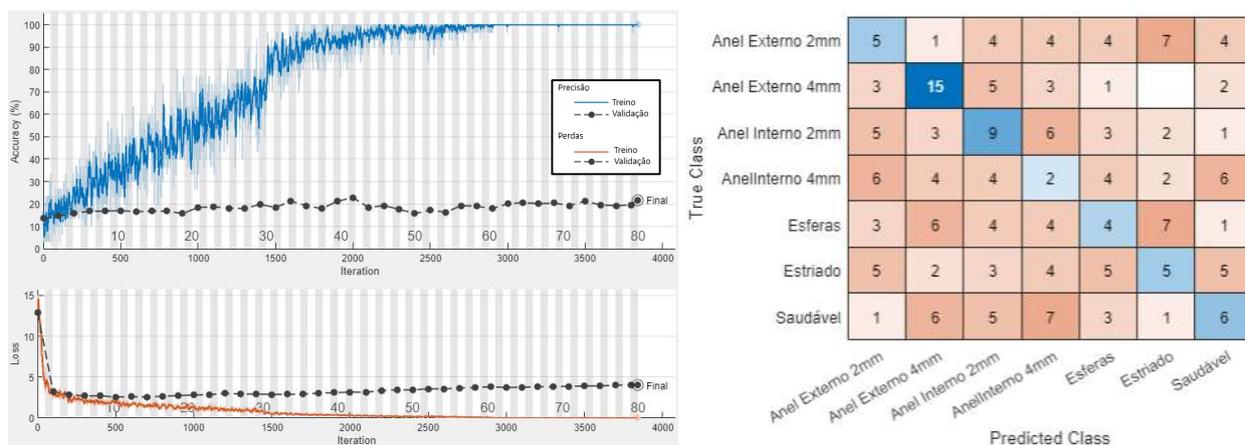


Figura 34 – Gráficos de treino, validação e função de perdas durante o treino da rede neuronal e matriz de confusão das imagens de teste com conjunto de dados onde é aplicada uma DWT 16x16 px.

De seguida o treino foi efetuado a partir de um conjunto de dados com imagens de tamanho 32x32 px, obtida através do mesmo método da iteração anterior. Esta é constituída por 10 imagens por condição de carga e por cada situação de funcionamento do motor, totalizando 420 imagens. Após a divisão para os diferentes propósitos, foram obtidas 302 imagens para treino, 76 imagens para validação durante o treino e 42 imagens para a etapa de teste.

Tal como nas situações anteriores o treino foi realizado por 10 vezes, verificando-se que a média dos resultados de validação final foi de **11,43%** e a de teste, fora da plataforma de treino, foi de **14,76%**. Quanto ao tempo de treino destas redes resultou numa média de **18 segundos**. Na Figura 35 está presente o gráfico de treino, validação e de perdas, e ainda a matriz de confusão para o conjunto de dados de tamanho 32x32 px.

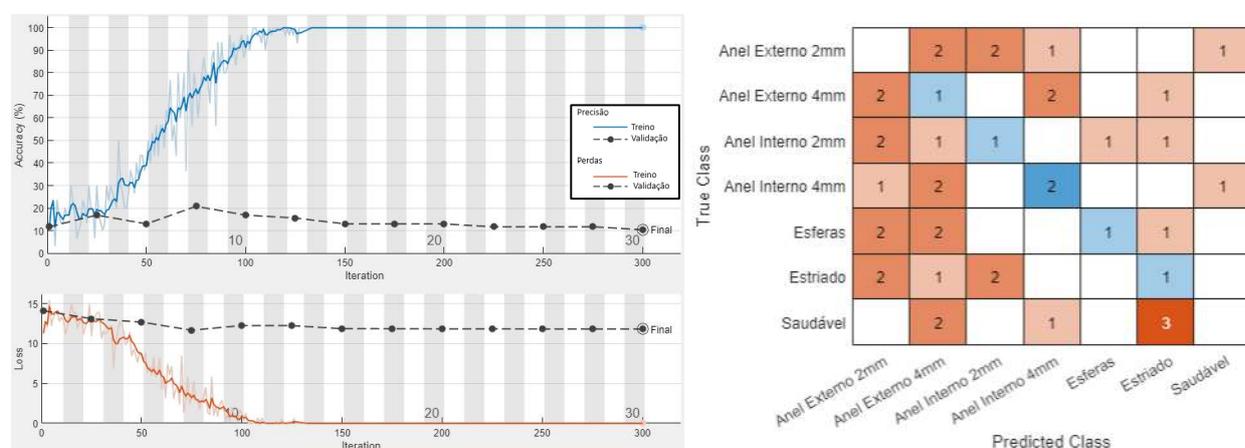


Figura 35 – Gráficos de treino, validação e função de perdas durante o treino da rede neuronal e matriz de confusão das imagens de teste com o conjunto de dados onde é aplicada uma DWT 32x32 px.

Ao analisar os resultados de validação e de teste, tanto para o conjunto de dados com imagens de tamanho 16x16 px como para a de 32x32 px, verifica-se que (embora na primeira as taxas duplicaram em relação à transformação direta em imagens) a rede neuronal ainda não tem a capacidade para identificar as características mais subtis que as falhas criam.

Devido ao facto anterior, para a seguinte iteração do método foi escolhido o treino da rede neuronal com imagens retiradas a partir da análise tempo-frequência dos dados iniciais.

4.4.2. Transformada de *Stockwell*

Devido aos fracos resultados nas etapas de validação e teste com imagens obtidas através da conversão de imagens a partir de dados no domínio do tempo e com a intenção de aumentar esses resultados é proposto o treino da rede neuronal com imagens depois de aplicada uma transformação para o domínio tempo-frequência aos sinais.

Neste caso, o método de processamento de sinal utilizado foi a *S-Transform*, que permite obter um histograma com a banda de frequências de interesse ao longo do tempo e dividir esse histograma em várias imagens.

Para mitigar a presença do harmónico à frequência fundamental da máquina, com alta amplitude e a baixas frequências, foi aplicada à soma das tensões diferenciais um filtro passa-alto *Buttleworth* de 3ª ordem, com uma frequência de corte de 125 Hz.

De modo a que a aplicação da *S-Transform* à soma das tensões diferenciais não requiera tanto poder computacional e seja de execução mais rápida, foi realizada uma subamostragem do sinal. Na subamostragem, à soma das tensões induzidas diferenciais é recolhido um valor do sinal a cada quatro valores, alterando a frequência de amostragem de 20 kHz para 5 kHz. Esta alteração não afetará os resultados pois só elimina as componentes harmónicas de frequência acima dos 2500 Hz, muito acima da gama de interesse de frequências onde se localizam as falhas.

Podemos observar dois histogramas das tensões diferenciais depois de aplicada uma *S-Transform* na Figura 25 do capítulo 3, com o sinal original na imagem a) e depois de aplicado ao sinal original um filtro passa-alto *Buttlerworth* de 3ª ordem na imagem b).

As imagens recolhidas dos histogramas resultantes da aplicação de uma *S-Tranform* são convertidas em imagens de tamanho 32x32 px e 64x64 px, deste modo garantindo que o tempo de treino não seja excessivamente longo. Estas imagens resultam da divisão dos vários histogramas

originais em várias imagens, onde em cada uma destas está representado pelo menos uma volta e meia do veio do motor. A variação nos tamanhos, ao contrário das imagens nos pontos anteriores, não varia o número de valores do sinal original que estão presentes em cada imagem, tendo como única diferença uma maior ou menor definição. As imagens resultantes desta iteração estão representadas na Tabela 12.

Tabela 12 – Imagens obtidas depois de aplicada uma S-Transform.

Situação	Condição de Carga					
	Desacoplado	0%	25%	50%	75%	100%
Anel Externo 2mm						
Anel Externo 4mm						
Anel Interno 2mm						
Anel Interno 4mm						
Esferas						
Estiramento Generalizado						
Saudável						

Tabela 13 – Conjuntos de dados para os diferentes casos de treino realizados nesta iteração do método de diagnóstico.

Caso de Treino	Conjunto de Dados de Treino e Validação	Tamanho (px)	N° de Imagens		Conjunto de dados de Teste	N° de Imagens
			Treino	Validação		
1	Todas as cagas de um teste	16x16	2177	546	Todas as cagas de um teste	301
		32x32				
2	Aumento do conjunto de dados com os outros dois testes	64x64	6531	1631	Aumento do conjunto de dados com os outros dois testes	910
3	Aumento do conjunto de dados com sobreposição de imagens	64x64	21770	5446	Aumento do conjunto de dados com sobreposição de imagens	3024
4	Vazio-50%-100%	64x64	12096	3024	25%-75%	1008
5	Vazio-25%-75%-100%	64x64	16120	4032	50%	504

Os conjuntos de dados resultantes da aplicação de uma *S-Transform* às tensões induzidas diferenciais, com tamanho 32x32 px e 64x64 px, têm o mesmo número de imagens. Assim sendo as bases de dados são compostas por 72 imagens por situação de carga e por cada condição de funcionamento do motor, resultando num total de 3024 imagens. Do total de imagens disponíveis 2177 imagens são para treino, 546 imagens para validação durante o treino e 301 imagens para o teste.

O processo de treino da CNN com imagens resultantes da aplicação de uma *S-Transform* iniciou-se com imagens de tamanho 32x32 px.

Analogamente às situações anteriores, foi efetuado o treino 10 vezes com as mesmas opções de treino, sendo a média dos resultados de validação final de **90,31%** e a de teste com as mesmas redes de **89,67%**. No que concerne ao tempo de treino das redes atingiu-se uma média de **1 minuto e 32 segundos**. A Figura 36 apresenta o gráfico de treino, validação e de perdas, e ainda a matriz de confusão para o conjunto de dados de tamanho 32x32 px.

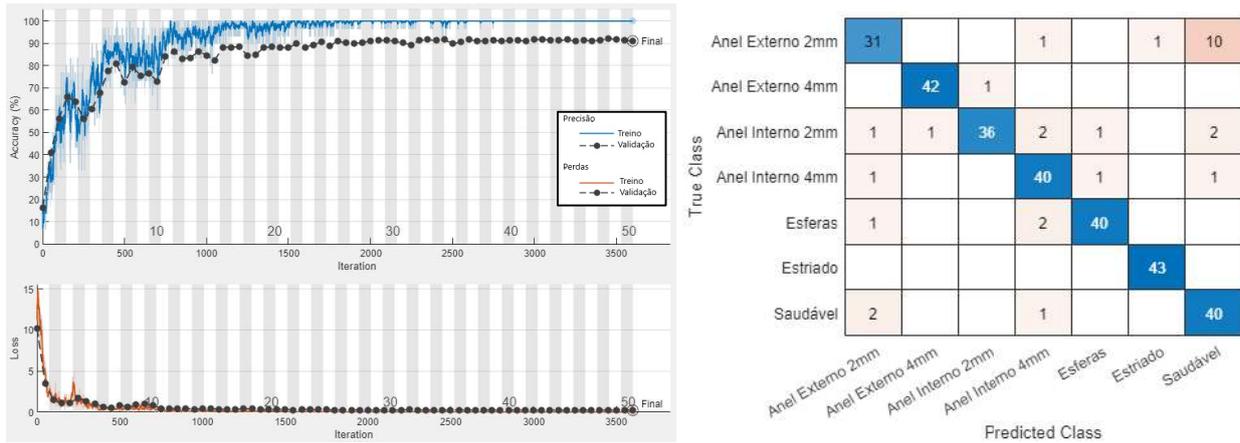


Figura 36 – Gráficos de treino, validação e função de perdas durante o treino da rede neuronal e matriz de confusão das imagens de teste com o conjunto de dados onde é aplicada uma S-Transform 32x32 px.

Posteriormente, o treino da rede neuronal prosseguiu com o conjunto de dados com imagens de dimensão 64x64 px. Para este caso, a média dos resultados de validação final foi de **94,08%** e a de teste foi de **94,05%**. Quanto ao tempo de treino das redes obteve-se uma média de **2 minutos**. De referir que estes resultados são obtidos depois de realizados 10 treinos. A Figura 37 ilustra o gráfico de treino, validação e de perdas, e ainda uma matriz de confusão para conjunto de dados de tamanho 64x64 px.

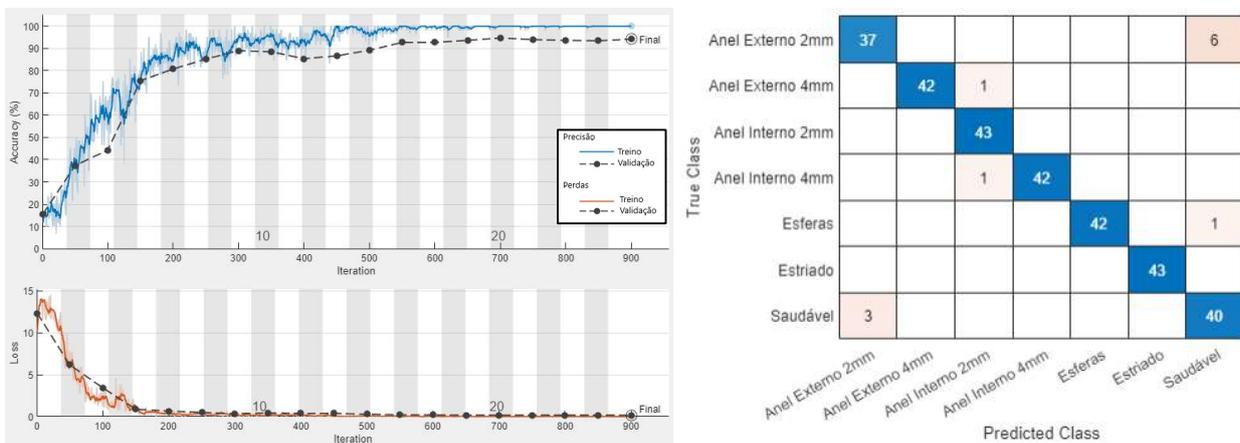


Figura 37 – Gráficos de treino, validação e função de perdas durante o treino da rede neuronal e matriz de confusão das imagens de teste com o conjunto de dados onde é aplicada uma S-Transform 64x64 px.

Como podemos verificar nas duas situações de treino acima descritas, tanto com um conjunto de dados com imagens 32x32 px como com imagens 64x64 px, os resultados das taxas de validação e posterior teste são satisfatórios, pois a rede é capaz de identificar corretamente a grande maioria das imagens de teste.

Através do aumento da base dados, tanto com a introdução de novos ensaios como com a sobreposição de imagens é possível alcançar resultados de classificação corretas, quer de teste quer de validação, mais próximos do ideal.

Para a fase de treino da CNN com aumento de dados, fez-se uso do conjunto de dados com imagens de tamanho 64x64 px, devido às suas taxas de validação e teste mais elevadas, sem que o tempo de treino seja proibitivo.

Para o caso de treino 2, onde é efetuado o aumento do conjunto de dados por via da adição dos restantes dois ensaios, retirados nas mesmas condições de funcionamento do motor, o conjunto de dados é composto por 216 imagens por nível de carga e por cada situação de funcionamento do motor, tendo no total 9072 imagens. Das 9072 imagens 6531 foram utilizadas para treino, 1631 para validação ao longo do treino e 910 para teste depois de exportada a rede treinada.

Após efetuado o treino por 10 vezes como convencionado, a média dos resultados obtidos foi de **97,51%** e de **97,12%**, para validação e para teste, respetivamente. Verifica-se um aumento no tempo de treino, relativamente ao caso de treino anterior, para um total de **5 minutos**. Sendo que na Figura 38 está representado o gráfico de treino, validação e de perdas, e ainda uma matriz de confusão para o conjunto de dados com a adição dos dois ensaios.

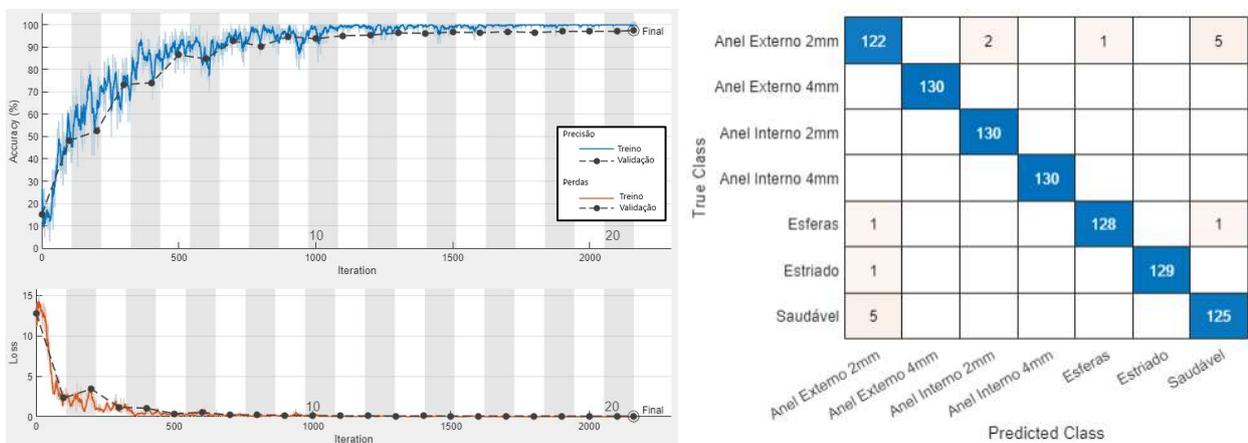


Figura 38 – Gráficos de treino, validação e função de perdas durante o treino da rede neuronal e matriz de confusão das imagens de teste com o conjunto de dados onde é aplicada uma S-Transform 64x64 px com a adição de dois ensaios.

Para o terceiro caso de treino o conjunto de dados anterior foi novamente aumentado, sobrepondo na imagem seguinte uma parte da imagem anterior. Este acréscimo conduziu a um aumento de 216 para 720 imagens por situação de carga e por cada condição de funcionamento do motor, ou seja, 240 por cada ensaio. Ao realizar-se esta sobreposição cerca de 80% da imagem

anterior está na imagem seguinte. O conjunto de dados final tem um total de 30240 imagens, onde 21770 são imagens para treino, 5446 para a validação da rede durante o treino e 3024 para teste depois de extraída a CNN treinada.

Como era expectável o tempo de treino desta CNN sofreu um aumento considerável, sendo a sua média de **14 minutos e 36 segundos**. No entanto, este aumento no tempo de treino conduziu a classificações muito próximas do máximo, com a média de resultados de validação e teste a atingir, respetivamente, **99,73%** e **99,71%**. Sendo que na Figura 39 está ilustrado o gráfico de treino, validação e de perdas, e ainda uma matriz de confusão para o conjunto de dados.

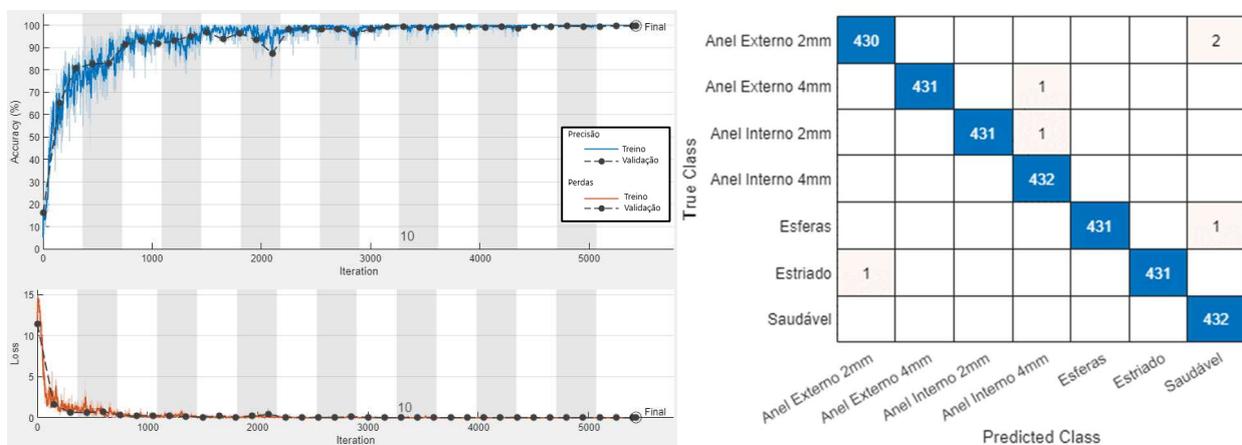


Figura 39 – Gráficos de treino, validação e função de perdas durante o treino da rede neuronal e matriz de confusão das imagens de teste com o conjunto de dados onde é aplicada uma S-Transform 64x64 px com aumento de dados por sobreposição de imagens.

Os resultados com estes casos de treinos são muito satisfatórios, uma vez que a CNN consegue classificar quase plenamente as imagens de validação e teste corretamente. O aumento do conjunto de dados, primeiro com a adição de novos ensaios e depois com a sobreposição de imagens, embora leve a tempos de treino mais elevados, permite atingir taxas de classificação muito elevadas, cerca de 99,7%.

Para testar a robustez do método de diagnóstico, foi proposto nos casos de treino 4 e 5 a transferência de conhecimento. Quer isto dizer que, o treino e validação da CNN foram efetuados com um conjunto de dados com certos níveis de carga e o teste realizado com diferentes níveis de carga aos utilizados no treino.

No primeiro caso onde se efetua o teste com cargas desconhecidas, designado por caso de treino 4, efetuou-se o treino e validação da rede neuronal com o conjunto de dados do caso de treino 3, mas apenas com os níveis de carga em vazio, 50% e 100% da carga nominal.

Relativamente ao teste, o mesmo foi efetuado com o conjunto de dados do caso de treino 1, mas apenas com os níveis de carga 25% e 75% da carga nominal.

O conjunto de dados de treino e validação é composta, respetivamente, por 12096 e 3024 imagens, totalizando 15120 imagens, quanto ao conjunto de dados de teste, a mesma é composta por 144 imagens por situação de funcionamento, num total de 1008 imagens.

Nesse sentido foi possível verificar que os resultados de treino e validação foram os expetáveis, com uma média de **99,85%**, em tudo similares ao caso de treino anterior, apresentando um tempo de treino médio de **7 minutos**. Contudo, no que diz respeito ao teste com 25% e 75% da carga nominal, apenas foi possível classificar corretamente **17,96%** das imagens. Na Figura 40 está apresentado o gráfico de treino, validação e de perdas, e ainda uma matriz de confusão para o conjunto de dados de teste do caso 4.

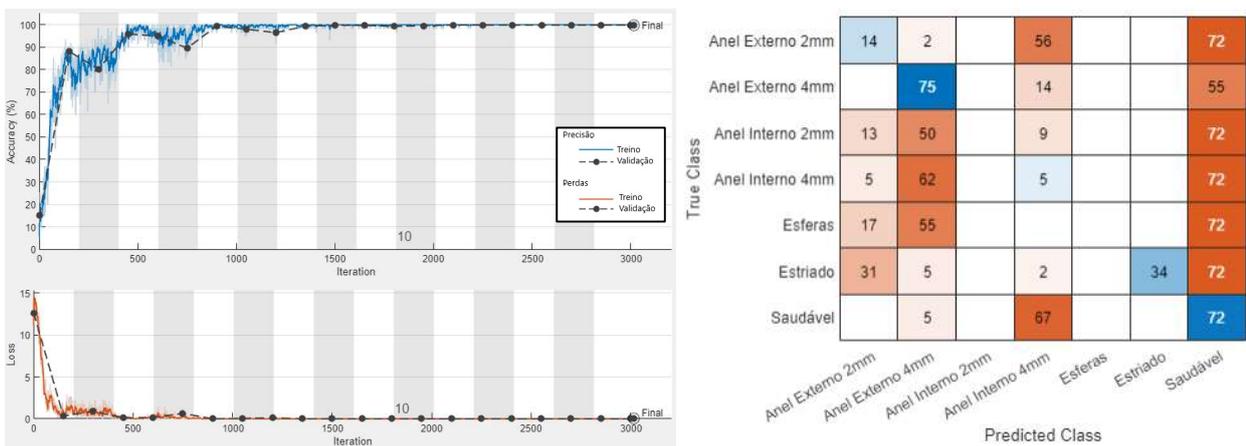


Figura 40 – Gráficos de treino, validação e função de perdas durante o treino da rede neuronal com o conjunto de dados com o motor em funcionamento em vazio, a 50% e 100% da carga nominal e matriz de confusão das imagens de teste com o conjunto de dados com o motor em funcionamento a 25% e 75% da carga nominal.

Para o quinto e último caso de treino, onde a rede foi testada com cargas desconhecidas, embora neste caso só a um nível de carga central. Em suma, treino e validação da CNN com as cargas em vazio, a 25%, 75% e a 100% da carga nominal e teste da mesma com o motor a funcionar a 50% da carga nominal.

O grupo de imagens para treino e validação é formado respetivamente por 16120 e 4032 imagens, contabilizando um total de 20152 imagens. Relativamente ao conjunto de dados de teste a mesma é composta por 72 imagens por cada situação de funcionamento do motor, para um total de 504 imagens.

Realizado o treino da CNN, é possível verificar que os resultados de validação são idênticos aos dois casos de treino anteriores, com uma média de **99,83%**, e um tempo de treino médio de **10 minutos**. Por outro lado os resultados de teste obtidos são de **35,38%**. Encontra-se presente na Figura 41 o gráfico de treino, validação e de perdas, e ainda uma matriz de confusão para o presente conjunto de dados do caso 5.

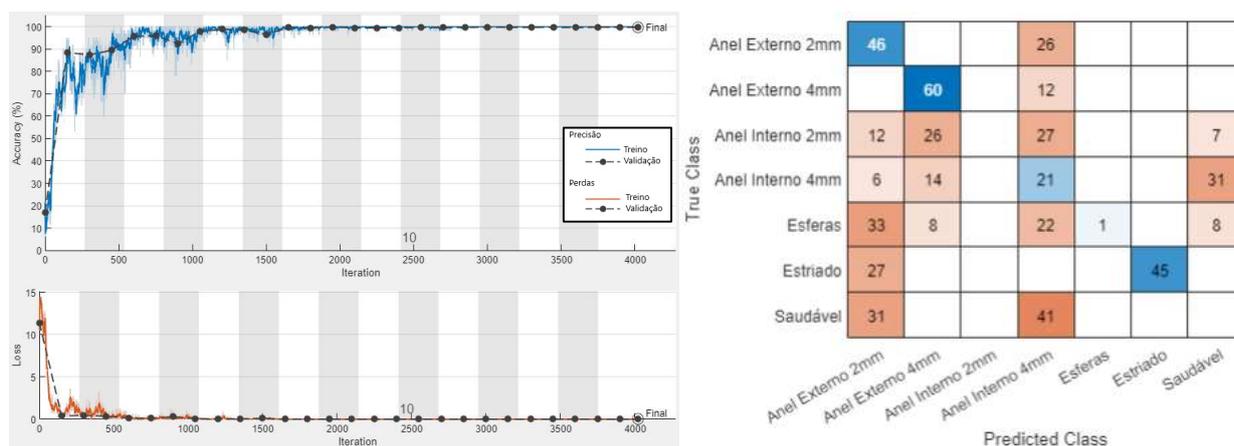


Figura 41 – Gráficos de treino, validação e função de perdas durante o treino da rede neuronal com o conjunto de dados com o motor em funcionamento em vazio, a 25%, 75% e 100% da carga nominal e a matriz de confusão das imagens de teste com o conjunto de dados com o motor em funcionamento a 50% da carga nominal.

Os resultados dos casos de treino 4 e 5, levam a concluir que ao não ser presenciada com os harmónicos característicos de cada falha nos diferentes níveis de carga onde posteriormente é testada, a CNN demonstra grande incapacidade na identificação das falhas em níveis de carga desconhecidos.

Podemos ainda verificar que muitas vezes cargas baixas são confundidas com a situação saudável de funcionamento ou cargas mais elevadas confundidas com situações de funcionamento onde a falha é mais severa. Deste modo verifica-se que não ocorre a tão desejada transferência de conhecimento onde as taxas de teste ficam muito aquém do pretendido.

5. Conclusão e Trabalho Futuro

5.1. Conclusão

O trabalho apresentado nesta dissertação incidiu sobre a aplicação de um algoritmo de inteligência artificial, neste caso uma Rede Neuronal de Convolução, no diagnóstico de falhas em rolamentos de motores de indução. Este diagnóstico é efetuado através da aprendizagem das características adjacentes a cada falha por parte da rede. As características estão presentes nas tensões induzidas diferenciais, recolhidas através de bobinas de teste instaladas no estator do motor, que por sua vez são transformadas num conjunto de dados de imagens. Neste sentido, a técnica de diagnóstico desenvolvida distingue-se das anteriores pela capacidade de deteção de falhas sem que lhe seja transmitida qualquer informação sobre as mesmas.

As falhas analisadas nos rolamentos (falhas nos anéis interno e externo, esferas e estriamento generalizado) ilustram de forma controlada as falhas que ocorrem com mais frequência em ambiente industrial.

A análise de FFTs, aplicadas a sinais com falhas sobrepostas com a do sinal com o motor em funcionamento saudável, leva à conclusão de que as mesmas se manifestam com maior intensidade na gama das médias frequências, mais propriamente entre os 100 Hz e os 700 Hz. Paralelamente foi também feita a análise comparativa entre as tensões induzidas diferenciais simples e a resultante da soma das três. A análise anterior conduziu à escolha da resultante da soma como sinal a transformar em imagens, devido à maior amplitude das componentes harmónicas para cargas mais elevadas.

Primeiramente, a rede neuronal foi treinada e testada com um conjunto de dados de imagens em escala de cinzentos, transformadas diretamente dos sinais no domínio do tempo, sem receberem qualquer tipo de processamento de sinal. Do treino e teste foram obtidas taxas de validação e teste muito aquém do pretendido, com as principais características de cada falha a não serem adquiridas pela rede.

De seguida, aplicou-se ao sinal resultante da soma das tensões diferenciais induzidas uma DWT de nível 3. Esta transformada permitiu isolar as componentes harmónicas mais baixas do sinal original, abaixo dos 1250Hz. Embora os resultados de validação e teste apresentem uma ligeira melhoria, estes ficaram ainda muito aquém do pretendido, uma vez que apenas alcançaram uma média de 20,58% de classificações corretas.

Por último, foi aplicada uma *S-Transform* aos sinais, o resultado dessa aplicação foi transformado em duas bases de dados, uma de imagens de tamanho 32x32 px e outra com tamanho 64x64 px, diferindo apenas na definição da imagem apresentada à CNN. O treino da rede com estas duas bases de dados resultou em taxas de validação e teste muito perto do pretendido, com a primeira a rondar os 90% e a segunda os 94%. O tempo de treino médio foi respetivamente, 1 minuto e 30 segundos e 2 minutos.

Foi decidido a progressão do método de diagnóstico com o conjunto de dados com imagens de tamanho 64x64 px, devido à obtenção de melhores resultados sem um aumento acentuado de tempo de treino. Essa progressão foi efetuada com a junção de mais 2 ensaios retirados nas mesmas condições de funcionamento, com resultados de validação e teste acima dos 97% e um tempo médio de treino de 5 minutos. Posteriormente optou-se ainda pela adição de imagens obtidas a partir da sobreposição de imagens onde 80% da imagem anterior está presente na seguinte. O treino com o último conjunto de dados deu origem a resultados muito próximos da totalidade de imagens classificadas corretamente, com classificações médias de 99,7% e um tempo de treino de 14 minutos e 30 segundos. Deste modo foi alcançado um dos objetivos da dissertação, a criação de um método de diagnóstico eficaz, baseado em inteligência artificial, para detetar falhas em rolamentos.

Com a obtenção de taxas de acerto muito elevadas com o presente método de diagnóstico, o passo seguinte foi aplicar a rede a cargas desconhecidas, isto é, o treino da rede com um determinado conjunto de cargas e o teste noutras. No primeiro caso de treino deste tipo, a CNN foi treinada com um conjunto de dados com o motor a funcionar em vazio, 50% e 100% de carga e testada as cargas de 25% e 75%, obtendo-se um resultado de validação de 99,85% e de teste de 17,96%. No segundo caso deste tipo, é efetuado o treino da rede com um conjunto de dados com o motor a funcionar em vazio, 25%, 75% e 100% da carga e testado numa só com 50% de carga, obtendo uma taxa de validação de 99,83% e de teste de 35,38%.

Os resultados atingidos com a aplicação da rede a cargas desconhecidas ficaram muito aquém do pretendido, o que leva a concluir que os harmónicos característicos de cada falha presentes na soma de tensões induzidas diferenciais, variam grandemente com a condição de carga a que o motor está a operar. Tal facto torna infelizmente difícil a implementação deste método de diagnóstico em ambiente industrial devido ao valor infinito de cargas a que o motor pode estar a operar.

5.2. Trabalho Futuro

O método de diagnóstico foi comprovado para condições de carga que são conhecidas pela CNN, de modo que um aperfeiçoamento desta, quer por via de um melhor ajuste de pesos ou mesmo da sua composição, quer com a fusão com outros algoritmos poderão levar a uma transferência de conhecimento eficaz, como demonstrado com outras bases de dados. Não obstante, seria pertinente/útil a implementação de outros métodos de processamento de sinal com vista à obtenção de imagens diferentes onde os harmônicos característicos de cada falha possam estar mais visíveis.

Juntamente com os dados utilizados nesta dissertação foram complementarmente realizados ensaios onde o motor era alimentado por um conversor de frequência. Considera-se que seria extremamente interessante alargar o método de diagnóstico desenvolvido ao motor alimentado a diferentes frequências.

Seria igualmente desafiador efetuar a aplicação deste método a outras falhas elétricas e/ou mecânicas, tanto no rotor como no estator. Podendo para esse fim serem utilizadas as mesmas ou outras grandezas adquiridas da máquina. Em última instância, poder-se-ia inclusivamente realizar a extensão deste método a máquinas elétricas de diferentes tipos, tais como máquinas de ímanes permanentes, atualmente muito utilizadas na tração automóvel.

Bibliografia

1. Liang, X., M.Z. Ali, and H. Zhang, *Induction Motors Fault Diagnosis Using Finite Element Method: A Review*. IEEE Transactions on Industry Applications, 2020. **56**(2): p. 1205-1217.
2. Blodt, M., et al., *Models for Bearing Damage Detection in Induction Motors Using Stator Current Monitoring*. IEEE Transactions on Industrial Electronics, 2008. **55**(4): p. 1813-1822.
3. *Report of Large Motor Reliability Survey of Industrial and Commercial Installations, Part I*. IEEE Transactions on Industry Applications, 1985. **IA-21**(4): p. 853-864.
4. *Report of Large Motor Reliability Survey of Industrial and Commercial Installations, Part II*. IEEE Transactions on Industry Applications, 1985. **IA-21**(4): p. 865-872.
5. *Report of Large Motor Reliability Survey of Industrial and Commercial Installations: Part 3*. IEEE Transactions on Industry Applications, 1987. **IA-23**(1): p. 153-158.
6. Nandi, S., H.A. Toliyat, and X. Li, *Condition Monitoring and Fault Diagnosis of Electrical Motors—A Review*. IEEE Transactions on Energy Conversion, 2005. **20**(4): p. 719-729.
7. Zhang, P., et al., *A Survey of Condition Monitoring and Protection Methods for Medium-Voltage Induction Motors*. IEEE Transactions on Industry Applications, 2011. **47**(1): p. 34-46.
8. Zhang, S., et al., *Deep Learning Algorithms for Bearing Fault Diagnostics—A Comprehensive Review*. IEEE Access, 2020. **8**: p. 29857-29881.
9. Neupane, D. and J. Seok, *Bearing Fault Detection and Diagnosis Using Case Western Reserve University Dataset With Deep Learning Approaches: A Review*. IEEE Access, 2020. **8**: p. 93155-93178.
10. Cavaleiro, P.M.L.R.F., *Tensões Induzidas Diferenciais para o Diagnóstico de Avarias em Rolamentos de Motores de Indução Trifásicos*, in DEEC. 2020, Universidade de Coimbra.
11. Dehghan, H., F. Haghjoo, and S.M.A. Cruz, *A Flux-Based Differential Technique for Turn-to-Turn Fault Detection and Defective Region Identification in Line-Connected and Inverter-Fed Induction Motors*. IEEE Transactions on Energy Conversion, 2018. **33**(4): p. 1876-1885.
12. Soleimani, Y., S.M.A. Cruz, and F. Haghjoo, *Broken Rotor Bar Detection in Induction Motors Based on Air-Gap Rotational Magnetic Field Measurement*. IEEE Transactions on Instrumentation and Measurement, 2019. **68**(8): p. 2916-2925.
13. Maciejewski, N.A.R., A.E. Treml, and R.A. Flauzino. *A Systematic Review of Fault Detection and Diagnosis Methods for Induction Motors*. in 2020 FORTEI-International Conference on Electrical Engineering (FORTEI-ICEE). 2020.
14. Kumar, S., et al., *A Comprehensive Review of Condition Based Prognostic Maintenance (CBPM) for Induction Motor*. IEEE Access, 2019. **7**: p. 90690-90704.
15. Albrecht, P.F., et al., *Assessment of the Reliability of Motors in Utility Applications - Updated*. IEEE Transactions on Energy Conversion, 1986. **EC-1**(1): p. 39-46.
16. Önel, I.Y. and M.E.H. Benbouzid, *Induction Motor Bearing Failure Detection and Diagnosis: Park and Concordia Transform Approaches Comparative Study*. IEEE/ASME Transactions on Mechatronics, 2008. **13**(2): p. 257-262.
17. Agostinho, J.A.C., *DIAGNÓSTICO DE AVARIAS NOS ROLAMENTOS DE UM MOTOR DE INDUÇÃO TRIFÁSICO*, in DEEC. 2013, Universidade de Coimbra.
18. Faiz, J., B.M. Ebrahimi, and M.B.B. Sharifian, *Finite Element Transient Analysis of an On-Load Three-Phase Squirrel-Cage Induction Motor with Static Eccentricity*. Electromagnetics, 2007. **27**(4): p. 207-227.
19. Faiz, J., et al., *Comprehensive Eccentricity Fault Diagnosis in Induction Motors Using Finite Element Method*. IEEE Transactions on Magnetics, 2009. **45**(3): p. 1764-1767.
20. Rezig, A., M.R. Mekideche, and A. Djerdir, *EFFECT OF ROTOR ECCENTRICITY FAULTS ON NOISE GENERATION IN PERMANENT MAGNET SYNCHRONOUS MOTORS*. Progress In Electromagnetics Research C, 2010. **15**: p. 117-132.
21. Zhan, H., et al. *Detecting Eccentricity Fault in Dual Three-Phase Permanent Magnet Machines by Means of Zero-Sequence Voltage Component*. IEEE.
22. Dash, R.N., et al. *Condition monitoring of induction motors: — A review*. IEEE.

23. Immovilli, F., et al., *Diagnosis of Bearing Faults in Induction Machines by Vibration or Current Signals: A Critical Comparison*. IEEE Transactions on Industry Applications, 2010. **46**(4): p. 1350-1359.
24. Zhou, W., T.G. Habetler, and R.G. Harley. *Bearing Condition Monitoring Methods for Electric Machines: A General Review*. IEEE.
25. Benbouzid, M.E.H., M. Vieira, and C. Theys, *Induction Motors' Faults Detection and Localization Using Stator Current Advanced Signal Processing Techniques*. IEEE Transactions on Power Electronics, 1999. **14**(1): p. 14-22.
26. Yazidi, A., H. Henao, and G.A. Capolino. *Broken Rotor Bars Fault Detection in Squirrel Cage Induction Machines*. IEEE.
27. Bacha, K., et al., *Induction Machine Fault Detection Using Stray Flux EMF Measurement and Neural Network-Based Decision*. Electric Power Systems Research, 2008. **78**(7): p. 1247-1255.
28. Ceban, A., R. Pusca, and R. Romary, *Study of Rotor Faults in Induction Motors Using External Magnetic Field Analysis*. IEEE Transactions on Industrial Electronics, 2012. **59**(5): p. 2082-2093.
29. Cabanas, M.F., et al., *Unambiguous Detection of Broken Bars in Asynchronous Motors by Means of a Flux Measurement-Based Procedure*. IEEE Transactions on Instrumentation and Measurement, 2011. **60**(3): p. 891-899.
30. Mirzaeva, G., K.I. Saad, and M.G. Jahromi, *Comprehensive Diagnostics of Induction Motor Faults Based on Measurement of Space and Time Dependencies of Air Gap Flux*. IEEE Transactions on Industry Applications, 2017. **53**(3): p. 2657-2666.
31. Maru, B. and P.A. Zotos, *Anti-Friction Bearing Temperature Rise for NEMA Frame Motors*. IEEE Transactions on Industry Applications, 1989. **25**(5): p. 883-888.
32. Henao-Sepulveda, J.A., M. Toledo-Quinones, and Y. Jia. *Contactless Monitoring of Ball Bearing Temperature*. IEEE.
33. Hawman, M.W. and W.S. Galinaitis. *Acoustic Emission Monitoring of Rolling Element Bearings*. IEEE.
34. Heng, R.B.W. and M.J.M. Nor, *Statistical Analysis of Sound and Vibration Signals for Monitoring Rolling Element Bearing Condition*. Applied Acoustics, 1998. **53**(1-3): p. 211-226.
35. Yimin, S. and F. Nezu. *Bearing Fault Detection Using Laser Displacement Sensor*. IEEE.
36. Toliyat, H.A., et al. *Electric Machines: Modeling, Condition Monitoring, and Fault Diagnosis*. 2012.
37. Konar, P. and P. Chattopadhyay, *Multi-Class Fault Diagnosis of Induction Motor Using Hilbert And Wavelet Transform*. Applied Soft Computing, 2015. **30**: p. 341-352.
38. Puche-Panadero, R., et al., *Improved Resolution of the MCSA Method Via Hilbert Transform, Enabling the Diagnosis of Rotor Asymmetries at Very Low Slip*. IEEE Transactions on Energy Conversion, 2009. **24**(1): p. 52-59.
39. Kaffanke, J., et al., *Application of the Chirp z-Transform to MRI Data*. Journal of Magnetic Resonance, 2006. **178**(1): p. 121-128.
40. Gonçalves, M.J.M., *Técnicas Avançadas de Processamento de Sinal no Diagnóstico de Avarias em Rolamentos de Motores de Indução Trifásicos*, in DEEC. 2015, Universidade de Coimbra: DEEC.
41. Henríquez Rodríguez, P., et al., *Application of the Teager–Kaiser Energy Operator in Bearing Fault Diagnosis*. ISA Transactions, 2013. **52**(2): p. 278-284.
42. Bediaga, I., et al., *Ball Bearing Damage Detection Using Traditional Signal Processing Algorithms*. IEEE Instrumentation & Measurement Magazine, 2013. **16**(2): p. 20-25.
43. Wang, H. and P. Chen, *Fuzzy Diagnosis Method for Rotating Machinery in Variable Rotating Speed*. IEEE Sensors Journal, 2011. **11**(1): p. 23-34.
44. Cocconcelli, M., et al. *STFT Based Approach for Ball Bearing Fault Detection in a Varying Speed Motor*. in *Condition Monitoring of Machinery in Non-Stationary Operations*. 2012. Berlin, Heidelberg: Springer Berlin Heidelberg.
45. Seker, S. and E. Ayaz, *A Study of Condition Monitoring for Induction Motors Under Accelerated Aging Process*. IEEE Power Engineering Review, 2002. **22**: p. 35-37.
46. Baydar, N. and A. Ball, *A Comparative Study of Acoustic and Vibration Signals in Detection of Gear Failures Using Wigner–Ville Distribution*. Mechanical Systems and Signal Processing, 2001. **15**(6): p. 1091-1107.

47. Soualhi, A., K. Medjaher, and N. Zerhouni, *Bearing Health Monitoring Based on Hilbert–Huang Transform, Support Vector Machine, and Regression*. IEEE Transactions on Instrumentation and Measurement, 2015. **64**(1): p. 52-62.
48. Gao, Z., C. Cecati, and S.X. Ding, *A Survey of Fault Diagnosis and Fault-Tolerant Techniques—Part I: Fault Diagnosis With Model-Based and Signal-Based Approaches*. IEEE Transactions on Industrial Electronics, 2015. **62**(6): p. 3757-3767.
49. Hamadache, M. and D. Lee. *Absolute Value Principal Components Analysis (AVPCA) and Parameter Estimation (PE) to Bearing Fault Detection Using Rotor Speed Signal Monitoring — A comparative study*. IEEE.
50. Intel. *Software Development AI Courses*. Available from: <https://software.intel.com/content/www/us/en/develop/topics/ai/training/courses.html>.
51. Almounajjed, A., et al. *Investigation Techniques for Rolling Bearing Fault Diagnosis Using Machine Learning Algorithms*. IEEE.
52. Fiipetti, F. and P. Vas. *Recent Developments of Induction Motor Drives Fault Diagnosis Using AI Techniques*. IEEE.
53. Awadallah, M.A. and M.M. Morcos, *Application of AI Tools in Fault Diagnosis of Electrical Machines and Drives - An Overview*. IEEE Transactions on Energy Conversion, 2003. **18**(2): p. 245-251.
54. Xu, G., et al., *Bearing Fault Diagnosis Method Based on Deep Convolutional Neural Network and Random Forest Ensemble Learning*. Sensors, 2019. **19**(5): p. 1088.
55. Rojas, A. and A.K. Nandi. *Detection and Classification of Rolling-Element Bearing Faults using Support Vector Machines*. IEEE.
56. Jia, F., et al., *Deep Neural Networks: A Promising Tool for Fault Characteristic Mining and Intelligent Diagnosis of Rotating Machinery with Massive Data*. Mechanical Systems and Signal Processing, 2016. **72-73**: p. 303-315.
57. Mao, W., et al., *Imbalanced Fault Diagnosis of Rolling Bearing Based on Generative Adversarial Network: A Comparative Study*. IEEE Access, 2019. **7**: p. 9515-9530.
58. CWRU. *Case Western Reserve University (CWRU) Bearing Data Center*. Dec. 2018; Available from: <https://csegroups.case.edu/bearingdatacenter/pages/welcome-case-western-reserve-universitybearing-data-center-website>.
59. Guo, L., et al., *Deep Convolutional Transfer Learning Network: A New Method for Intelligent Fault Diagnosis of Machines With Unlabeled Data*. IEEE Transactions on Industrial Electronics, 2019. **66**(9): p. 7316-7325.
60. Zhang, W., et al., *A New Deep Learning Model for Fault Diagnosis with Good Anti-Noise and Domain Adaptation Ability on Raw Vibration Signals*. Sensors, 2017. **17**(2): p. 425.
61. Janssens, O., et al., *Convolutional Neural Network Based Fault Detection for Rotating Machinery*. Journal of Sound and Vibration, 2016. **377**: p. 331-345.
62. Lu, C., Z. Wang, and B. Zhou, *Intelligent Fault Diagnosis of Rolling Bearing Using Hierarchical Convolutional Network Based Health State Classification*. Advanced Engineering Informatics, 2017. **32**: p. 139-151.
63. Xia, M., et al., *Fault Diagnosis for Rotating Machinery Using Multiple Sensors and Convolutional Neural Networks*. IEEE/ASME Transactions on Mechatronics, 2018. **23**(1): p. 101-110.
64. Zhang, W., et al., *Fault State Recognition of Rolling Bearing Based Fully Convolutional Network*. Computing in Science & Engineering, 2019. **21**(5): p. 55-63.
65. Zhang, W., et al., *A Deep Convolutional Neural Network with New Training Methods for Bearing Fault Diagnosis under Noisy Environment And Different Working Load*. Mechanical Systems and Signal Processing, 2018. **100**: p. 439-453.
66. Li, S., et al., *An Ensemble Deep Convolutional Neural Network Model with Improved D-S Evidence Fusion for Bearing Fault Diagnosis*. Sensors, 2017. **17**(8): p. 1729.
67. Guo, S., et al., *An Intelligent Fault Diagnosis Method for Bearings with Variable Rotating Speed Based on Pythagorean Spatial Pyramid Pooling CNN*. Sensors, 2018. **18**(11): p. 3857.
68. Qian, W., et al., *An Intelligent Fault Diagnosis Framework for Raw Vibration Signals: Adaptive Overlapping Convolutional Neural Network*. Measurement Science and Technology, 2018. **29**(9): p. 095009.

69. Pan, J., et al., *LiftingNet: A Novel Deep Learning Network with Layerwise Feature Learning from Noisy Mechanical Data for Fault Classification*. IEEE Transactions on Industrial Electronics, 2018. **65**(6): p. 4973-4982.
70. Zilong, Z. and Q. Wei. *Intelligent Fault Diagnosis of Rolling Bearing Using One-Dimensional Multi-Scale Deep Convolutional Neural Network Based Health State Classification*. IEEE.
71. Wang, R., et al., *A Non-Contact Fault Diagnosis Method for Rolling Bearings Based on Acoustic Imaging and Convolutional Neural Networks*. IEEE Access, 2020. **8**: p. 132761-132774.
72. Wen, L., et al., *A New Convolutional Neural Network-Based Data-Driven Fault Diagnosis Method*. IEEE Transactions on Industrial Electronics, 2018. **65**(7): p. 5990-5998.
73. Lau, E.C.C. and H.W. Ngan, *Detection of Motor Bearing Outer Raceway Defect by Wavelet Packet Transformed Motor Current Signature Analysis*. IEEE Transactions on Instrumentation and Measurement, 2010. **59**(10): p. 2683-2690.
74. Cusido, J., et al., *Fault Detection in Induction Machines Using Power Spectral Density in Wavelet Decomposition*. IEEE Transactions on Industrial Electronics, 2008. **55**(2): p. 633-643.
75. Moukadem, A., et al., *A New Optimized Stockwell Transform Applied on Synthetic and Real Non-Stationary Signals*. Digital Signal Processing, 2015. **46**: p. 226-238.

Anexo I – Comparação entre Redes de Aprendizagem Profunda

Tabela 14 – Sumário de diferentes arquiteturas de aprendizagem profunda [1].

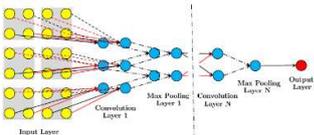
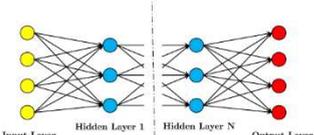
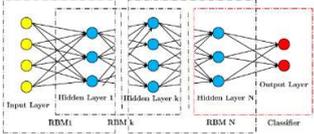
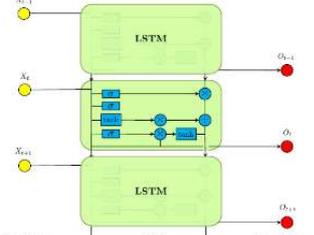
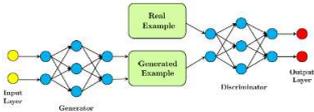
Arquitetura	Descrição	Características
	<p>Redes Neurais Convolucionais Preparada para imagens 2D, dados 1D temporal necessitam de ser processados em vetores 2-D. Aplicar o algoritmo “ReLU” depois das camadas de convolução ajudam a acelerar a velocidade de convergência. Várias variantes têm sido propostas: ADCNN [2], “LeNet-5”[3], “LiftingNet” [4, 5].</p>	<p>Prós: Requer menos conexões neuronais que uma ANN. Uma CNN clássica tem uma boa capacidade para lidar com o ruído. Contra: Pode necessitar de muitas camadas para encontrar uma hierarquia. Pode necessitar de uma ampla base de dados já classificada.</p>
	<p>Codificadores Automáticos Profundos Concebido extrair características ou redução da dimensão. Método de aprendizagem não supervisionado com o objetivo de reconstruir o vetor de entrada. Algumas das variantes propostas: SDA[6, 7], conjunto profundo de AE[8] e SAE – rede de conexão local[9].</p>	<p>Prós: Não requer uma base de dados já classificada. Algumas variantes aumentam a capacidade para lidar com o ruído e a robustez. Contra: Necessita de uma fase de pré treino. Durante o treino os erros podem desaparecer.</p>
	<p>Redes de Crença Profunda Composta por RNMs onde a camada oculta de cada sub-rede serve como camada visível da próxima Só tem conexões indiretas nas duas primeiras camadas Permitem o treino supervisionado e não supervisionado da rede</p>	<p>Prós: Propõe uma estratégia de aprendizagem camada a camada para inicializar a rede. Dedução maleável maximiza a probabilidade. Contra: O treino pode requerer muito poder computacional devido ao processo de inicialização e a etapa de amostragem.</p>
	<p>Redes Neurais Recorrentes É uma ANN capaz de analisar fluxos de dados 1D sequenciais ou temporais. LSTM fizeram com que a aplicação das RNNs reaparecesse. Eficaz em aplicações onde a saída depende de computações anteriores.</p>	<p>Prós: Memoriza eventos sequenciais. Capaz de modelar dependências temporais. Capaz de receber dados com comprimento variável. Contra: Erros na aprendizagem devido à ausência ou aumento exponencial do gradiente.</p>
	<p>Rede Generativa Adversária Composta por um gerador e um discriminador. Originalmente concebida para gerar imagem que imitassem fotos reais. Aplicado para o aumento da base de dados para aplicações onde temos escassez de dados. Utilizada na tarefa de classificação, normalmente de uma maneira semi supervisionada.</p>	<p>Prós: Requer poucas modificações quando transferida para novas aplicações. Não requer aproximações de Monte Carlo para o treino. Não introduz inclinações determinísticas. Contra: O treino de uma GAN é instável pois requer que encontremos o equilíbrio de “Nash”. Tem a dificuldade de aprender a gerar dados discretos, com por exemplo texto.</p>

Tabela 15 – Comparação da precisão da classificação com a base de dados da CWRU em diferentes algoritmos [1].

Ref.	Algoritmo	C.O.	Classif.	Características	%A.T.	P.M.%
[2]	Adaptive CNN	3	Softmax	Predição do tamanho da avaria	50%	97.90%
[10]	CNN	4	Softmax	Resistência ao ruído	90%	92.60%
[11]	CNN	4	Softmax	Fusão de sensores	70%	99.40%
[3]	CNN based on LeNet-5	8	Cm. FC	Melhor extração de características	83%	99.79%
[12]	Deep fully connected CNN	8	CTC	Validação com base de dados reais	78%	99.22%
[13]	Multi-scale deep CNN	9	Softmax	Tempo de treino reduzido	90%	98.57%
[14]	CNN com interface de treino	13	Softmax	Adaptação a mudanças de carga	96%	95.50%
[15]	IDS-CNN	3	Softmax	Adaptação a mudanças de carga	80%	98.92%
[5]	CNN – baseada em LiftingNet	6	Cm. FC	Adaptação a mudanças de velocidade	50%	99.63%
[4]	PSPP-CNN	9	Softmax	Adaptação a mudanças de velocidade	67%	99.19%
[16]	AOCNN com SF	4	Softmax	Reduz a percentagem de treino	5%	99.19%
[17]	SAE	3	ELM	Adaptação a mudanças de carga	50%	99.61%
[18]	SAE	3	ELM	Reduz o tempo de treino	50%	99.83%
[7]	Stacked denoising AE	3	N/A	Resistência ao ruído	50%	91.79%
[6]	SDAE	3	Softmax	Resistência ao ruído	80%	99.83%
[19]	Conjunto profundo de AE	3	Softmax	Melhor extração de características	67%	99.15%
[8]	AE de onda profunda	3	ELM	Reduz o tempo de treino	67%	95.20%
[9]	SAE – rede de conexão local	2	Softmax	Características invariantes ao deslocamento	25%	99.92%
[20]	SAE	3	SVM	Diagnostico Online	N/A	95.10%
[21]	Transf. complexa de árvore dupla	5	N/A	DBN adaptativa	67%	94.38%
[22]	DBN	2	Softmax	Adaptação a mudanças de carga	N/A	98.80%
[23]	DBN com aprendizagem em conjunto	4	Sigmoid	Precisa e robusta	N/A	96.95%
[24]	CNN-LSTM	3	Softmax	Precisão	83%	99.60%
[25]	RNN profunda (DRNN)	3	N/A	Precisão	60%	94.75%
[26]	DCGAN	8	SVM	Aumento artificial da base de dados	96%	86.33%
[27]	CatAAE	11	Softmax	Adaptação a mudanças de carga	91%	90.68%
[28]	A2CNN	27	Softmax	Adaptação de domínio	N/A	99.21%
[29]	GAN+SDAE	8	Softmax	Aumento artificial da base de dados	78%	99.20%

Anexo 2 – Componentes Harmônicas

Tabela 16 – Frequências características com maior amplitude.

Falha	Carga	Tempo(s)	Três ou Quatro Componentes Harmônicas com Maior Amplitude (Hz)			
			R	S	T	Soma
Anel Externo 4mm	0	1º e 2º	320,5/491/591	320,5/491/591	320,5/491/591	320,5/491/591
		1º	320/491/591	320/491/591	320/491/591	320/491/591
		2º	230/466/491/591	230/466/491/591	230/491/466/591	230/466/491/591
		3º	320/491/591	320/491/591	320/491/591	320/491/591
		4º	320/491/591	320/491/591	320/491/591	320/491/591
		5º	230/491/591	230/491/591	230/491/591	230/491/591
		Completo	320,4/490,8/591	320,4/490,8/591	320,4/490,8/591	320,4/490,8/591
	100	1º e 2º	213,5/131,5/576,5	213,5/131,5/576,5	213,5/131,5/576,5	213,5/576,5
		1º	330/355/530/555	330/355/530/555	330/355/530/555	330/355/530/555
		2º	330/355/455/530	330/355/455/530	330/355/455/530	330/355/455/530
		3º	330/530/655	330/530/655	330/530/655	330/530/655
		4º	330/530/655	330/530/655	330/530/655	330/530/655
		5º	355/530/655	330/530/655	330/430/655	330/530/655
		Completo	330,2/530,4/654,8	330,2/530,4/654,8	330,2/530,4/654,8	330,2/454,6/530,4
Anel Interno 4mm	0	1º e 2º	344,5/563,5/613,5	344,5/563,5/613,5	344,5/563,5/613,5	344,5/563,5/613,5
		1º	244/344/464	244/344/464	244/344/464	244/344/464
		2º	244/344/464	244/344/464	244/344/464	244/344/464
		3º	244/344/464	244/344/464	244/344/464	244/344/464
		4º	244/344/464	244/344/464	244/344/464	244/344/464
		5º	344/464/614	344/464/614	344/464/614	344/464/614
		Completo	344,2/478,8/613,6	344,2/478,8/613,6	344,2/478,8/613,6	244,2/344,2/563,5
	100	1 e 2			NA	
		1º			NA	
		2º			NA	
		3º			NA	
		4º			NA	
		5º			NA	

Legenda: Verde: Maior Amplitude. Amarelo: Amplitude Média Superior. Roxo: Amplitude Média Inferior. Vermelho: Menor Amplitude.

Anexo 3 – Características das Máquinas Elétricas Utilizadas na Montagem Laboratorial

Tabela 17 – Características do Motor de Indução Trifásico.

Marca	WEG
Tensão	400/690 V (Δ/Y)
Corrente Nominal	6.15/3.57 A (Δ/Y)
Frequência	50 Hz
Potência	3 kW
Nº de Polos	4
Velocidade Nominal	1440 rpm
Fator de Potência	0.8

Tabela 18 – Características da Máquina de Corrente Contínua.

Marca	AEG
Tensão	220V
Corrente Nominal	17A
Frequência	50Hz
Potência	3/4 kW (Motor/Gerador)
Velocidade Nominal	1450 rpm

Bibliografia Anexos

1. Zhang, S., et al., *Deep Learning Algorithms for Bearing Fault Diagnostics—A Comprehensive Review*. IEEE Access, 2020. **8**: p. 29857-29881.
2. Guo, X., L. Chen, and C. Shen, *Hierarchical Adaptive Deep Convolution Neural Network and its Application to Bearing Fault Diagnosis*. Measurement, 2016. **93**: p. 490-502.
3. Wen, L., et al., *A New Convolutional Neural Network-Based Data-Driven Fault Diagnosis Method*. IEEE Transactions on Industrial Electronics, 2018. **65**(7): p. 5990-5998.
4. Guo, S., et al., *An Intelligent Fault Diagnosis Method for Bearings with Variable Rotating Speed Based on Pythagorean Spatial Pyramid Pooling CNN*. Sensors, 2018. **18**(11): p. 3857.
5. Pan, J., et al., *LiftingNet: A Novel Deep Learning Network With Layerwise Feature Learning From Noisy Mechanical Data for Fault Classification*. IEEE Transactions on Industrial Electronics, 2018. **65**(6): p. 4973-4982.
6. Guo, X., C. Shen, and L. Chen, *Deep Fault Recognizer: An Integrated Model to Denoise and Extract Features for Fault Diagnosis in Rotating Machinery*. Applied Sciences, 2016. **7**(1): p. 41.
7. Lu, C., et al., *Fault Diagnosis of Rotary Machinery Components Using a Stacked Denoising Autoencoder-Based Health State Identification*. Signal Processing, 2017. **130**: p. 377-388.
8. Haidong, S., et al., *Intelligent Fault Diagnosis of Rolling Bearing Using Deep Wavelet Auto-Encoder with Extreme Learning Machine*. Knowledge-Based Systems, 2018. **140**: p. 1-14.
9. Jia, F., et al., *A Neural Network Constructed by Deep Learning Technique and its Application to Intelligent Fault Diagnosis of Machines*. Neurocomputing, 2018. **272**: p. 619-628.
10. Lu, C., Z. Wang, and B. Zhou, *Intelligent Fault Diagnosis of Rolling Bearing Using Hierarchical Convolutional Network Based Health State Classification*. Advanced Engineering Informatics, 2017. **32**: p. 139-151.
11. Xia, M., et al., *Fault Diagnosis for Rotating Machinery Using Multiple Sensors and Convolutional Neural Networks*. IEEE/ASME Transactions on Mechatronics, 2018. **23**(1): p. 101-110.
12. Zhang, W., et al., *Fault State Recognition of Rolling Bearing Based Fully Convolutional Network*. Computing in Science & Engineering, 2019. **21**(5): p. 55-63.
13. Zilong, Z. and Q. Wei. *Intelligent Fault Diagnosis of Rolling Bearing Using One-Dimensional Multi-Scale Deep Convolutional Neural Network Based Health State Classification*. IEEE.
14. Zhang, W., et al., *A Deep Convolutional Neural Network with New Training Methods for Bearing Fault Diagnosis Under Noisy Environment and Different Working Load*. Mechanical Systems And Signal Processing, 2018. **100**: p. 439-453.
15. Li, S., et al., *An Ensemble Deep Convolutional Neural Network Model with Improved D-S Evidence Fusion for Bearing Fault Diagnosis*. Sensors, 2017. **17**(8): p. 1729.
16. Qian, W., et al., *An Intelligent Fault Diagnosis Framework for Raw Vibration Signals: Adaptive Overlapping Convolutional Neural Network*. Measurement Science And Technology, 2018. **29**(9): p. 095009.
17. Jia, F., et al., *Deep Neural Networks: A Promising Tool for Fault Characteristic Mining and Intelligent Diagnosis of Rotating Machinery with Massive Data*. Mechanical Systems and Signal Processing, 2016. **72-73**: p. 303-315.
18. Mao, W., et al., *Bearing Fault Diagnosis with Auto-Encoder Extreme Learning Machine: A Comparative Study*. Proceedings of The Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science, 2017. **231**(8): p. 1560-1578.
19. Shao, H., et al., *A Novel Method for Intelligent Fault Diagnosis of Rolling Bearings Using Ensemble Deep Auto-Encoders*. Mechanical Systems And Signal Processing, 2018. **102**: p. 278-297.
20. Mao, W., et al. *Online Bearing Fault Diagnosis using Support Vector Machine and Stacked Auto-Encoder*. IEEE.
21. Shao, H., et al., *Rolling Bearing Fault Diagnosis Using Adaptive Deep Belief Network with Dual-Tree Complex Wavelet Packet*. ISA Transactions, 2017. **69**: p. 187-201.
22. Tang Hoang, D. and H. Jun Kang. *Deep Belief Network and Dempster-Shafer Evidence Theory for Bearing Fault Diagnosis*. IEEE.

23. Liang, T., et al. *Bearing Fault Diagnosis Based on Improved Ensemble Learning and Deep Belief Network*. 2018.
24. Pan, H., et al., *An Improved Bearing Fault Diagnosis Method using One-Dimensional CNN and LSTM*. 2018, 2018. **64**(7-8): p. 10.
25. Jiang, H., et al., *Intelligent Fault Diagnosis of Rolling Bearings Using an Improved Deep Recurrent Neural Network*. *Measurement Science And Technology*, 2018. **29**(6): p. 065107.
26. Xie, Y. and T. Zhang. *Imbalanced Learning for Fault Diagnosis Problem of Rotating Machinery Based on Generative Adversarial Networks*. IEEE.
27. Liu, H., et al., *Unsupervised Fault Diagnosis of Rolling Bearings Using a Deep Neural Network Based on Generative Adversarial Networks*. *Neurocomputing*, 2018. **315**: p. 412-424.
28. Zhang, B., et al., *Adversarial Adaptive 1-D Convolutional Neural Networks for Bearing Fault Diagnosis under Varying Working Condition*. arXiv pre-print server, 2018.
29. Mao, W., et al., *Imbalanced Fault Diagnosis of Rolling Bearing Based on Generative Adversarial Network: A Comparative Study*. *IEEE Access*, 2019. **7**: p. 9515-9530.