

PEDRO MIGUEL AGOSTINHO ATELA

Licenciado em Ciências da Engenharia Eletrotécnica e de
Computadores

ANÁLISE AUTOMÁTICA DA OSCILOGRAFIA ASSOCIADA A CURTO-CIRCUITOS EM LINHAS DE TRANSMISSÃO DE ENERGIA ELÉTRICA

MESTRADO EM ENGENHARIA ELETROTÉCNICA E DE COMPUTADORES

Universidade NOVA de Lisboa
Setembro, 2022

ANÁLISE AUTOMÁTICA DA OSCILOGRAFIA ASSOCIADA A CURTO-CIRCUITOS EM LINHAS DE TRANSMISSÃO DE ENERGIA ELÉTRICA

PEDRO MIGUEL AGOSTINHO ATELA

Licenciado em Ciências da Engenharia Eletrotécnica e de Computadores

Orientador: Doutor Francisco Alexandre Ganho da Silva Reis
REN Serviços SA

Coorientador: Doutor Nuno Manuel Ortega Amaro
Prof. Auxiliar, FCT-Nova

Júri

Presidente: Doutor Paulo José Carrilho de Sousa Gil
Professor Auxiliar, FCT-NOVA

Arguente: Doutor João Francisco Alves Martins
Professor Associado com Agregação, FCT-NOVA

Vogal: Doutor Francisco Alexandre Ganho da Silva Reis
REN Serviços SA

Análise automática da oscilografia associada a curto-circuitos em linhas de transmissão de energia elétrica

Copyright © Pedro Miguel Agostinho Atela, Faculdade de Ciências e Tecnologia, Universidade NOVA de Lisboa.

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

Dedico este trabalho a toda a minha família.

Agradecimentos

Agradeço ao Professor Doutor Francisco Reis, pela oportunidade que me concedeu de realizar a dissertação sobre este tema e por toda a ajuda dada ao longo do processo.

Ao Engenheiro Nuno Amaro e ao Engenheiro Francisco Silva pela disponibilidade demonstrada.

Ao *R&D Nester* pela parceria que possibilitou o desenvolvimento desta dissertação.

Aos professores do Departamento de Engenharia Eletrotécnica e de Computadores por todo o conhecimento que transmitiram.

À minha mãe Alice Atela, ao meu pai Luís Atela, ao meu irmão Francisco Atela, à minha namorada Madalena Afoito, às minhas avós Maria Vicência e Maria Luísa e à minha prima Lénia. Obrigado pela paciência, compreensão e apoio incondicional que sempre me deram ao longo da vida. Grande parte daquilo que alcancei e poderei alcançar devo-o a vocês.

Aos meus amigos por todo o companheirismo e divertimento que me proporcionaram e que foram essenciais durante todo este processo.

*«The present is theirs; the future, for which I really
worked is mine.» (Nikola Tesla)*

Resumo

O objetivo da presente dissertação, é desenvolver e aplicar metodologias que permitem a análise automática da oscilografia dos sinais das tensões e das correntes associados a defeitos causados por curto-circuitos em linhas de transmissão de energia elétrica.

Para o efeito foram simulados diferentes tipos de defeitos (curto-circuitos Fase - Terra (FT), Fase - Fase - Terra (FFT) e Fase - Fase - Fase - Terra (FFFT)) no laboratório do *R&D Nester* utilizando o modelo disponibilizado da Rede Nacional de Transporte (RNT) portuguesa.

Para cada um dos defeitos simulados foi desenvolvido e aplicado um método baseado na transformada de *wavelet*, que permite identificar nos sinais de defeito, os instantes de início do defeito, de abertura dos disjuntores e de restabelecimento do circuito, fazendo-se a partir desses instantes, a segmentação dos sinais. Posteriormente, a partir da informação fornecida pela segmentação dos sinais, foi desenvolvido um método, tendo por base Redes Neurais Artificiais, capaz de classificar os defeitos, ou seja, permite distinguir se os defeitos são entre a fase A e a terra, entre a fase B e a terra, etc.

A aplicação dos métodos de segmentação e classificação indicados anteriormente apresentaram uma taxa de sucesso na ordem dos 98,5% para diferentes cenários topológicos e operacionais da rede.

Palavras-chave: Análise automática de defeitos, Segmentação dos sinais de defeito, Classificação dos sinais de defeito, *Wavelet*, Redes Neurais Artificiais

Abstract

The aim of this dissertation is to develop and apply methodologies which allow for the automatic analysis of waveforms from voltage and current signals associated with faults caused by short circuits.

For this purpose, different types of faults (Phase - Ground, Phase - Phase - Ground and Phase - Phase - Phase - Ground short circuits) were simulated in R&D Nester laboratory using the existing Portuguese transmission grid model.

For each of the faults simulated, a method based on wavelet transform was developed and applied, which allowed the identification of the time instants of fault initiation, circuit breakers opening and circuit re-establishment in the fault signals and by the use of this instants make the segmentation of the signal. From the information provided by the segmentation of the signals, a method was developed based on Artificial Neural Networks, capable of classifying whether a fault was between phase A and ground, or between phase B and ground, etc.

The application of the segmentation and classification methods indicated above, presented a success of 98,5% for different topological and operational network scenarios.

Keywords: Automatic Fault Analysis, Fault signal segmentation, Fault signal classification, Wavelet, Artificial Neural Networks

Índice

Índice de Figuras	xvii
Índice de Tabelas	xix
Siglas	xxiii
1 Introdução	1
1.1 Enquadramento e motivação	1
1.2 Objetivos	2
1.3 Estrutura do documento	3
2 Análise automática de defeitos	5
2.1 Tipos de defeitos ocorrentes nas linhas de transmissão de energia elétrica	5
2.2 Equipamentos de Proteção	7
2.2.1 Relé de proteção	7
2.2.2 Disjuntores	8
2.3 Formato COMTRADE	8
2.4 Segmentação dos sinais de defeito	9
2.5 Classificação dos sinais de defeito	10
2.5.1 Transformada de <i>wavelet</i>	10
2.5.2 Lógica Difusa	11
2.5.3 Redes Neurais Artificiais	12
2.5.4 Máquinas de Suporte Vetorial	12
2.6 Conclusão	13
3 Métodos para a segmentação e classificação dos sinais de defeito	15
3.1 Segmentação: Transformada de <i>wavelet</i>	15
3.1.1 Transformada de <i>wavelet</i> contínua	18
3.1.2 Transformada de <i>wavelet</i> discreta	19
3.2 Classificação: Redes Neurais Artificiais	20

3.2.1	Introdução	21
3.2.2	O neurónio artificial	22
3.2.3	Arquiteturas das RNAs	23
3.2.4	Processos de aprendizagem das RNAs	25
3.2.5	Algoritmo de Retropropagação	26
3.2.6	Critério de paragem da fase de treino	27
3.3	Metodologia desenvolvida e implementação	28
3.4	Conclusão	31
4	Aplicação e resultados	33
4.1	Cenários topológicos	33
4.1.1	Simulação de defeitos	35
4.1.2	Interpretação da informação contida na oscilografia	36
4.2	Segmentação dos sinais de defeito	38
4.2.1	Processamento adicional	44
4.3	Classificação dos sinais de defeito	51
4.3.1	Conjuntos de treino e de teste	51
4.3.2	Camadas de entrada e de saída	52
4.3.3	Parâmetros do modelo	54
4.3.4	Fases de treino e de teste	58
4.4	Análise dos resultados	61
4.5	Conclusão	62
5	Conclusão	63
5.1	Conclusões	63
5.2	Perspetivas de trabalho futuro	64
	Bibliografia	67
	Anexos	
I	Características das linhas de transmissão seleccionadas	71
II	Análise dos ficheiros COMTRADE de configuração gerados	73
III	Exemplo de segmentação dos sinais de defeito	75
IV	Resultados obtidos pela RNA na fase de teste	77

Índice de Figuras

2.1	Tipos de defeitos em redes elétricas (adaptado de [7]).	6
2.2	Defeitos por curto-circuito (adaptado de [8]).	6
2.3	Diagrama de blocos de um sistema de lógica difusa.	11
3.1	Exemplo da informação que é extraída de um sinal pela aplicação da TF. . .	16
3.2	Representação gráfica da “janela” que percorre o sinal na transformada de <i>Fourier</i> de tempo curto (adaptado de [28]).	16
3.3	<i>Wavelet Morlet</i>	17
3.4	Comparação entre a resolução da transformada de <i>Fourier</i> de tempo curto e da transformada de <i>wavelet</i>	18
3.5	<i>Wavelet Morlet</i> para diferentes valores de escalamento (identificado como “a”) e de deslocamento (identificado como “b”).	19
3.6	Decomposição de nível múltiplo para um sinal com frequência de amostragem de 100 kHz, em que os coeficientes de detalhe estão representados pela letra D e os de aproximação pela letra A (adaptado de [7]).	20
3.7	Constituintes de um neurónio biológico.	21
3.8	Modelo de um neurónio [32].	22
3.9	Rede direta de uma só camada.	24
3.10	Rede direta multicamada.	24
3.11	Rede recorrente [33].	25
3.12	Gráficos do erro da RNA sobre o conjunto de treino e de validação ao longo da fase de treino [32].	28
3.13	Sequência de passos do trabalho desenvolvido.	29
3.14	Conjunto de <i>scripts</i> desenvolvidos no trabalho.	30
4.1	Localização aproximada de cada uma das linhas sobre as quais se simularam os defeitos, assim como, o seu nível de tensão [38].	34
4.2	Modelização no <i>software HyperSim</i> da RNT, na zona de Lisboa (entre Fanhões e Alto Mira).	35
4.3	Principais informações contidas no ficheiro COMTRADE de configuração. . . .	37

4.4	Sinal original e coeficientes de detalhe para a corrente da fase A no caso de um defeito A-T.	39
4.5	Sinal original e coeficientes de detalhe para a tensão da fase A no caso de um defeito A-T.	40
4.6	Gráficos dos coeficientes de detalhe no fim de ser definido o <i>threshold</i> (traçado a verde).	41
4.7	Zonas dos gráficos em que os coeficientes de detalhe superam o <i>threshold</i> (indicadas pelos círculos a vermelho); 1º- começo do defeito; 2º- abertura dos disjuntores; 3º- restabelecimento do circuito.	42
4.8	Resultado final da segmentação do sinal para a corrente e tensão da fase A num defeito A-T.	43
4.9	Segmentos constituintes do sinal.	44
4.10	Coeficientes de detalhe para as correntes das três fases e respetivos sinais originais num defeito em que na corrente da fase C não se determinou os três eventos do sinal.	46
4.11	Processo efetuado quando se obteve múltiplos coeficientes acima do <i>threshold</i> definido dizendo respeito ao mesmo evento no sinal.	48
4.12	Fluxograma que descreve o processo executado para a segmentação dos sinais de defeito.	49
4.13	Exemplo de um sinal em que não se conseguiu efetuar a segmentação através do nível 1 de decomposição.	50
4.14	Decomposição do sinal da figura 4.13 para o primeiro e segundo níveis.	50
4.15	Segmentos do sinal que constituem os dados de entrada da Rede Neuronal Artificial (RNA).	52
4.16	Diagrama de blocos do classificador de defeitos (adaptado de [21]).	53
4.17	Processo efetuado para a determinação dos parâmetros que otimizam a <i>performance</i> do modelo.	56
4.18	Constituição dos três melhores modelos obtidos durante a procura dos parâmetros que otimizam o desempenho da rede e <i>score</i> obtido por cada um.	57
4.19	Arquitetura final do modelo.	58
4.20	Erros obtidos pelo modelo no conjunto de treino e de validação em função do número de épocas.	59
4.21	Resultados obtidos pelo modelo.	60
4.22	Distribuição do erro absoluto dos resultados obtidos pelo modelo.	60
4.23	Resultados obtidos pelo modelo e conversão para os valores lógicos 0 e 1.	61
II.1	Informações contidas no ficheiro COMTRADE de dados.	73
III.1	Resultado final da segmentação dos sinais de defeito das correntes e tensões das três fases.	75

Índice de Tabelas

2.1	Ocorrência de cada tipo de defeito por curto-circuito [9].	7
3.1	Funções de ativação (adaptado de [34]).	23
4.1	Características das linhas selecionadas [37].	34
4.2	Valores mínimos e máximos de cada variável das simulações.	36
4.3	Significado dos campos usados para se processar a informação.	37
4.4	Informação dos canais contida no ficheiro de dados.	38
4.5	Instante temporal em que ocorreram cada um dos eventos dos sinais da figura 4.8.	44
4.6	Porcentagem de utilização de cada um dos níveis da Transformada de <i>Wavelet</i> Discreta (TWD).	51
4.7	Linhas sobre as quais se simularam os defeitos para o conjunto de treino. .	51
4.8	Linhas sobre as quais se simularam os defeitos para o conjunto de teste. . .	52
4.9	Correspondência entre o neurónio ativo à saída e o tipo de defeito.	54
4.10	Espaço de procura para os parâmetros da RNA.	55
4.11	Correspondência entre o nome da variável e o parâmetro representado. . .	57
4.12	Erro médio quadrático do modelo final nos conjuntos de treino, validação e teste.	59
4.13	Comparação entre o pior resultado obtido pelo modelo e o resultado esperado.	61
4.14	Erro médio quadrático e erro absoluto máximo obtido na fase de teste consoante o defeito seja FT, FFT ou FFFT.	62
I.1	Características das linhas selecionadas de uma forma mais detalhada [37].	72
IV.1	Resultados obtidos na linha Carvoeira - Trajouce para 20 defeitos FT. . . .	77
IV.2	Conversão dos resultados obtidos pelo modelo para os valores lógicos 0 e 1.	78

Siglas

API	<i>Application Programming Interface</i>
AT	Alta Tensão
COMTRADE	<i>Common Format for Transient Data Exchange</i>
FF	Fase - Fase
FFF	Fase - Fase - Fase
FFFT	Fase - Fase - Fase - Terra
FFT	Fase - Fase - Terra
FT	Fase - Terra
IED	Dispositivos Eletrônicos Inteligentes
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
MAT	Muito Alta Tensão
MVS	Máquinas de Suporte Vetorial
REN	Rede Elétrica Nacional, S.A.
RNA	Rede Neuronal Artificial
RNT	Rede Nacional de Transporte
TF	Transformada de <i>Fourier</i>
TW	Transformada de <i>Wavelet</i>
TWD	Transformada de <i>Wavelet</i> Discreta

Introdução

1.1 Enquadramento e motivação

As redes elétricas necessitam de disponibilizar ao consumidor um serviço com uma elevada continuidade e uma boa qualidade de energia elétrica. A continuidade de serviço é definida como a frequência e duração das interrupções do fornecimento de energia elétrica e a qualidade da energia diz respeito à forma da onda de tensão. O objetivo é diminuir o número de interrupções e fornecer uma onda de tensão alternada sinusoidal constante ao longo do tempo, em termos de amplitude e de frequência [1].

Tendo esse objetivo em vista, uma das dimensões que se afigura como essencial diz respeito ao controlo e proteção das redes de transporte de energia elétrica. A ocorrência de defeitos nestas redes é inevitável, quer seja, por falha de determinados equipamentos, por manobras ou por descargas atmosféricas. Dos defeitos que acontecem nas redes de transporte, mais de 85% dão-se nas linhas de transmissão de energia elétrica que podem ser linhas aéreas ou cabos subterrâneos e são responsáveis por efetuar a ligação entre as centrais produtoras e as subestações Muito Alta Tensão (MAT)/Alta Tensão (AT) que permitem a interface física com o operador da rede de distribuição [2]. A possibilidade de obtenção de informação que permita caracterizar cada um dos defeitos que ocorrem, através da extração de informação provenientes de determinados equipamentos presentes nas subestações, é essencial. Embora em muitas situações, a rede opere automaticamente, os operadores da rede precisam de monitorizar o seu funcionamento e também de lidar com problemas que não conseguem ser resolvidos automaticamente pelos equipamentos. Por esse motivo, entre outros, os dados gerados durante determinado tipo de defeito ou perturbação, têm de ser analisados.

Hoje em dia, ao contrário do que acontecia no passado, há cada vez mais equipamentos com a capacidade de fornecer dados que permitem a análise de determinados defeitos ou perturbações, chamados de Dispositivos Eletrónicos Inteligentes (IED). A análise manual de toda a informação demora tempo e é complexa, por esse motivo, certas gravações efetuadas podem acabar por não ser estudadas perdendo-se assim o conhecimento que poderia ser extraído [3]. A oportunidade de automatizar a análise de defeitos a partir

de informação residente em IEDs é a principal motivação desta dissertação. A análise automática de defeitos é definida como a capacidade de um programa computacional, analisar e correlacionar os dados disponíveis sobre o mesmo [3]. Atualmente, o grande desafio é converter o máximo de informação disponível em conhecimento de uma forma automática e com um alto nível de fiabilidade.

1.2 Objetivos

Tendo em vista o problema apresentado anteriormente, o trabalho desenvolvido pretende implementar métodos capazes de efetuar a análise automática dos sinais de defeito, a partir da oscilografia das tensões e das correntes das três fases das linhas em que ocorre a falha e tem os seguintes objetivos principais:

- Desenvolver *script* que permite a geração e tratamento de ficheiros no formato *Common Format for Transient Data Exchange* (COMTRADE) no laboratório do *R&D Nester*;
- Segmentar os sinais de defeito identificando variáveis chave na caracterização do defeito como seja, o seu início, o instante de abertura dos disjuntores, etc;
- Classificar os sinais de defeito tendo por base características intrínsecas associadas a cada um dos tipos de defeitos.

No que diz respeito ao primeiro ponto, foi disponibilizado pelo *R&D Nester* o modelo da Rede Nacional de Transporte (RNT) de Eletricidade no *software HyperSim*¹. O *HyperSim* permite executar simulações de transitórios eletromagnéticos e eletromecânicos em redes elétricas. Através da *Application Programming Interface* (API), que o simulador tem com a linguagem de programação *Python*, tenciona-se desenvolver um *script* que automatize a geração de diferentes tipos de curto-circuitos (Fase - Terra (FT), Fase - Fase - Terra (FFT) e Fase - Fase - Fase - Terra (FFFT)) em linhas de MAT, que são o tipo de linhas que constitui a RNT, e que faça a extração da oscilografia correspondente em formato COMTRADE. Os ficheiros COMTRADE, são um conjunto de ficheiros que contêm as formas de onda de transitórios e de eventos que acontecem em redes elétricas [4]. Normalmente, a informação sobre determinado defeito ou perturbação na rede, está neste formato.

Através da oscilografia obtida no simulador e descrita nos ficheiros COMTRADE, tem-se como objetivo testar métodos de segmentação e de classificação de defeitos. As metodologias de análise automática de defeitos, que se pretendem desenvolver, devem ser capazes de ler os ficheiros COMTRADE e a partir dessa leitura extrair informações sobre [3]:

- As fases defeituosas e o tipo de defeito;

¹<https://www.opal-rt.com/systems-hypersim/>

- O tempo que durou o defeito;
- O instante de operação dos disjuntores;
- O instante de restabelecimento do circuito ou de tentativa de restabelecimento.

O objetivo da segmentação do sinal de defeito é encontrar os instantes de começo do defeito, de abertura dos disjuntores e de restabelecimento ou tentativa de restabelecimento da ligação. A partir desses indicadores, determinam-se os instantes de operação dos disjuntores, o instante de restabelecimento da ligação e também a duração do defeito.

Já a classificação do defeito, tem como resultado, a identificação do tipo de defeito (se o defeito ocorreu entre a fase A e a terra, entre a fase B e a terra, etc). Esta classificação permite verificar se os equipamentos operaram de forma adequada e, muitas vezes, é usado como informação para posteriormente se localizar em que zona da linha ocorreu o defeito, ou seja, para se localizar o defeito, primeiro identificam-se as fases defeituosas e só depois se determina a localização do mesmo.

Com a implementação da segmentação e classificação dos sinais de defeito, muita da informação que se requer na análise automática de defeitos é extraída. Tenciona-se com a elaboração deste trabalho, gerar ficheiros COMTRADE através do simulador *HyperSim*, extrair a informação contida nesses ficheiros e, a partir da análise dessa informação, efetuar a segmentação e classificação de cada um dos sinais de defeito.

1.3 Estrutura do documento

A dissertação está estruturada em cinco capítulos.

No Capítulo 2, apresentam-se quais os tipos de defeitos que acontecem em linhas de transmissão de energia elétrica, os principais equipamentos de proteção, o formato COMTRADE, os objetivos da segmentação do sinal de defeito e, por fim, são descritos, de forma sucinta, métodos existentes para a classificação de defeitos, assim como, aplicações anteriores dos mesmos.

No Capítulo 3 é desenvolvida e apresentada a teoria por detrás dos algoritmos aplicados no desenvolvimento da dissertação. Começa-se por explicar o porquê da utilização da transformada de *wavelet* e os seus principais conceitos e, de seguida, passa-se à descrição da técnica usada para a classificação de defeitos, as Redes Neurais Artificiais. O capítulo termina com a apresentação da metodologia desenvolvida para a análise automática dos sinais de defeito.

No Capítulo 4, é apresentado o estudo efetuado sobre o modelo da RNT. É explicado o tratamento da informação realizado sobre os ficheiros COMTRADE que contêm a oscilografia dos sinais de defeito. Para além disso, é realizada a segmentação dos sinais e posterior classificação, para um conjunto diverso de situações. São ainda mostrados e analisados os resultados obtidos pelas técnicas de segmentação e de classificação usadas.

Por fim, no Capítulo 5, são descritas as conclusões finais e abordadas as perspectivas de trabalho futuro.

Análise automática de defeitos

Neste capítulo serão descritos os tipos de defeitos ocorrentes nas linhas de transmissão de energia elétrica e também os principais equipamentos de proteção usados para se eliminar esses defeitos. De seguida, será abordado o formato COMTRADE, dado que os ficheiros analisados na dissertação, se encontram neste formato.

O capítulo termina, com a discussão da importância e dos objetivos da segmentação dos sinais de defeito e com a descrição dos principais métodos de classificação de defeitos, assim como, aplicações anteriores dos mesmos.

2.1 Tipos de defeitos ocorrentes nas linhas de transmissão de energia elétrica

Diz-se que uma rede elétrica se encontra numa situação anómala de funcionamento, quando um dos seus parâmetros (tensão, corrente, frequência, etc.) excede ou está abaixo dos seus valores em condições habituais de operação [5]. Já um defeito, é definido como uma falha que requer o disparo imediato dos disjuntores associados à proteção do elemento defeituoso, de forma a dissociá-lo do resto da rede. Esse elemento, pode ser um equipamento da rede, um elemento primário do circuito, etc [6].

Os defeitos ocorrentes em redes elétricas, nas linhas de transmissão de energia, categorizam-se em três tipos:

- Defeitos por curto-circuito;
- Defeitos por circuito aberto;
- Defeitos combinados.

Os defeitos por curto-circuito, são defeitos em que existe corrente a fluir entre fases ou entre pelo menos uma das fases e a terra. Já os defeitos por circuito aberto são, na maior parte das vezes, causados pela interrupção de uma ou duas fases, o que provoca que a impedância entre elas seja diferente. Enquanto que os defeitos combinados, surgem quando se dá simultaneamente, um defeito por curto-circuito e por circuito aberto.

Os defeitos por curto-circuito, podem ainda ser divididos em simétricos e assimétricos. Nos defeitos simétricos incluem-se os defeitos FT, FFT e Fase - Fase (FF), ao passo que os simétricos, são dados pelos defeitos FFFT e Fase - Fase - Fase (FFF). Um esquema de todos os defeitos falados, encontra-se na figura 2.1.




Figura 2.1: Tipos de defeitos em redes elétricas (adaptado de [7]).

Os defeitos por curto-circuito, são os mais habituais em linhas de transmissão de energia elétrica. Este tipo de defeitos é caracterizado por um aumento da corrente nas fases defeituosas e também por uma diminuição da tensão nessas fases. A configuração dos defeitos por curto-circuito está ilustrada na imagem 2.2 e na tabela 2.1, estão expostas as percentagens de ocorrência de cada tipo de curto-circuito.




Figura 2.2: Defeitos por curto-circuito (adaptado de [8]).

Tabela 2.1: Ocorrência de cada tipo de defeito por curto-circuito [9].

Tipo de defeito	Ocorrência
FT	70% a 80%
FFT	10% a 17%
FF	8% a 10%
FFF e FFFT	2% a 3%

Da tabela retira-se que grande parte dos curto-circuitos que acontecem em linhas de transmissão de energia elétrica, são do tipo FT e que os curto-circuitos FFT apresentam também uma percentagem de ocorrência considerável.

2.2 Equipamentos de Proteção

O principal objetivo dos equipamentos de proteção usados nas redes elétricas é o de isolar a falha que ocorreu num determinado ponto, dos outros componentes que se encontram em normal funcionamento. Estes equipamentos de proteção, para o caso dos defeitos por curto-circuito, não conseguem impedir o fluxo momentâneo da corrente de defeito pelo sistema mas diminuem o tempo em que esse fluxo ocorre e o alcance que determinados defeitos poderiam ter na rede.

2.2.1 Relé de proteção

Os relés de proteção são muitas vezes apelidados como o “cérebro” do esquema de proteção aplicado em determinada zona da rede elétrica, uma vez que, entre outras funções, são responsáveis por emitir o sinal de disparo para o disjuntor atuar.

Estes dispositivos podem ser divididos em três categorias [9]:

- Relés eletromecânicos;
- Relés de estado sólido;
- Relés digitais.

Os relés eletromecânicos foram os primeiros a surgir. Posteriormente aplicaram-se os relés de estado sólido que têm como mais valia o facto de não terem na sua constituição partes móveis [10].

O aparecimento dos relés digitais, aconteceu com o principal propósito de reduzir os tempos de eliminação dos defeitos. Têm a grande mais valia de terem incorporada capacidade de comunicação, o que permite um maior controlo e monitorização do estado da rede. Incorporam ainda outros tipos de melhorias em relação aos anteriores como uma elevada precisão, ocupam uma área menor e o custo da sua instalação é mais reduzido. Hoje em dia, grande parte dos relés usados são relés digitais.

2.2.2 Disjuntores

Os disjuntores de alta tensão, são responsáveis pela interrupção da corrente no circuito aquando da ocorrência de uma situação que assim o exija. O corte da corrente é feito quando esta está a passar por um zero de forma a diminuir a tensão transitória que se irá estabelecer aos terminais do disjuntor, com o intuito de diminuir o risco de reacendimento do arco elétrico.

Estes equipamentos são classificados de acordo com o meio que usam para a extinção do arco elétrico. Os principais tipos são os seguintes:

- Disjuntores a óleo;
- Disjuntores a ar;
- Disjuntores a vácuo;
- Disjuntores a SF6.

2.3 Formato COMTRADE

Devido ao aumento de dados presentes nas subestações provenientes de distintos equipamentos digitais, surgiu a necessidade de se criar um formato para esses dados [4]. O formato COMTRADE, como o próprio nome indica, é um formato para a troca de dados em situações de transitórios ou de defeitos na rede, definido pelo *Institute of Electrical and Electronics Engineers* (IEEE) [11].

Este formato é constituído por quatro ficheiros:

- Cabeçalho;
- Ficheiro de configuração;
- Ficheiro de dados;
- Ficheiro de informação.

O cabeçalho é um ficheiro de texto do tipo ASCII, de cariz opcional. Poderá incluir qualquer tipo de informação, sem nenhuma ordem em específico.

O mesmo não acontece com o ficheiro de configuração, que tem de respeitar um determinado formato dado que se destina a ser processado por um programa específico que seja responsável pela sua leitura. Este ficheiro, é também de texto do tipo ASCII e serve para fornecer a informação necessária ao computador para ler o ficheiro de dados corretamente. Entre outro tipo de dados, este ficheiro contém informações sobre o número de canais que foram gravados, de que tipo são esses canais (analógicos ou digitais), a quantidade de amostras gravadas, a frequência de operação da rede, etc.

O ficheiro de dados, para cada amostra do sinal que se gravou, dá informação sobre o seu valor e também dos instantes temporais em que ocorreram cada uma dessas amostras [4].

Quanto ao ficheiro de informação, é também opcional e serve para acrescentar algum tipo de informação que ajude à análise dos dados.

2.4 Segmentação dos sinais de defeito

A análise dos defeitos ocorrentes em redes elétricas é feita através da inspeção das medições efetuadas pelo IEDs. Exemplos de IEDs são os relés de proteção digitais e os *digital fault recorders*. O objetivo desta análise é através dos dados recebidos, extrair conhecimento acerca da situação que ocorreu no sistema.

Uma análise automática dos dados fornecidos pelos IEDs traz os seguintes benefícios [12]:

- Maior consistência;
- Redução do tempo da análise;
- Custos mais reduzidos.

A análise mais consistente deve-se ao facto de os dados poderem ser analisados de forma diferente por diferentes pessoas dentro da organização, o que causará o aparecimento de diversas soluções para o mesmo problema e que pode conduzir a uma atuação errada sobre o mesmo. Se a análise automática fôr consistente pode resolver algumas destas discrepâncias.

Esta automatização diminui o tempo despendido pelos trabalhadores na análise dos eventos e, por vezes, resulta em relatórios gerados automaticamente, baixando assim os custos para a empresa.

O primeiro passo para se fazer uma análise automática de defeitos, é identificar os instantes em que os eventos associados ao defeito ocorreram. Sendo esses eventos: o instante de começo do defeito, da abertura dos contactos dos disjuntores e de restabelecimento do circuito [13]. A descoberta desses eventos, permite dividir o sinal nos segmentos de pré-defeito, de defeito, de abertura dos contactos do disjuntor até ao fecho dos mesmos e num último segmento que tem início aquando do fecho dos contactos do disjuntor.

A partir dos segmentos enumerados, consegue-se extrair um conjunto de informações, como por exemplo, o tempo que durou o defeito e os tempos de operação dos disjuntores mas também, retirar-se algumas características de cada um dos segmentos que sirvam de base para outros algoritmos que visem a análise automática do sinal de defeito [14].

Para se realizar a segmentação do sinal, são muitas vezes usadas técnicas que detetam mudanças abruptas na sua oscilografia, mudanças essas que coincidem com os eventos anteriormente enumerados. Uma mudança abrupta no sinal, define-se como uma variação

repentina ao nível da sua amplitude. De entre as diversas técnicas que detetam mudanças abruptas nas oscilografias gravadas, destaca-se a Transformada de *Wavelet* (TW) que depois de um estudo comparativo realizado em [14], parece ser a técnica mais adequada para este propósito.

2.5 Classificação dos sinais de defeito

O objetivo da classificação dos sinais defeituosos é o de discriminar o tipo de defeito. Neste capítulo serão apresentados os principais métodos para satisfazer este propósito. Grande parte dos algoritmos usados anteriormente, destinam-se a aplicações relacionadas com a decisão de disparo enviada pelo relé ao disjuntor. Ou seja, em caso de defeito têm como objetivo detetar, classificar e localizar o defeito o mais rápido possível para desenergizar a linha. No entanto, no trabalho realizado estudou-se a forma como essas técnicas classificavam os defeitos para posteriormente se aplicar uma metodologia similar mas numa perspetiva de análise automática dos sinais de defeito provenientes da oscilografia fornecida pelos IED.

De entre as técnicas para se classificar os sinais de defeito que foram analisadas, destacam-se a transformada de *wavelet*, lógica difusa, as redes neuronais artificiais e as máquinas de suporte vetorial. De seguida, irá ser feita uma breve descrição de cada uma destas técnicas assim como, de aplicações anteriores em que foram usadas para a classificação de defeitos.

2.5.1 Transformada de *wavelet*

A TW, é uma técnica capaz de fazer a análise de sinais no domínio do tempo e da frequência com uma resolução variável. Através da utilização da técnica de decomposição de nível múltiplo, a transformada de *wavelet* consegue decompor sinais em diferentes bandas de frequência. Esta aplicação tem como resultado um conjunto de coeficientes de detalhe que contêm as componentes de alta frequência do sinal e um conjunto de coeficientes de aproximação que contêm as componentes de baixa frequência. Esta técnica, vai ser abordada mais detalhadamente no capítulo seguinte, visto que foi aplicada numa perspetiva de segmentação dos sinais de defeito e não de classificação dos mesmos.

Em [15] foi usada a entropia de *wavelet* para se classificar o defeito. O objetivo de juntar estas duas técnicas é aliar a capacidade que a transformada de *wavelet* tem de analisar sinais não estacionários (sinais cujas componentes de frequência variam ao longo do tempo) com a informação disponibilizada pelo cálculo da entropia. O algoritmo baseia-se na soma dos valores da entropia dos coeficientes de detalhe da TW para detetar e classificar o defeito. A transformada de *wavelet* é aplicada sobre os sinais das correntes das três fases da linha. O método classificou corretamente os defeitos simulados.

No trabalho desenvolvido em [16], são usados os valores medidos das correntes das fases em apenas um extremo da linha de transmissão. Depois de aplicada a transformada

de *wavelet*, é definido um *threshold* que permite distinguir entre os diversos tipos de defeitos e também distinguir sinais defeituosos de sinais não defeituosos. É reportado que o método pode ser aplicado em defeitos com valores de resistência até 500Ω .

2.5.2 Lógica Difusa

A lógica difusa é um tipo de lógica que pretende modular o conhecimento humano num algoritmo que seja subsequentemente aplicado no problema em questão [17]. Como tal, procura lidar com as imprecisões e incertezas que estão associadas ao raciocínio humano [18]. O resultado final produzido pode ter qualquer valor entre 0 e 1. Na figura 2.3 está apresentado um diagrama de blocos que descreve a utilização desta técnica. São passados um conjunto de variáveis de entrada (podem ser os valores das tensões e das correntes), que são submetidas a um processo chamado de fuzificação que consiste em transformar os valores numéricos em valores linguísticos. De seguida, no mecanismo de inferência são usadas as regras estabelecidas sobre o sistema para retirar conclusões sobre o mesmo e, por fim, no processo de desfuzificação, o resultado obtido pelo mecanismo de inferência é transformado numa variável contínua, neste caso indicadora do tipo de defeito.




Figura 2.3: Diagrama de blocos de um sistema de lógica difusa.

Em [19] desenvolveu-se uma técnica com lógica difusa capaz de detetar e classificar defeitos. As entradas do sistema são os valores das correntes das três fases durante o defeito e é a partir desses valores que se estabelece o mecanismo de inferência. São recolhidos os valores das correntes apenas numa extremidade da linha. O método é constituído por dois classificadores: um para os defeitos que incluem a terra e outro para os restantes.

No artigo [20] aplicou-se lógica difusa, recolhendo os valores das correntes nas três fases durante o defeito. De seguida, com o cálculo das componentes positiva, negativa e homopolar da frequência fundamental das correntes, construiu-se as regras e o mecanismo de inferência que permitem classificar o defeito. O método apresentou uma eficácia de 96,87% em linhas de transmissão duplas. Este tipo de linhas são particularmente problemáticas devido ao acoplamento entre as fases que origina não-linearidades elevadas.

2.5.3 Redes Neurais Artificiais

As RNAs são sistemas computacionais cuja criação foi baseada no funcionamento biológico do cérebro animal. São constituídas por neurónios artificiais com ligações entre si, através das quais, transmitem informações de neurónio para neurónio. De uma forma geral, são formadas por uma camada de entrada, onde são passados os dados de entrada e uma camada de saída onde é obtido o resultado final. Podem ainda possuir uma ou várias camadas escondidas, entre a camada de entrada e a de saída. Após serem submetidas a um processo de aprendizagem, ganham a capacidade de fazer previsões sobre um determinado problema. Devido à sua grande capacidade de generalização, classificação e reconhecimento de padrões, têm sido amplamente utilizadas em diversas aplicações relacionadas com redes elétricas [21]. Na classificação de defeitos, estas redes têm, normalmente, como entrada as tensões ou as correntes das três fases e através de características observadas nos dados de entrada, determinam o tipo de defeito.

No artigo [22] aplicou-se uma rede neuronal para a classificação de defeitos numa linha de transmissão dupla. São usados os valores das correntes das três fases como dados de entrada para a RNA e também a componente positiva e homopolar de cada uma das correntes. O método só classifica defeitos do tipo fase-terra e fê-lo corretamente para todo o conjunto de teste.

No trabalho efetuado em [23] usou-se um método que combina a transformada de *wavelet* e uma rede neuronal. É feita a deteção do defeito através da transformada de *wavelet*. Já a classificação, está à responsabilidade da rede neuronal que, em caso de defeito, recebe como entrada os sinais das tensões e das correntes nos instantes de pré-defeito (antes de se dar o defeito) e de defeito. Este método apresentou uma eficácia de 99,83%.

2.5.4 Máquinas de Suporte Vetorial

As Máquinas de Suporte Vetorial (MVS) são uma técnica baseada na teoria da aprendizagem estatística, usada em problemas de classificação ou de regressão. À semelhança das RNAs, as MVS passam por um processo de treino em que é desenvolvido um modelo que tem como objetivo indicar a classe a que pertencem determinados atributos. A grande maioria dos algoritmos que usam MVS, separa os dados em dois grupos. Durante a fase de treino, cada par de dados tem a forma $(x_1, y_1) \dots (x_n, y_n)$ onde x_n representa o vetor de dados de entrada e y_n a classe onde o vetor será integrado [24]. Tem-se que $y_j \in \{-1, 1\}$ e $x_i \in R_n$. O objetivo é, quando terminada a fase de treino, o algoritmo indicar a classe a que pertencem determinados conjuntos de dados sem lhe ser fornecida a sua classe.

Em [25] são usadas máquinas de suporte vetorial para se classificar o defeito. Os valores das correntes das três fases são pré-processados através da transformada de *wavelet* e a classificação do defeito é feita através dos valores dos ângulos entre as correntes de cada fase.

No método usado em [26], são utilizados os sinais das correntes durante o defeito como entrada para a máquina de suporte vetorial. Antes disso, os sinais das correntes são decompostos nas suas características de mais altas frequências usando a transformada de *wavelet*. A percentagem de sucesso na classificação dos defeitos, foi mais baixa para defeitos FT com um valor de 98,8%.

2.6 Conclusão

Neste capítulo foram revistos os tipos de defeitos ocorrentes em linhas de transmissão de energia elétrica, dando especial ênfase aos defeitos por curto-circuito, assim como, os principais equipamentos de proteção.

Foi ainda abordado o formato COMTRADE que é constituído por quatro ficheiros: o cabeçalho, o ficheiro de configuração, o ficheiro de dados e o ficheiro de informação.

Relativamente à análise automática dos sinais de defeito, para se alcançar a segmentação do sinal a partir das mudanças abruptas existentes no mesmo, o uso da transformada de *wavelet* é a técnica mais indicada.

Depois de uma análise de diversas técnicas usadas anteriormente para a classificação de defeitos, pode-se concluir que as RNAs apresentam uma grande eficácia (com percentagens de sucesso a rondar os 100%) e, por isso, foi a técnica aplicada neste trabalho.

Métodos para a segmentação e classificação dos sinais de defeito

Neste capítulo, são abordados os fundamentos teóricos da transformada de *wavelet* e das Redes Neurais Artificiais dado que, foram os métodos usados para se segmentar e classificar os sinais de defeito, respetivamente. O capítulo termina com a explicação da metodologia desenvolvida para a análise automática dos sinais de defeito a partir destes métodos.

3.1 Segmentação: Transformada de *wavelet*

À semelhança da Transformada de *Fourier* (TF), a transformada de *wavelet* é uma ferramenta matemática para a análise de sinais [27].

A TF, faz uma análise global ao sinal, separando-o nas sinusóides que o constituem de diferentes frequências. Esta transformada, passa o sinal do domínio do tempo para o domínio da frequência. Se em determinadas situações, este tipo de análise é bastante útil, quando se está perante um sinal não estacionário e se pretende obter informações sobre o instante temporal em que ocorreram determinadas frequências, tem de se recorrer a outros métodos. Um sinal não estacionário é definido como um sinal cujas componentes de frequência variam ao longo do tempo. Na imagem 3.1 está ilustrado o tipo de informação extraído pela TF. Do sinal da imagem, obteve-se as suas componentes de frequência mas não existe qualquer referência temporal sobre as mesmas.




Figura 3.1: Exemplo da informação que é extraída de um sinal pela aplicação da TF.

Para tentar ultrapassar algumas das desvantagens apresentadas pela TF, surgiram algumas variantes como a “transformada de *Fourier* de tempo curto”. Nesta técnica o sinal é dividido em segmentos que se apresentam quase estacionários e, para cada um dos segmentos é calculada a sua transformada de *Fourier*. Esta divisão do sinal é feita por uma “janela” que o percorre (figura 3.2).




Figura 3.2: Representação gráfica da “janela” que percorre o sinal na transformada de *Fourier* de tempo curto (adaptado de [28]).

Mesmo com esta técnica, derivado ao facto de a janela ter um tamanho fixo ao longo de todo o sinal, acontece que, se o comprimento da janela for demasiado pequeno, a resolução da frequência poderá ficar demasiado baixa para o tipo de análise que se pretende e, por outro lado, se se aumentar o comprimento em demasia, eventualmente, deixará de se poder considerar o sinal estacionário. Então, em certas situações, não existe uma janela que se adeque à análise do sinal completo.

Destas limitações apresentadas, por vezes, surge a necessidade de se utilizar um método mais flexível, onde se possa variar a escala de análise no domínio do tempo e da frequência [28].

A transformada de *wavelet*, faz uma decomposição do sinal em segmentos de menor dimensão a partir de várias *wavelets* que são geradas a partir de uma “*wavelet mãe*”. As *wavelets*, são uma forma de onda oscilatória que possui valor médio igual a zero. Um exemplo, apresenta-se na imagem 3.3.




Figura 3.3: *Wavelet Morlet*.

Ao contrário da transformada de *Fourier* de tempo curto, que apresenta uma resolução fixa no domínio do tempo e da frequência, a TW permite fazer a análise do sinal através de janelas de tamanho variável. Com esta abordagem, em situações em que é necessário uma análise das componentes de baixa frequência do sinal de uma forma mais precisa, aumenta-se o tamanho da janela e quando se quer analisar as componentes de alta frequência, diminui-se a janela [27]. Na figura 3.4, apresenta-se uma comparação entre os domínios de análise da transformada de tempo curto de *Fourier* e da TW.




Figura 3.4: Comparação entre a resolução da transformada de *Fourier* de tempo curto e da transformada de *wavelet*.

Da figura, observa-se que, ao contrário da transformada de *Fourier* de tempo curto, que apresenta uma região tempo-frequência, na transformada de *wavelet* a resolução depende da escala utilizada [28]. Quando aumentamos a resolução no domínio do tempo, perdemos precisão na escala da frequência e vice-versa.

3.1.1 Transformada de *wavelet* contínua

A TW na sua forma contínua é dada por 3.1.

$$TWC(a, b) = \int_{-\infty}^{+\infty} x(t) \psi_{a,b}^*(t) dt \quad (3.1)$$

Com $\psi(t)$ a ser calculado por 3.2.

$$\psi_{a,b}(t) = |a|^{-\frac{1}{2}} \psi\left(\frac{t-b}{a}\right) \quad (3.2)$$

O termo $\psi(t)$ representa a *wavelet* mãe, que será selecionada de acordo com o problema que se pretende resolver. O termo a , é o termo de escalamento da transformada. Ao diminuir-se o seu valor, a *wavelet* ficará com um aspeto mais “encolhido”, o que a habilitará a captar frequências mais elevadas no sinal. O contrário acontecerá se se aumentar o seu valor. Nesse caso, a onda ficará mais larga, estando assim mais recetiva a variações do sinal em baixa frequência [29]. Quanto ao parâmetro b , este representa o parâmetro de deslocamento do sinal, na medida em que, ao mudarmos o seu valor, estamos a mover o centro da forma de onda para a esquerda ou para a direita no domínio do tempo. O efeito destas variáveis sobre a *wavelet* mãe está ilustrado na figura 3.5.




Figura 3.5: *Wavelet Morlet* para diferentes valores de escalamento (identificado como “a”) e de deslocamento (identificado como “b”).

3.1.2 Transformada de *wavelet* discreta

A transformada de *wavelet* contínua, para além de exigir um maior tempo de processamento, é redundante. A sua versão discreta, constitui um método mais eficiente para se analisar o sinal. O seu cálculo é feito através da expressão 3.3.

$$TWD(m, n) = a_0^{-\frac{m}{2}} \left(\sum x[k] \psi^*[(k - na_0^m b_0)/a_0^m] \right) \quad (3.3)$$

Este cálculo de uma forma discreta é conseguido fazendo $a = a_0^m$, $b = na_0 b_0$ e $t = kT$ na equação 3.1. Onde $k, m, n \in \mathbb{Z}$ e $T = 1$ [27].

Para a TWD, define-se um valor fixo para a_0 e b_0 . Para evitar a redundância falada anteriormente, tem de se escolher valores para a_0 e b_0 que façam com que as diversas *wavelets* resultantes, sejam todas ortonormais entre si, ou seja, que não haja uma correlação entre estas. No caso de haver uma correlação, a informação extraída será redundante [30].

A TWD, é, muitas vezes, implementada com uma técnica chamada decomposição de nível múltiplo (*Multiresolution Analysis*) que consiste em se aplicar um banco de filtros passa-baixo e passa-alto ao sinal. O que acontece, é que o sinal é processado nesses filtros e ocorre uma redução para metade do seu número de amostras. Depois de se processar o sinal no filtro passa-alto, obtém-se os chamados coeficientes de detalhe, enquanto que à saída do filtro passa-baixo, tem-se os coeficientes de aproximação. À primeira passagem do sinal pelos filtros chama-se primeiro nível de decomposição do sinal e assim sucessivamente. Na figura 3.6, está apresentado o esquema da técnica de decomposição de

nível múltiplo. Se o sinal for amostrado a uma frequência de 100 kHz, os coeficientes de aproximação do primeiro nível irão conter as componentes do sinal entre 0 - 50 kHz e os coeficientes de detalhe, as componentes entre 50 - 100 kHz. No segundo nível de decomposição, os coeficientes de aproximação vão ser calculados para os componentes entre 0 - 25 kHz e os de detalhe entre 25 - 50 kHz.

Com o uso desta técnica, consegue-se analisar o sinal em diferentes escalas de tempo e de frequência.




Figura 3.6: Decomposição de nível múltiplo para um sinal com frequência de amostragem de 100 kHz, em que os coeficientes de detalhe estão representados pela letra D e os de aproximação pela letra A (adaptado de [7]).

A TWD implementada através da técnica de decomposição de nível múltiplo, foi a técnica utilizada para se segmentar os sinais de defeito. A aplicação desta metodologia irá ser feita no capítulo seguinte.

3.2 Classificação: Redes Neurais Artificiais

Serão agora apresentados alguns dos fundamentos básicos das RNAs, visto que foi a técnica usada para se classificar os sinais de defeito que foram gerados.

As Redes Neurais Artificiais, como foi referido no capítulo anterior, são redes computacionais inspiradas no funcionamento biológico do sistema nervoso humano ou animal. São constituídas por uma estrutura composta por neurónios artificiais com ligações entre si que possuem capacidade de aprendizagem.

3.2.1 Introdução

Devido à sua inspiração no sistema nervoso, será agora apresentada uma breve descrição dos neurónios biológicos com o intuito de dar a entender que elementos e características se tentaram replicar para as RNAs.

Os neurónios biológicos, são células responsáveis pela transmissão dos impulsos nervosos. Estima-se que o cérebro humano seja constituído por, aproximadamente, 100 bilhões de neurónios que comunicam entre si [31]. A estrutura formada por estes neurónios é extremamente complexa, processa rapidamente a informação e funciona em paralelo. Estas características fazem com que os engenheiros olhem para a neurobiologia com o objetivo de chegarem a novas ideias para resolverem problemas complexos [32].

Os estímulos elétricos entre neurónios, são transmitidos através do axónio de um neurónio para as dendrites de um outro neurónio, que são responsáveis por receber essa informação e fazer a sua posterior condução até ao corpo celular. O ponto de contacto entre as dendrites e os axónios, é chamado de sinapse [33]. Na figura 3.8 apresenta-se a estrutura de um neurónio biológico.




Figura 3.7: Constituintes de um neurónio biológico.

As conexões entre os neurónios, podem ser formadas por dois tipos de sinapses distintas [34]:

- Inibitórias;
- Excitatórias.

As conexões inibitórias previnem o neurónio de gerar um estímulo elétrico, bloqueando a transmissão do sinal, enquanto que as conexões excitatórias têm o efeito oposto. Os neurónios podem ainda, ter entre si uma maior ou menor influência.

Olhando para a imagem 3.8, que representa um neurónio artificial, é possível identificar alguns elementos análogos ao neurónio biológico. O elemento central dessa figura é o neurónio artificial, ao qual são estabelecidas várias ligações que condicionam a informação que este irá transmitir aos outros neurónios da RNA.

3.2.2 O neurónio artificial

As RNAs são compostas por um conjunto de neurónios artificiais ligados entre si que apresentam a constituição representada na figura 3.8. A partir deste ponto da dissertação, sempre que se falar de um neurónio, está-se a referir aos neurónios artificiais das RNAs.




Figura 3.8: Modelo de um neurónio [32].

Cada neurónio artificial, apresenta na sua constituição vários sinais de entrada ligados a si por determinados pesos. Esses pesos representam a influência de certa ligação sobre o neurónio. Se um neurónio estiver ligado a outro, com um peso de valor alto e positivo, essa ligação terá uma influência grande sobre o neurónio que recebe o sinal e o contrário acontece se o valor do peso for baixo e positivo. Há ainda a hipótese de o peso ter valor negativo e, nesse caso, essa ligação tem um efeito inibitório.

A saída de cada neurónio artificial é calculada fazendo-se a soma de cada uma das suas ligações de entrada mais a adição de um *bias* que é responsável por aumentar ou diminuir o valor final da soma resultante das diferentes ligações.

O resultado obtido é, após essas operações, submetido a uma função de ativação que tem como objetivo condicionar o sinal de saída, através da aplicação de determinada expressão.

Analiticamente, tem-se que os cálculos necessários para se obter o valor final de um neurónio k são dados pelas equações 3.4 e 3.5 [32].

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (3.4)$$

$$y_k = \varphi(u_k + b_k) \quad (3.5)$$

Onde $x_1, x_2, \dots, x_m$ são os sinais de entrada e $w_{k1}, w_{k2}, \dots, w_{km}$ são os pesos correspondentes às ligações entre o neurónio e os sinais de entrada. Já b_k representa o *bias* e $\varphi(\cdot)$ a função de ativação. O valor final da saída do neurónio k é dado por y_k . O que cada uma destas variáveis representa, é aplicável à figura 3.8.

Relativamente às funções de ativação, na tabela 3.1 estão descritas equações de algumas funções e respetivos contradomínios.

Tabela 3.1: Funções de ativação (adaptado de [34]).

Nome	Função f	Contradomínio
Limiar	$f(x) = \begin{cases} 0 & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$	$\{0, 1\}$
Linear	$f(x) = x$	$] -\infty, +\infty[$
Sigmóide	$f(x) = \frac{1}{1+e^{-x}}$	$[0, 1]$
Tangente Hiperbólica	$f(x) = \tanh(x)$	$[-1, 1]$

De salientar a função Sigmóide que é amplamente utilizada. Esta função tende a aproximar os valores que recebe como entrada a um dos seus extremos, o que é uma característica bastante desejável para se classificar diferentes dados.

3.2.3 Arquiteturas das RNAs

Designa-se por arquitetura da rede, a maneira como os neurónios artificiais se ligam entre si. De uma forma geral, pode-se categorizar os tipos de arquiteturas em três classes diferentes:

1. **Redes diretas de uma só camada:** Este tipo de redes são as que apresentam uma constituição mais simples. Os dados fornecidos à rede, que são passados na camada de entrada, são diretamente direcionados para a camada de saída. Neste tipo de arquitetura, os dados fluem sempre da entrada para a saída. Na figura 3.9 está apresentado um exemplo, cuja camada de entrada e a camada de saída são constituídas por três neurónios.




Figura 3.9: Rede direta de uma só camada.

2. **Redes diretas multicamada:** As redes diretas multicamada, diferem das anteriores, uma vez que a camada de entrada não está diretamente ligada à camada de saída. Entre estas encontra-se, pelo menos, uma camada intermédia chamada de camada escondida (do inglês *hidden layer*). A introdução destas camadas tem como objetivo aumentar a capacidade da rede em modelar funções que apresentem uma maior complexidade. Têm a desvantagem da sua introdução aumentar exponencialmente a fase de aprendizagem da rede [34]. À semelhança das redes anteriores, o fluxo de dados também é sempre da entrada para a saída. Na imagem 3.10, está presente uma rede com uma configuração 3-3-2: 3 neurónios de entrada, 3 neurónios na camada escondida e 2 neurónios na camada de saída.




Figura 3.10: Rede direta multicamada.

3. **Redes recorrentes:** Neste tipo de redes, a propagação de informação não é feita de uma forma exclusivamente direta (da entrada para a saída) e apresentam, pelo menos, um ciclo de realimentação, ou seja, há pelo menos um neurónio cuja saída influencia a sua entrada, quer de uma forma direta ou passando primeiramente por outros neurónios. Um exemplo deste tipo de rede está na figura 3.11.




Figura 3.11: Rede recorrente [33].

A rede utilizada neste trabalho, foi uma rede direta multicamada visto que permite a resolução de problemas mais complexos, comparando com as rede diretas de uma só camada e para aplicações relacionadas com a classificação dos defeitos, nos trabalhos anteriores presentes na literatura, não são usadas redes recorrentes.

3.2.4 Processos de aprendizagem das RNAs

O processo de aprendizagem da rede, diz respeito à fase em que lhe são fornecidos os dados de treino e ocorre um ajuste dos seus parâmetros, nomeadamente os pesos entre as ligações, de forma a otimizar o seu desempenho. A forma com que este processo ocorre, pode ser de três tipos: através de aprendizagem supervisionada, de aprendizagem de reforço ou de aprendizagem não supervisionada.

Na **aprendizagem supervisionada** são fornecidos à rede os dados de entrada e o valor da saída desejada para cada conjunto de dados. Diz-se que a aprendizagem da rede é feita através de um “professor”. O seu modo de funcionamento consiste em comparar a saída obtida com a saída desejada. A diferença entre ambas as saídas representa o erro da rede que se pretende diminuir ao longo do processo de treino ajustando os pesos entre as ligações.

Relativamente à **aprendizagem de reforço**, apesar de não se fornecer a resposta desejada durante a fase de treino, diz-se à rede se o resultado está correto ou não. Os pesos das ligações que originaram uma resposta assertiva são aumentados e o contrário acontece aos pesos que mais contribuíram para que o resultado obtido pela rede fosse errado.

Por fim, na **aprendizagem não supervisionada**, não é fornecido nenhum “professor” à rede e a sua aprendizagem é feita através de agrupamentos de certos padrões que estejam presentes nos dados ou através da descoberta de algumas regularidades a nível estatístico que estejam presentes [34].

De entre estes três tipos de aprendizagem, no modelo implementado no capítulo seguinte, usou-se aprendizagem supervisionada.

3.2.5 Algoritmo de Retropropagação

Durante a fase de aprendizagem (também denominada como fase de treino), o objetivo é fazer-se o ajuste dos pesos das ligações entre os neurónios.

Dos algoritmos usados para se aplicar a aprendizagem supervisionada em redes diretas multicamada, o mais usado é o algoritmo de retropropagação. Como a RNA utilizada neste trabalho tem este tipo de arquitetura e foi usada aprendizagem supervisionada, vai-se proceder à sua explicação.

O algoritmo de retropropagação, tem como objetivo diminuir a função do erro através da aplicação de métodos de gradiente descendente. A função do erro é calculada através da comparação entre os valores obtidos pelo modelo e os valores desejados. Essa função pode ser dada, por exemplo, pela expressão do erro médio quadrático, do erro absoluto, etc.

Este algoritmo é dividido em duas fases:

- Direta;
- Retropropagação.

Na **fase direta**, os dados de entrada são fornecidos à rede e são calculados os valores de saída de todos os neurónios de todas as camadas. Os valores de cada neurónio nas camadas escondidas são preservados uma vez que vão ser necessários na fase seguinte do algoritmo. Comparando o valor desejado para a saída com o valor obtido, é calculado o erro da saída através da função de erro. Na **fase de retropropagação**, o algoritmo mede a contribuição que cada ligação de saída teve para o erro final. No fim de se saber a influência de cada uma das ligações de saída, é feito o mesmo cálculo para as camadas anteriores até se chegar à camada de entrada. Este cálculo é efetuado através da retropropagação do gradiente do erro, daí o nome atribuído ao algoritmo [35]. Por fim, os pesos entre as ligações são ajustados com o intuito da função global do sistema se aproximar de um mínimo global ou local. Este processo é cíclico e termina quando se atingir o critério de paragem pré-estabelecido.

3.2.6 Critério de paragem da fase de treino

Através do algoritmo de retropropagação, o erro da rede durante a fase de treino, vai diminuindo.

Antes de se efetuar essa fase de treino, é necessário pré-estabelecer um critério de paragem, ou seja, estabelecer quando se irá terminar a fase de aprendizagem da rede. Será agora exposto, o critério de paragem usado na RNA que se elaborou nesta dissertação.

À medida que o número de épocas aumenta, o erro entre a saída obtida e a desejada vai diminuindo (entende-se por época um ciclo completo de treino, ou seja, a passagem de todos os dados de treino pela rede). Essa diminuição acontece progressivamente embora seja mais acentuada nas primeiras épocas. Se se tiver em conta apenas a diminuição do erro da RNA sobre os dados que formam o conjunto de treino e se fôr treinando a rede até que o erro pare de diminuir, pode acontecer que a rede fique sobreajustada. Uma rede sobreajustada apresenta um bom desempenho no conjunto de treino mas quando exposta a dados diferentes dos de treino, a sua *performance* degrada-se. O que acontece é que a RNA em vez de generalizar os dados recebidos, começa a aprender o seu ruído estatístico e deixa de ter a capacidade de obter bons resultados para dados diferentes [36]. Com o intuito de evitar este fenómeno é necessário estabelecer-se um critério de paragem diferente de forma a não treinar a rede durante um número de épocas que seja excessivo.

O método que foi utilizado neste trabalho é denominado por *early-stopping*. Neste método, uma percentagem dos dados do conjunto de treino passam a constituir o conjunto de validação. Com o uso desta técnica, os pesos entre as ligações do modelo vão sendo ajustados através do conjunto de treino mas periodicamente, ao final de um determinado número de épocas, é calculado o erro da rede também sobre os dados de validação.

Normalmente, comparando a curva do erro sobre o conjunto de treino e sobre o conjunto de validação, o erro do modelo sobre o conjunto de validação é superior. O erro sobre o conjunto de treino vai diminuindo ao longo do número de épocas mas, no conjunto de validação, diminui primeiramente e depois começa a aumentar a partir de uma determinada fase do treino (figura 3.12). A partir desse mínimo do erro sobre o conjunto de validação, é quando a rede começa essencialmente a aprender o ruído que está contido nos dados de treino, por isso, segundo o método de *early-stopping*, é quando se deve terminar a aprendizagem do modelo.




Figura 3.12: Gráficos do erro da RNA sobre o conjunto de treino e de validação ao longo da fase de treino [32].

3.3 Metodologia desenvolvida e implementação

A metodologia desenvolvida no trabalho, para a análise automática dos sinais de defeito, tem por base os fundamentos teóricos abordados neste capítulo e pode ser dividida em quatro fases principais: simulação de defeitos, pré-tratamento da informação dos ficheiros COMTRADE associados aos defeitos, segmentação dos sinais através da transformada de *wavelet* e classificação dos defeitos por meio de uma RNA. Na figura 3.13 apresenta-se a sequência de passos efetuados no trabalho.




Figura 3.13: Sequência de passos do trabalho desenvolvido.

Toda esta metodologia, desde a simulação de defeitos até à sua classificação final, foi conseguida através do desenvolvimento de um conjunto de *scripts* e ficheiros cuja sequência de utilização está ilustrada na figura 3.14.




Figura 3.14: Conjunto de *scripts* desenvolvidos no trabalho.

O *script* `gerador_defeitos.py` é responsável por:

- Interagir com o ficheiro `PT_grid.ecf`, que é o ficheiro que contém a modulação da RNT no *software* *HyperSim*;
- Através dessa interação gerar os defeitos sobre a rede portuguesa;
- Definir todos os parâmetros das simulações;
- Extrair os ficheiros COMTRADE de configuração e de dados com informação sobre a oscilografia dos defeitos.

O *script* `segmentacao.py` é responsável por:

- Processar a informação contida em todos os ficheiros COMTRADE gerados;
- Fazer a segmentação dos sinais de defeito;

- Calcular os dados de entrada para a RNA e passá-los ou para o ficheiro *BaseDados.csv*, onde estão os dados do conjunto de treino da rede, ou para o ficheiro *BaseDadosTeste.csv*, onde estão os dados de teste.

Por fim, o script *classificacao.py*, é responsável por:

- Realizar a fase de treino da RNA desenvolvida;
- Testar o modelo final.

A aplicação de toda esta metodologia, será descrita no capítulo seguinte.

3.4 Conclusão

Ao contrário da TF, a TW, permite analisar sinais com diferentes resoluções no domínio do tempo e da frequência, o que faz com que em certas aplicações, seja mais adequada a sua utilização. A transformada de *wavelet* na sua forma discreta, foi aplicada nesta dissertação através da técnica de decomposição de nível múltiplo. Como os sinais de defeito podem apresentar componentes não periódicas e ainda conter componentes sinusoidais e impulsos, a transformada de *wavelet* é adequada para fazer a sua análise.

As redes neuronais artificiais, são constituídas por neurónios com ligações entre si com determinados pesos. Foram analisadas as arquiteturas principais que as redes neuronais podem ter e também os diferentes tipos de aprendizagem. As RNAs diretas multicamada com aprendizagem supervisionada, normalmente, usam o algoritmo de retropropagação durante a fase de treino para ajustar os pesos entre as ligações da rede. Antes de se efetuar esse treino é preciso pré-estabelecer um critério de paragem do mesmo. Na RNA que foi implementada no capítulo seguinte, utilizou-se um método denominado por *early-stopping*.

A metodologia efetuada neste trabalho, com o propósito de efetuar a análise automática de sinais de defeito, tem por base os fundamentos teóricos da transformada de *wavelet* e das redes neuronais apresentados e, foi implementada através de um conjunto de *scripts* aplicados em sequência desde a simulação dos sinais de defeito até à sua classificação final.

Aplicação e resultados

Neste capítulo é efetuada a aplicação dos métodos que visam a análise automática dos sinais de defeito. O capítulo inicia-se com a descrição dos cenários topológicos analisados e simulados e, de seguida, demonstra-se as aplicações efetuadas com o propósito de segmentar e classificar os sinais de defeito. São ainda expostos os resultados obtidos.

4.1 Cenários topológicos

Através do modelo da RNT disponibilizado no *software HyperSim*, gerou-se as formas de onda das correntes e das tensões nas três fases para diversas situações de defeito em várias linhas de transmissão da rede portuguesa. O objetivo é fazer-se posteriormente a extração automática dos ficheiros COMTRADE que contêm os dados associados a esses defeitos. Esta primeira fase é bastante importante para o trabalho subsequente na medida em que se pretende gerar uma diversidade de cenários topológicos e operacionais de forma a testar a aplicabilidade dos métodos de segmentação e classificação dos defeitos numa maior diversidade de condições. Os cenários topológicos e operacionais dizem respeito a linhas com diferentes capacidades térmicas, localizadas em diferentes zonas de Portugal, com níveis de tensão distintos (150 kV, 220 kV e 400 kV) e também com vários comprimentos. Posto isto, selecionaram-se 12 linhas de norte a sul do país, sobre as quais, se geraram os defeitos. As linhas selecionadas estão indicadas na tabela 4.1, assim como, as suas principais características. No anexo I, podem ser consultadas as características dessas linhas de uma forma mais detalhada.

Apresenta-se ainda, na figura 4.1, a localização aproximada de cada uma das linhas no mapa da RNT portuguesa retirado do site da Rede Elétrica Nacional, S.A. (REN), assim como, o seu nível de tensão.

Tabela 4.1: Características das linhas selecionadas [37].

Barramento inicial	Barramento final	Tensão (kV)	Comprimento (km)	Capacidade térmica máxima de projeto (MVA)			
				Primavera	Verão	Outono	Inverno
Carrapateiro	Estarreja 3	220	50,9	941	897	982	1021
Carregado	Rio Maior 1	220	40,2	400	382	418	435
Carvoeira	Trajouce	220	46	400	382	418	435
Fernão Ferro	Ribatejo	400	83,9	1386	1321	1386	1386
Ferreira do Alentejo	Ourique	150	44,5	186	164	196	206
Ferreira do Alentejo	Sines	400	59,4	1386	1361	1386	1386
Pedralva	Vila Fria 2	150	41,7	204	195	214	222
Pocinho	Chafariz	220	61,9	364	333	381	381
Porto Alto	Palmela 2	150	36,5	204	191	214	222
Riba D'Ave	Oleiros	150	35,2	123	104	139	153
Sines	Portimão 3	400	97,8	1386	1386	1386	1386
Vieira do Minho	Pedralva 1	400	33	1386	1386	1386	1386




Figura 4.1: Localização aproximada de cada uma das linhas sobre as quais se simularam os defeitos, assim como, o seu nível de tensão [38].

Observa-se, da tabela 4.1, que foram escolhidas quatro linhas para cada nível de tensão com capacidades térmicas máximas entre 104 MVA e 1386 MVA e com comprimentos entre 33 km e 97,8 km. Procurou-se diversificar ao máximo estes parâmetros das linhas mas devido a limitações impostas pelo modelo das linhas usado no simulador, não foi possível simular defeitos em linhas que possuem comprimento inferior a 30 km.

Por outro lado, na figura 4.1 é perceptível que as linhas analisadas apresentam uma variabilidade considerável ao nível da sua localização.

4.1.1 Simulação de defeitos

Para se simular os defeitos sobre cada uma das linhas selecionadas, numa primeira fase, foi necessário proceder à correta modelização do troço de linha em causa. Para isso teve-se acesso ao modelo da Rede Portuguesa desenvolvido no laboratório do *R&D Nester*. A figura 4.2, demonstra como os diversos elementos da RNT de Eletricidade são modulados no *HyperSim*, neste caso na região de Lisboa, mais concretamente entre Fanhões e Alto Mira.




Figura 4.2: Modelização no *software HyperSim* da RNT, na zona de Lisboa (entre Fanhões e Alto Mira).

Em relação a cada uma das linhas procederam-se a alterações no modelo de forma a este estar adaptado para o objetivo pretendido. Foram acrescentados disjuntores em ambas as suas extremidades de forma a se conseguir simular o comportamento real desses disjuntores em caso de defeito.

Para cada uma das simulações, escolheu-se o tipo de defeito (entre a fase A e a terra, entre a fase B e a terra, etc.) assim como o número de simulações e foi selecionada uma linha aleatoriamente. Só foram simulados defeitos à terra, ou seja: defeitos A-T, B-T, C-T, A-B-T, A-C-T, B-C-T e A-B-C-T. Em cada simulação fez-se variar, também de uma forma aleatória, a resistência do defeito, a localização do defeito ao longo do troço da linha e os tempos do seu começo, do fim, e de abertura e fecho dos disjuntores. A tabela 4.2 contém os valores máximos e mínimos de cada variável e também a variação entre cada valor.

Tabela 4.2: Valores mínimos e máximos de cada variável das simulações.

Parâmetro	Valor mínimo	Valor máximo	Variação entre cada valor
Início do defeito	0,1s	0,3s	0,01s
Abertura do disjuntor	início do defeito + 0,04s	início do defeito + 0,06s	0,001s
Fim do defeito	fecho do disjuntor - 0,06s	fecho do disjuntor - 0,04s	0,001s
Fecho do disjuntor	abertura do disjuntor + 0,9s	abertura do disjuntor + 0,9s	sem variação
Localização do defeito	40% do comprimento da linha	60% do comprimento da linha	10% do comprimento da linha
Resistência do defeito	2 Ω	20 Ω	1 Ω

O valor de certas variáveis, foi calculado a partir do valor de uma outra, por exemplo, o momento do fim do defeito dá-se entre 0,06 s e 0,04 s antes do fecho do disjuntor.

A razão de se ter simulado defeitos apenas entre 40% e 60% do comprimento da linha tem a ver, mais uma vez, com limitações impostas pelo modelo das linhas usado no simulador.

A extração dos ficheiros COMTRADE associados à oscilografia obtida nas simulações foi feita automaticamente.

4.1.2 Interpretação da informação contida na oscilografia

Extraídos os ficheiros COMTRADE associados aos diferentes defeitos simulados, foi necessário ler e interpretar de forma correta a informação neles contida. A cada um dos defeitos estão associados dois ficheiros: um ficheiro COMTRADE de configuração e um de dados.

O ficheiro de configuração, entre outros aspetos, dá informação sobre quais as variáveis cuja oscilografia está descrita no ficheiro de dados. Uma descrição completa do significado de cada um dos campos presentes nos ficheiros de configuração que foram gerados, pode ser consultada no anexo II. Aqui serão mencionados os aspetos mais importantes contidos nestes ficheiros com o intuito de processar a sua informação. Na figura 4.3 está um exemplo de um destes ficheiros e também a indicação de onde se situam os seus principais campos, enquanto que a tabela 4.3 indica o que esses campos representam. Cada uma das linhas contidas no retângulo da figura 4.3 diz respeito a um canal. Os canais gravados foram as correntes e tensões das três fases da linha sobre a qual se simulou o defeito.




Figura 4.3: Principais informações contidas no ficheiro COMTRADE de configuração.

Tabela 4.3: Significado dos campos usados para se processar a informação.

Abreviação	Informação sobre o canal
<i>An</i>	Índice do canal analógico
<i>can_id</i>	Identificador do canal
<i>uu</i>	Unidades do canal
<i>a</i>	Multiplicador do canal
<i>b</i>	Offset do canal

Através de *An*, sabe-se a posição em que a informação sobre a oscilografia da variável identificada pelo *can_id* se encontra no ficheiro COMTRADE de dados. Como a primeira coluna no ficheiro de dados diz respeito ao número da amostra e a segunda coluna ao instante temporal dessa amostra, os dados de cada um dos canais são expostos a partir da coluna 3. Na tabela 4.4, está um exemplo da informação contida no ficheiro de dados. Este tipo de ficheiros é separado por vírgulas e não tem qualquer tipo de informação sobre o que representa cada coluna. Para se ter um melhor entendimento da informação presente num ficheiro deste tipo, nessa tabela está um exemplo em que se mostram as 10 primeiras linhas de um ficheiro de dados acompanhado pela descrição da informação presente em cada coluna.

Tabela 4.4: Informação dos canais contida no ficheiro de dados.

Nº amostra	Tempo (μs)	Índice dos canais analógicos (An)					
		1	2	3	4	5	6
1	0	-7353	14891	29602	10933	3876	-29234
2	50	-7312	14563	29719	10679	4287	-29383
3	100	-7269	14235	29830	10422	4697	-29524
4	150	-7224	13905	29934	10160	5105	-29658
5	200	-7177	13574	30032	9894	5510	-29785
6	250	-7128	13243	30123	9623	5913	-29905
7	300	-7078	12910	30208	9349	6314	-30016
8	350	-7026	12577	30286	9071	6712	-30121
9	400	-6972	12243	30358	8788	7108	-30217
10	450	-6917	11908	30423	8502	7502	-30307

Para se obter o valor real dos dados, tem de se usar a expressão 4.1.

$$Vr = a \times x + b \quad (4.1)$$

Em que Vr é o valor real da variável que se quer obter, a o multiplicador do canal, x o valor presente no ficheiro de dados e b o *offset*. Os valores de a e de b são os indicados no ficheiro de configuração, na linha do An correspondente. Ao se multiplicar todos os valores da coluna do ficheiro de dados pelo a respetivo e se somar b , obtém-se a evolução temporal do canal. Por exemplo, se se quiser obter o valor da variável com índice analógico $An = 1$ no instante temporal $t = 0 \mu s$, faz-se a seguinte operação:

$$Vr = 0,202287 \times (-7353) - 42,310303$$

Este procedimento foi feito para cada um dos canais em estudo (tensões e correntes nas três fases) para cada instante de tempo. A partir dos valores reais de cada um dos canais gravados, elaborou-se a segmentação do sinal.

4.2 Segmentação dos sinais de defeito

Através dos ficheiros COMTRADE, retirou-se a informação sobre a evolução temporal dos sinais. Para se efetuar a segmentação dos sinais defeituosos usou-se a TWD, implementada com a técnica de decomposição de nível múltiplo abordada no capítulo 3 e teve-se como base, o trabalho desenvolvido no artigo [27].

Quando se faz este tipo de análise, com recurso à TWD, há um conjunto de informações que precisam de ser especificadas [39]:

- A frequência de amostragem;
- O comprimento da janela usada (em termos de tempo);
- O nível de decomposição;
- A *wavelet* mãe.

Os sinais foram amostrados a uma frequência de 20 kHz e usou-se uma janela com um comprimento fixo de 1,5 s para todos os defeitos. Fez-se o cálculo dos coeficientes de detalhe dos sinais das correntes e das tensões das três fases para o primeiro nível de decomposição e foi usada como *wavelet* mãe a *daubechies 4*. Optou-se pela *daubechies 4* uma vez que é considerada a que apresenta melhores resultados no campo da segmentação dos sinais de defeito [8].

Nas figuras 4.4 e 4.5, estão demonstrados o módulo dos coeficientes de detalhe calculados no caso de um defeito A-T para a corrente e tensão da fase A e também os respectivos sinais originais. A diferença entre o número de amostras entre os gráficos dos sinais originais e os gráficos dos coeficientes de detalhe, tem a ver com a aplicação da técnica de decomposição de nível múltiplo, em que o número de coeficientes de detalhe calculados para o primeiro nível de decomposição corresponde a metade do número de amostras do sinal original.




Figura 4.4: Sinal original e coeficientes de detalhe para a corrente da fase A no caso de um defeito A-T.




Figura 4.5: Sinal original e coeficientes de detalhe para a tensão da fase A no caso de um defeito A-T.

Depois de obtidos os coeficientes de detalhe para o primeiro nível de decomposição do sinal, utilizou-se o *threshold* de *Donoho* e *Johnstone*, calculado através da equação 4.2.

$$T = \sigma \sqrt{2 \cdot \log_e n} \quad (4.2)$$

Em que σ é o desvio padrão dos coeficientes e n o número de coeficientes calculados. Este *threshold* define uma linha horizontal ao longo dos coeficientes de detalhe em que apenas os que possuem um valor mais elevado se encontram acima dessa reta. Como os coeficientes com um valor elevado representam uma mudança maior em relação à média do sinal, os pontos acima do *threshold* dizem respeito aos coeficientes que representam os instantes temporais possíveis de mudanças abruptas no sinal, que significam os eventos de início do defeito, de abertura dos disjuntores ou de restabelecimento do circuito. No fim de calculado o seu valor, o *threshold* foi traçado sobre os gráficos das tensões e das correntes (figura 4.6).




Figura 4.6: Gráficos dos coeficientes de detalhe no fim de ser definido o *threshold* (traçado a verde).

Os coeficientes de detalhe que se encontram acima do *threshold* definido são os coeficientes indicativos de cada um dos três eventos que se visam determinar. Na figura 4.7, indica-se a zona no eixo das abcissas em que esses coeficientes superam o *threshold* através de círculos a vermelho. O primeiro círculo é indicativo do instante de começo do defeito, o segundo do instante de abertura dos disjuntores e o terceiro do restabelecimento do circuito.




Figura 4.7: Zonas dos gráficos em que os coeficientes de detalhe superam o *threshold* (indicadas pelos círculos a vermelho): 1º- começo do defeito; 2º- abertura dos disjuntores; 3º- restabelecimento do circuito.

Determinados os instantes de mudanças abruptas do sinal, obteve-se a sua segmentação final, presente na figura 4.8, onde se expõe a segmentação efetuada num defeito A-T para a corrente e tensão da fase A dos sinais apresentados anteriormente nas imagens 4.4 e 4.5. No anexo III, podem ser consultados os sinais das correntes e das tensões das restantes fases para este caso.




Figura 4.8: Resultado final da segmentação do sinal para a corrente e tensão da fase A num defeito A-T.

Estes três eventos permitiram dividir o sinal em quatro segmentos: o segmento A que corresponde à fase de pré-defeito, o segmento B que vai desde o começo do defeito até à abertura física dos contactos dos disjuntores, o segmento C que diz respeito aos instantes em que os contactos dos disjuntores se encontram abertos e o segmento D que começa no instante de restabelecimento do circuito [27]. Cada um destes segmentos, está apresentado na figura 4.9.




Figura 4.9: Segmentos constituintes do sinal.

A análise descrita até aqui, foi efetuada para as tensões e correntes das três fases das linhas de transmissão o que causou, em certas situações, a seleção de coeficientes que representam instantes temporais diferentes. Por exemplo, o instante de abertura dos disjuntores determinado na oscilografia da corrente da fase A, pode não ser o mesmo determinado na oscilografia da corrente da fase B. Por isso, calculou-se a moda entre os instantes obtidos para cada um dos sinais.

Para se obter o instante em segundos em que ocorreu cada um dos eventos tem de se multiplicar o número da amostra em que esse instante aconteceu pelo período de amostragem. Os instantes determinados, em função do tempo, para os sinais da figura 4.8 estão apresentados na tabela 4.5.

Tabela 4.5: Instante temporal em que ocorreram cada um dos eventos dos sinais da figura 4.8.

Evento	Nº amostra	Instante temporal (s)
Começo do defeito	2020	0,101
Abertura dos contactos dos disjuntores	2990	0,1495
Restabelecimento do circuito	20980	1,049

Subtraindo o instante de começo do defeito pelo instante da abertura dos contactos dos disjuntores, obtém-se o tempo total que o defeito esteve a atuar sobre a rede que neste caso foi de 48,5ms.

Com o uso da metodologia descrita, em 737 defeitos gerados, 12 não se conseguiram segmentar, correspondendo a uma taxa de sucesso de aproximadamente 98,5%.

4.2.1 Processamento adicional

Para alguns dos defeitos simulados, em certos sinais, foi necessário fazer um processamento adicional da sua oscilografia com o intuito de efetuar a segmentação de forma correta. Vão agora ser explicados os três casos em que isso aconteceu.

4.2.1.1 Caso I: Sinais sem os três eventos determinados

Como foi referido anteriormente, o processo descrito para se efetuar a segmentação dos sinais de defeito, foi feito para os sinais das correntes e das tensões das três fases. O que pode levar a que, em alguns desses seis sinais, sejam identificados menos do que três eventos possíveis. Isso deve-se ou ao facto de os sinais não terem mudanças abruptas acentuadas ou por essas mudanças estarem abaixo do *threshold*. Nesses casos, os resultados obtidos para esse sinal em específico não foram considerados e a moda entre os instantes foi efetuada apenas para os sinais que têm os três instantes definidos. Na figura 4.10 está um exemplo disso mesmo. À esquerda estão os coeficientes de detalhe com os instantes determinados e à direita o sinal original. Neste defeito do tipo A-T, na corrente da fase C, só está um instante definido. Neste caso o instante calculado para essa variável não foi considerado e usou-se apenas os restantes instantes das outras variáveis. Essa avaliação também foi feita para as correntes culminando em três eventos comuns para as seis variáveis.

Normalmente, as fases defeituosas, por possuírem sinais com mudanças abruptas mais acentuadas, têm os três instantes definidos e as restantes podem ou não tê-los. Como na fase de segmentação não se tem informação sobre o tipo de defeito, teve-se de procurar os três eventos em todas as fases.




Figura 4.10: Coeficientes de detalhe para as correntes das três fases e respectivos sinais originais num defeito em que na corrente da fase C não se determinou os três eventos do sinal.

4.2.1.2 Caso II: Seleção dos coeficientes corretos

Muitas vezes, mais que um coeficiente superou o *threshold* definido, dizendo respeito ao mesmo evento que ocorreu no sinal. Na imagem 4.11, está descrito o processo efetuado neste tipo de situações. O gráfico superior da imagem é o mesmo da figura 4.6 onde se apresentou os coeficientes de detalhe calculados para a oscilografia do sinal da corrente da fase A demonstrado na figura 4.4. A diferença é que neste novo gráfico, cada um dos coeficientes de detalhe calculados está representado por um ponto para se perceber melhor esta situação. Por exemplo, no instante de restabelecimento do circuito há um conjunto de pontos muito próximos uns dos outros, acima do *threshold*, todos indicadores desse evento (esses coeficientes estão dentro do círculo a vermelho presente no gráfico). Aqui surge o problema de selecionar qual o coeficiente indicador do evento, visto que, existem vários acima do *threshold* definido.

Em [8] usou-se uma técnica em que se agregavam um certo número de amostras seguidas, fazendo a soma dos seus coeficientes e armazenando o ponto médio, reduzindo-se assim o número de pontos possíveis. No desenvolvimento efetuado, aplicou-se uma técnica similar mas em vez de se agruparem os coeficientes, definiu-se um tempo limite de proximidade entre os instantes de mudanças abruptas no sinal que se pretendem determinar, ou seja, coeficientes que excedam o *threshold* mas que estejam dentro de um limite de proximidade, correspondem ao mesmo evento. Assim, deu-se um tempo reduzido para a estabilização do sinal e definiu-se como indicador do evento, o primeiro coeficiente que superou o *threshold*. Foi definida uma tolerância no número de amostras equivalente a 20 *ms* no domínio do tempo entre cada um dos eventos.

Na figura 4.11, no gráfico onde se faz uma aproximação dos coeficientes de detalhe na zona de restabelecimento do circuito, consegue-se identificar qual o primeiro ponto acima do *threshold*. Esse ponto, diz respeito ao coeficiente definido como identificador do instante. A seleção do coeficiente correto está exposta no último gráfico da imagem.



Figura 4.11: Processo efetuado quando se obteve múltiplos coeficientes acima do *threshold* definido dizendo respeito ao mesmo evento no sinal.

4.2.1.3 Caso III: Influência do nível de decomposição

Para certos defeitos simulados, em nenhum dos sinais das correntes e das tensões se conseguiu encontrar os três eventos pretendidos. Nesses casos, foi feita a segmentação do sinal através do nível 2 de decomposição da TWD e, em caso de novo insucesso, foi aplicado o nível 3 de decomposição. O processo elaborado segue o fluxograma presente na figura 4.12.




Figura 4.12: Fluxograma que descreve o processo executado para a segmentação dos sinais de defeito.

Com a utilização de diferentes níveis de decomposição, são captadas diferentes gamas de frequência do sinal pela TWD. À medida que se aumenta o nível de decomposição, as componentes capturadas pela TWD correspondem a componentes de menor frequência, o que para certos casos se revelou vantajoso. Um exemplo disso está nas imagens 4.13 e 4.14. Para este caso, num defeito A-T, para o primeiro nível de decomposição, não se conseguiu

determinar os eventos requeridos em nenhuma das fases, por isso, usou-se o segundo nível de decomposição. A figura 4.13 diz respeito ao sinal da corrente da fase A e na figura 4.14 estão os coeficientes obtidos para o primeiro e segundo níveis de decomposição do sinal. Como se pode observar, com o primeiro nível apenas se determinou coeficientes indicadores de dois eventos, enquanto que através do segundo nível estão definidos os coeficientes referentes aos três instantes.




Figura 4.13: Exemplo de um sinal em que não se conseguiu efetuar a segmentação através do nível 1 de decomposição.




Figura 4.14: Decomposição do sinal da figura 4.13 para o primeiro e segundo níveis.

A percentagem de utilização de cada um dos níveis apresenta-se na tabela 4.6. Grande parte da segmentação dos vários sinais gerados foi conseguida através do primeiro nível de decomposição mas com esta abordagem, analisaram-se corretamente mais oito sinais.

O quarto nível de decomposição não foi usado porque já incluía componentes de frequência demasiado baixas que não se adequavam ao problema.

Tabela 4.6: Percentagem de utilização de cada um dos níveis da TWD.

Nível de decomposição	Sinais segmentados	Percentagem
1	717	98,9%
2	6	0,8%
3	2	0,3%

4.3 Classificação dos sinais de defeito

A classificação dos sinais de defeito foi alcançada mediante a aplicação de uma RNA implementada através do *TensorFlow*, que é uma plataforma aberta para *machine learning* que permite criar e desenvolver redes neurais. A RNA foi codificada fazendo o uso da API do *TensorFlow* em *Python*. Aplicou-se uma rede direta multicamada cujo treino foi feito através de aprendizagem supervisionada.

4.3.1 Conjuntos de treino e de teste

O primeiro passo para a construção da rede neuronal no trabalho consistiu em definir os seus conjuntos de treino e de teste. Estes conjuntos são formados pelos defeitos simulados nas linhas apresentadas no início do capítulo. Das 12 linhas selecionadas, definiram-se 10 linhas para se simular os defeitos que constituem o conjunto de treino e duas linhas diferentes para se formar o conjunto de teste. Com esta abordagem, testou-se o modelo em linhas que não lhe foram apresentadas na fase de treino. Nesta divisão, teve-se como objetivo diversificar o conjunto de treino da rede, para o modelo desenvolvido ser aplicável na maior diversidade de cenários possível. Nas tabelas 4.7 e 4.8 estão indicadas as linhas sobre as quais se simularam os defeitos do conjunto de treino e as linhas usadas para o conjunto de teste.

Tabela 4.7: Linhas sobre as quais se simularam os defeitos para o conjunto de treino.

Linhas para o conjunto de treino	
Barramento inicial	Barramento final
Carrapatelo	Estarreja 3
Carregado	Rio Maior 1
Ferreira do Alentejo	Ourique
Pedralva	Vila Fria 2
Pocinho	Chafariz
Porto Alto	Palmela 2
Riba D'Ave	Oleiros
Sines	Portimão 3
Vieira do Minho	Pedralva 1

Tabela 4.8: Linhas sobre as quais se simularam os defeitos para o conjunto de teste.

Linhas para o conjunto de teste	
Barramento inicial	Barramento final
Carvoeira	Trajouce 3
Fernão Ferro	Ribatejo

O conjunto de treino é formado por exatamente 90 defeitos de cada tipo, que dá um total de 630 defeitos e o conjunto de teste tem um total de 95 defeitos simulados sobre as linhas da tabela 4.8.

4.3.2 Camadas de entrada e de saída

Formados os conjuntos de treino e de teste, decidiu-se quais os dados que se iriam passar como entrada para a RNA.

Devido às mudanças de amplitude que ocorrem nas fases defeituosas aquando do início da falha, quer nos sinais das correntes quer nos sinais das tensões, optou-se por se calcular o valor eficaz em três segmentos de cada um dos sinais: no segmento de pré-defeito, no de defeito e no segmento em que os disjuntores se encontram abertos. O que dá um total de 18 dados de entrada (porque se calculou o valor eficaz em 3 segmentos de cada um dos 6 sinais).

Estes segmentos estão identificados na figura 4.15 através das letras A, B e C, respetivamente.




Figura 4.15: Segmentos do sinal que constituem os dados de entrada da RNA.

Optou-se por se usar também o segmento C, pois a forma como é extinguindo o arco elétrico em fases defeituosas e não defeituosas poderia acrescentar uma informação adicional ao modelo que o ajudasse a classificar o defeito com maior exatidão.

Antes de ser calculado o valor eficaz nesses segmentos, fez-se um pré-tratamento dos sinais efetuando a sua normalização com a técnica *z-score*. Com esta técnica, cada um dos pontos dos gráficos passou a ter um valor calculado pela seguinte expressão:

$$Z = \frac{x - \mu}{\sigma} \quad (4.3)$$

Em que μ é a média do conjunto de dados e σ o desvio padrão. Este tipo de normalização calcula por quantos desvios padrão um certo valor está acima ou abaixo da média das amostras. A sua utilização adequa-se quando o conjunto de dados tem alguns *outliers* [40], ou seja, alguns valores consideravelmente afastados dos restantes.

Já a camada de saída, é formada por sete neurónios, cada um deles responsável por identificar determinado tipo de defeito.

O diagrama de blocos do classificador de defeitos está representado na figura 4.16. Calculou-se os valores eficazes das correntes e das tensões e obteve-se à saída o tipo de defeito. A tabela 4.9 faz a correspondência entre os neurónios ativos e o resultado final obtido.




Figura 4.16: Diagrama de blocos do classificador de defeitos (adaptado de [21]).

Tabela 4.9: Correspondência entre o neurónio ativo à saída e o tipo de defeito.

Tipo de defeito	Neurónios						
	1	2	3	4	5	6	7
A-T	1	0	0	0	0	0	0
B-T	0	1	0	0	0	0	0
C-T	0	0	1	0	0	0	0
A-B-T	0	0	0	1	0	0	0
A-C-T	0	0	0	0	1	0	0
B-C-T	0	0	0	0	0	1	0
A-B-C-T	0	0	0	0	0	0	1

4.3.3 Parâmetros do modelo

Definidas as estruturas das camadas de entrada e de saída, fez-se a seleção dos restantes parâmetros que otimizariam a *performance* da rede neuronal. Ou seja, do número de camadas escondidas, dos neurónios em cada uma dessas camadas e das funções de ativação que conduziriam o modelo a uma melhor performance.

Para a definição do espaço de procura de cada um destes parâmetros consideraram-se alguns aspetos. No que diz respeito às camadas escondidas, teve-se como base que:

1. Duas camadas escondidas são suficientes para resolver qualquer problema não linear complexo [41];
2. Um aumento desnecessário do número de camadas escondidas, aumenta o tempo de treino da rede e a sua complexidade;

Por estes motivos, fez-se variar o número de camadas escondidas apenas entre um e dois. Quanto aos neurónios de cada uma das camadas escondidas, existem uma série de regras gerais que permitiram efetuar uma estimativa sobre o número a usar [41]:

1. O número de neurónios usados nas camadas escondidas deve ser 70% do tamanho da camada de entrada. Se esse número não fôr suficiente, pode-se adicionar o número de neurónios presentes na camada de saída também (neste caso, dá um total de 13 neurónios não contabilizando os neurónios da camada de saída);
2. O número de neurónios usados deve ser menos do dobro dos usados na camada de entrada (dá um total de menos de 36 neurónios);
3. O número de neurónios nas camadas escondidas está entre o número de neurónios da camada de entrada e de saída (entre 18 e 7).

Estas considerações são feitas para o número total de neurónios do modelo. Ou seja, fazendo a soma do número presente em cada uma das camadas escondidas. Embora seja referido em [41] que estas regras gerais não são sempre verdadeiras, permitiram que fosse

obtida uma estimativa. Variou-se o número de neurónios por camada entre 5 e 10, que dá um número mínimo de 5 e máximo de 20 de neurónios nas camadas escondidas, na procura que se efetuou.

Para as funções de ativação consideraram-se a tangente hiperbólica e a sigmóide.

O espaço de procura para cada um dos parâmetros está tabulado em 4.10.

Tabela 4.10: Espaço de procura para os parâmetros da RNA.

Parâmetro	Espaço de busca
Nº de camadas escondidas	Entre 1 e 2
Nº de neurónios	Entre 5 e 10 por camada
Funções de ativação	Tanh e Sigmóide

A partir deste espaço de procura, fez-se a seleção dos parâmetros que otimizam a *performance* do modelo. O processo efetuado está exposto no fluxograma da imagem 4.17. Definiu-se um máximo de iterações de 20 e em cada uma dessas iterações foi testado um conjunto de parâmetros. No final, definiram-se como parâmetros da rede, os que obtiveram um menor *score*. O *score* contabiliza o erro médio quadrático do modelo, nos dados de validação. Normalmente, os dados de validação constituem entre 10%-20% dos dados de treino. Na rede desenvolvida usou-se 20% do conjunto de treino para formar os dados de validação.

Nesta fase, treinou-se cada uma das combinações de parâmetros apenas durante 20 épocas para diminuir o tempo de busca pelos parâmetros ideais e cada modelo testado foi simulado 5 vezes para verificar a sua robustez pois, como se sabe, o mesmo modelo vai ter resultados diferentes de simulação para simulação devido à inicialização aleatória dos pesos das ligações entre os neurónios.




Figura 4.17: Processo efetuado para a determinação dos parâmetros que otimizam a *performance* do modelo.

Os parâmetros dos modelos que obtiveram um melhor *score*, estão apresentados na figura 4.18.

```

Showing 10 best trials
<keras_tuner.engine.objective.Objective object at 0x000002543B83B970>
Trial summary
Hyperparameters:
layers: 1
units_0: 8
act_0: tanh
learning_rate: 0.001
units_1: 6
act_1: tanh
Score: 0.042041005566716194
Trial summary
Hyperparameters:
layers: 1
units_0: 6
act_0: sigmoid
learning_rate: 0.0001
units_1: 4
act_1: sigmoid
Score: 0.05094556324183941
Trial summary
Hyperparameters:
layers: 1
units_0: 9
act_0: tanh
learning_rate: 0.001
units_1: 3
act_1: tanh
Score: 0.051135700196027756

```

Figura 4.18: Constituição dos três melhores modelos obtidos durante a procura dos parâmetros que otimizam o desempenho da rede e *score* obtido por cada um.

Os parâmetros representados por cada uma das variáveis presentes na figura 4.18 estão descritos na tabela 4.11. De notar que as variáveis *units_1* e *act_1* apesar de estarem presentes nos conjuntos de parâmetros que só têm uma camada (com *layer=1*), não são usados nestes casos.

Observa-se que uma rede formada por uma camada escondida com oito neurónios cuja função de ativação é a tangente hiperbólica, obteve um *score* de 0,042 que foi o mais baixo que se alcançou e, por esse motivo, o modelo passou a apresentar esta constituição.

Tabela 4.11: Correspondência entre o nome da variável e o parâmetro representado.

Variável	Parâmetro representado
<i>layers</i>	Camadas
<i>units_0</i>	Neurónios da primeira camada
<i>act_0</i>	Função de ativação da primeira camada
<i>units_1</i>	Neurónios da segunda camada
<i>act_1</i>	Função de ativação da segunda camada

Na figura 4.19, apresenta-se a arquitetura final do modelo, constituído por uma camada escondida com 8 neurónios cuja função de ativação é a tangente hiperbólica.




Figura 4.19: Arquitetura final do modelo.

4.3.4 Fases de treino e de teste

Encontrados os parâmetros que melhor se adequam ao problema, foi feito o treino do modelo com esse conjunto de parâmetros. Foi nesta fase que se usou o critério de paragem estabelecido no capítulo anterior. A evolução do erro do modelo sobre os dados do conjunto de treino e do conjunto de validação está demonstrado na figura 4.20.




Figura 4.20: Erros obtidos pelo modelo no conjunto de treino e de validação em função do número de épocas.

A fase de treino foi parada, quando o erro médio quadrático da rede no conjunto de validação não diminuiu ao longo de 5 épocas seguidas. Neste caso, apesar de se ter definido um número máximo de 100 épocas para a fase de treino, o modelo apenas foi treinado durante 55 e gravou-se o modelo obtido na época 50, ou seja, a rede usada corresponde à primeira da sequência de 5 épocas sem melhorias do erro sobre o conjunto de validação.

Concluído o treino do modelo, passou-se para a fase de teste. Os erros do modelo final nos conjuntos de treino, de validação e de teste estão presentes na tabela 4.12.

Tabela 4.12: Erro médio quadrático do modelo final nos conjuntos de treino, validação e teste.

Conjunto	Erro médio quadrático
Treino	0,0058
Validação	0,0063
Teste	0,0063

Verifica-se que o erro médio quadrático é baixo nos três conjuntos, o que é um bom indicador da *performance* da rede. Na fase de teste, o erro médio quadrático é ligeiramente superior ao obtido no conjunto de treino, o que faz sentido visto que a rede foi exposta a dados novos.

Na figura 4.21, mostram-se as previsões feitas pela rede sobre os dados do conjunto de teste. O objetivo é que as previsões feitas pelo modelo que têm uma abcissa igual a zero, tenham uma ordenada próxima de zero e as previsões feitas pelo modelo com ordenada igual a um, devem ter um valor próximo de um. As abcissas do gráfico representam o valor objetivo e, as ordenadas, o valor obtido pelo modelo. Calculou-se também o coeficiente de correlação (R) entre os valores do conjunto de teste e os valores obtidos pelo modelo. Um coeficiente de correlação de 0 indica que os dados não estão correlacionados entre si enquanto que, um coeficiente de correlação de 1 significa que os resultados requeridos

e os obtidos estão completamente correlacionados. O valor obtido foi $R=0,974$ que está bastante próximo de 1. No anexo IV estão demonstrados os resultados do modelo para 20 defeitos FT na linha Carvoeira - Trajouce.




Figura 4.21: Resultados obtidos pelo modelo.

A distribuição do erro absoluto no conjunto de teste obtido pelo modelo está apresentado na figura 4.22. Como se pode observar, grande parte das previsões feitas pelo modelo tem um erro absoluto próximo de zero.




Figura 4.22: Distribuição do erro absoluto dos resultados obtidos pelo modelo.

Neste histograma estão registradas as diferenças entre cada uma das 7 saídas obtidas pelo modelo e o valor objetivo para os 95 defeitos que formam o conjunto de teste.

4.4 Análise dos resultados

O método descrito para a segmentação dos sinais de defeito, revelou-se robusto perante o conjunto de sinais gerados. Grande parte da segmentação efetuada sobre os sinais conseguiu-se através do nível 1 de decomposição da TWD (98,9%), contudo foram verificadas vantagens de se ter uma abordagem em que caso a segmentação não fosse conseguida através do primeiro nível, fossem aplicados o segundo e terceiro níveis para se segmentar o sinal de defeito.

No que diz respeito à classificação dos defeitos, na figura 4.21, apresentou-se os resultados obtidos nos neurónios de saída do modelo para todos os dados do conjunto de teste. No trabalho elaborado, considerou-se que todos os neurónios da camada de saída com valor igual ou superior a 0,5 seriam convertidos para o valor lógico 1 e que os neurónios abaixo desse valor passariam para o valor lógico 0. Com esta abordagem, apenas 1 defeito dos 95, foi classificado incorretamente. Na imagem 4.23, apresenta-se a conversão mencionada em que o defeito classificado incorretamente pelo modelo está circundado a amarelo.




Figura 4.23: Resultados obtidos pelo modelo e conversão para os valores lógicos 0 e 1.

Na tabela 4.13 demonstra-se as saídas obtidos pelo modelo para o defeito classificado incorretamente.

Tabela 4.13: Comparação entre o pior resultado obtido pelo modelo e o resultado esperado.

Resultados	A-T	B-T	C-T	A-B-T	A-C-T	B-C-T	A-B-C-T
Objetivo	0	0	1	0	0	0	0
Saída do modelo	0.0652795	0.118877	0.4654	-0.110666	0.409092	-0.0137259	0.0635018

Como se pode observar, o modelo teve como resultado um valor relativamente baixo à saída para o neurónio que indica que o defeito seria C-T e um valor muito parecido para o defeito bifásico A-C-T. Isto pode ter acontecido devido ao facto dos dados disponíveis para

treino da rede neuronal serem relativamente reduzidos e haver uma grande variabilidade dos parâmetros de simulação para simulação (como se demonstrou na tabela 4.2), o que pode ter levado a que este caso do conjunto de teste possa ser substancialmente diferente de todos os dados de treino.

Fez-se ainda um estudo da *performance* da rede neuronal consoante o defeito fosse FT, FFT ou FFFT. O erro médio quadrático e o erro absoluto máximo obtidos para cada um destes defeitos estão expostos na tabela 4.14.

Tabela 4.14: Erro médio quadrático e erro absoluto máximo obtido na fase de teste consoante o defeito seja FT, FFT ou FFFT.

Defeitos	Nº de defeitos	Erro médio quadrático	Erro absoluto máximo
FT	40	0,007390	0,5346
FFT	42	0,005653	0,2625
FFFT	13	0,004979	0,1968

Da tabela retira-se que os piores resultados obtidos pelo modelo aconteceram para defeitos FT.

4.5 Conclusão

Neste capítulo foi apresentada a aplicação dos métodos que visam a análise automática dos sinais de defeito.

Foram expostas as linhas de transmissão escolhidas para a análise e os seus parâmetros principais. As simulações dos defeitos são feitas em cada umas dessas linhas e indicou-se os valores máximos e mínimos para cada um dos parâmetros das simulações.

A segmentação dos sinais de defeito foi efetuada com recurso ao primeiro nível de decomposição da TWD através da técnica de decomposição de nível múltiplo mas, por vezes, teve-se de recorrer ao segundo e terceiros níveis para se segmentar corretamente o sinal.

Depois de uma procura automática pelos parâmetros que maximizavam a *performance* da RNA, chegou-se a uma rede formada por uma camada escondida com oito neurónios em que a função de ativação usada é a tangente hiperbólica. O modelo apresentou um erro médio quadrático de 0,0058 no conjunto de treino e de 0,0063 nos conjuntos de validação e de teste. O coeficiente de correlação entre os valores objetivo no conjunto de teste e os obtidos pelo modelo é de 0,974, o que indica uma forte correlação entre o tipo de defeitos do conjunto de teste e os resultados obtidos.

Da análise dos erros médios quadráticos obtidos pela rede neuronal na fase de teste, verificou-se que o erro era mais elevado para defeitos FT.

Conclusão

Neste último capítulo, são apresentadas as conclusões principais sobre o trabalho desenvolvido bem como propostas de trabalho futuro.

5.1 Conclusões

Neste trabalho, foram apresentadas duas metodologias que têm por objetivo a análise automática da oscilografia dos sinais (tensões e correntes) gerados em situações de defeitos provocados por curto-circuitos. Uma que visa a segmentação desses sinais e outra a sua classificação consoante o tipo de defeito. Os defeitos por curto-circuito analisados são de 7 tipos: A-T, B-T, C-T, A-B-T, A-C-T, B-C-T e A-B-C-T.

As metodologias baseiam-se no tratamento da oscilografia obtida a partir do modelo da RNT disponibilizado pelo *R&D Nester* no *software HyperSim*, facto que permitiu, entre outros simular uma diversidade de cenários topológicos e operacionais da rede, como seja, efetuar a variação da resistência do defeito, variar a localização onde o defeito ocorreu ao longo das linhas de transmissão e também os diversos instantes para cada um dos eventos (começo do defeito, abertura do disjuntor, etc.). Como resultado, foram simulados e analisados 725 defeitos no total, em 12 linhas de transmissão da rede portuguesa no laboratório do *R&D Nester*. Dessas simulações, foi feita a extração automática dos ficheiros de dados e de configuração no formato COMTRADE que contém a informação necessária para se analisar os defeitos.

Posteriormente ao tratamento da informação contida nos ficheiros COMTRADE, com recurso à TWD, aplicada através da técnica de decomposição de nível múltiplo efetuou-se a segmentação do sinal. De entre as técnicas que fazem a segmentação do sinal de defeito através da deteção dos seus instantes de mudanças abruptas, segundo [14], a aplicação da transformada de *wavelet* é a que origina melhores resultados, daí a sua aplicação. Depois de um estudo efetuado sobre as diversas oscilografias geradas, chegou-se à conclusão que apesar de grande parte dos sinais se conseguirem segmentar através dos coeficientes de detalhe obtidos para o primeiro nível de decomposição (98,9%), é vantajoso aplicar metodologias que caso não se tenha sucesso através deste nível, explorem outras frequências do

sinal através da aplicação de outros níveis de decomposição. Com a aplicação do segundo e terceiro níveis, em oito defeitos conseguiu-se determinar os instantes requeridos para a segmentação do sinal, que não se tinham obtido com o primeiro nível de decomposição. O método aplicado revelou-se robusto perante os defeitos simulados, obtendo-se uma percentagem de sucesso de 98,5%.

Relativamente à classificação dos sinais de defeito, foram usados os segmentos determinados anteriormente para calcular os dados de entrada para a rede neuronal. Esses dados foram obtidos através do cálculo do valor eficaz nos segmentos de pré-defeito, de defeito e no segmento em que os contactos do disjuntor se encontram abertos. Após se ter feito uma análise sobre os parâmetros que minimizam o erro médio quadrático da rede sobre o conjunto de validação, chegou-se a um modelo com uma arquitetura 18-8-7, ou seja, com 18 neurónios na camada de entrada, 8 na camada escondida (cuja função de ativação é a tangente hiperbólica) e 7 neurónios na camada de saída, cada um indicador de um tipo de defeito. O erro médio quadrático obtido pelo modelo foi de 0,0058 no conjunto de treino e de 0,0063 nos conjuntos de validação e de teste. Da análise efetuada ao erro obtido pelo modelo, verificou-se que as piores previsões obtidas ocorrem para defeitos do tipo FT, em que o erro médio quadrático obtido foi de 0,007390 enquanto que para os defeitos FFT e FFFT foi de 0,005653 e 0,004979 respetivamente. Assumindo que as saídas do modelo acima de 0,5 têm valor lógico 1 e abaixo de 0,5 têm valor lógico 0, o modelo obteve uma percentagem de sucesso na classificação dos defeitos de 98,95% (apenas se classificou erradamente um caso do conjunto de teste). Comparando com outras técnicas existentes na literatura, conclui-se que o erro médio quadrático obtido, tem um valor relativamente baixo e que a percentagem de sucesso na classificação é similar à alcançada em métodos anteriores.

No início da dissertação, foi referido que se pretendia implementar métodos que permitissem a análise automática de defeitos por curto-circuito e a partir dessa análise extrair informação sobre: quais as fases defeituosas e o tipo de defeito, quanto tempo durou o defeito, qual foi o instante de operação dos disjuntores e qual foi o instante de restabelecimento do circuito. No trabalho efetuado, a partir da oscilografia dos sinais de defeito simulados, conseguiu-se retirar toda essa informação.

5.2 Perspetivas de trabalho futuro

Da realização deste trabalho surgem um conjunto de perspetivas de trabalho futuro que poderão ser feitos com o intuito de o melhorar, ou então, de o assumir como ponto de partida, para desenvolver trabalhos subsequentes. Essas perspetivas são as seguintes:

- Estudar a influência da frequência de amostragem dos sinais de defeito e também do comprimento da janela usada, sobre o método de segmentação desenvolvido, visto que, nas subestações, há equipamentos com uma grande variedade de frequências de amostragem;

- Aumentar a variabilidade dos parâmetros de cada simulação, assim como, o tamanho dos conjuntos de teste e de treino da rede neuronal para se conseguir uma validação ainda mais robusta da sua aplicabilidade na classificação de defeitos;
- Fazer estudos do impacto que diversos cenários têm sobre o desempenho dos métodos aplicados, como por exemplo, estudar a influência de diferentes linhas de transmissão, da localização do defeito na linha, etc.
- Aplicar a técnica de máquinas de suporte vetorial para a classificação dos sinais de defeito e fazer uma comparação com as RNA, uma vez que, da análise feita durante o estado da arte, pareceram as melhores soluções para o problema;
- Estudar a aplicabilidade dos métodos desenvolvidos no contexto de defeitos reais. Esta aplicação poderá levar a algumas alterações e melhorias aos mesmos. Por exemplo, se se tiver um conjunto de treino para a rede neuronal com dados simulados e também com dados reais, o modelo terá melhores resultados quando aplicado a outras situações reais.

Bibliografia

- [1] E. R. dos Serviços Energéticos (ERSE). *ELETRICIDADE|QUALIDADE DE SERVIÇO*. URL: <https://www.erse.pt/inicio/>. (acedido: 10.08.2022) (ver p. 1).
- [2] S. A. Aleem, N. Shahid e I. H. Naqvi. «Methodologies in power systems fault detection and diagnosis». Em: *Energy Systems* 6.1 (2015), pp. 85–108 (ver p. 1).
- [3] M. Musaruddin. «Automatic fault analysis in power systems via application service provider.» Tese de doutoramento. Adelaide: Universidade de Adelaide, Escola de Engenharia Elétrica e Eletrônica, 2011 (ver pp. 1, 2).
- [4] «IEEE/IEC Measuring relays and protection equipment – Part 24: Common format for transient data exchange (COMTRADE) for power systems». Em: *IEEE Std C37.111-2013 (IEC 60255-24 Edition 2.0 2013-04)* (2013), pp. 1–73. DOI: 10.1109/IEEESTD.2013.6512503 (ver pp. 2, 8, 9).
- [5] IEC 60050 - *International Electrotechnical Vocabulary - Details for IEV number 448-13-01: "power system abnormality"*. URL: <https://www.electropedia.org/iev/iev.nsf/display?openform&ievref=448-13-01>. (acedido: 05.01.2022) (ver p. 5).
- [6] IEC 60050 - *International Electrotechnical Vocabulary - Details for IEV number 448-13-02: "power system fault"*. URL: <https://www.electropedia.org/iev/iev.nsf/display?openform&ievref=448-13-02>. (acedido: 05.01.2022) (ver p. 5).
- [7] A. Prasad, J. B. Edward e K. Ravi. «A review on fault classification methodologies in power transmission systems: Part—I». Em: *Journal of electrical systems and information technology* 5.1 (2018), pp. 48–60 (ver pp. 6, 20).
- [8] F. Silva e N. Amaro. «Circuit Breaker Condition Based Maintenance Using Advanced Fault Detection and Analysis on COMTRADE Event Data». Em: *APCA International Conference on Automatic Control and Soft Computing*. Springer. 2022, pp. 542–553 (ver pp. 6, 39, 47).
- [9] J. L. Blackburn e T. J. Domin. *Protective relaying: principles and applications, 4th ed.* Boca Raton, FL: CRC press, 2014 (ver p. 7).

- [10] A. Abdelmoumene e H. Bentarzi. «A review on protective relays' developments and trends». Em: *Journal of Energy in Southern Africa* 25.2 (2014), pp. 91–95 (ver p. 7).
- [11] S. Beizhan e Z. Daonong. «The research & application of COMTRADE as a format for data exchange in smart substation». Em: *2014 International Conference on Power System Technology*. IEEE. 2014, pp. 1735–1742 (ver p. 8).
- [12] M. Kezunovic et al. «IEEE TUTORIAL ON AUTOMATED FAULT ANALYSIS». Em: *IEEE PES* (2001) (ver p. 9).
- [13] R. Yalda e M. Urosevic. «Automatic post-fault analysis based on disturbance data stored in substation devices: Approach towards the preventive maintenance». Dissertação. Estocolmo, Suécia: Instituto Real de Tecnologia, 2019 (ver p. 9).
- [14] A. Ukil e R. Zivanovic. «Detection of abrupt changes in power system fault analysis: A comparative study». Em: *S. African Univ. Power Engg. Conf.-SAUPEC05*. 2005 (ver pp. 9, 10, 63).
- [15] S. El Safty e A. El-Zonkoly. «Applying wavelet entropy principle in fault classification». Em: *International Journal of Electrical Power & Energy Systems* 31.10 (2009), pp. 604–607 (ver p. 10).
- [16] A. Prasad e J. B. Edward. «Application of wavelet technique for fault classification in transmission systems». Em: *Procedia Computer Science* 92 (2016), pp. 78–83 (ver p. 10).
- [17] V. Kecman. *Learning and soft computing: support vector machines, neural networks, and fuzzy logic models*. Cambridge, MA: MIT press, 2001 (ver p. 11).
- [18] L. A. Zadeh. «Fuzzy logic». Em: *Computer* 21.4 (1988), pp. 83–93 (ver p. 11).
- [19] A. Prasad et al. «Classification of faults in power transmission lines using fuzzy-logic technique». Em: *Indian Journal of Science and Technology* 8.30 (2015), pp. 1–6 (ver p. 11).
- [20] C. Cecati e K. Razi. «Fuzzy-logic-based high accurate fault classification of single and double-circuit power transmission lines». Em: *International Symposium on Power Electronics Power Electronics, Electrical Drives, Automation and Motion*. IEEE. 2012, pp. 883–889 (ver p. 11).
- [21] M. R. Bishal et al. «ANN Based Fault Detection & Classification in Power System Transmission line». Em: *2021 International Conference on Science & Contemporary Technologies (ICSCT)*. IEEE. 2021, pp. 1–4 (ver pp. 12, 53).
- [22] A. Jain, A. Thoke e R. Patel. «Fault classification of double circuit transmission line using artificial neural network». Em: *International Journal of Electrical Systems Science and Engineering* 1.4 (2008), pp. 750–755 (ver p. 12).

- [23] K. Silva, B. A. Souza e N. S. Brito. «Fault detection and classification in transmission lines based on wavelet transform and ANN». Em: *IEEE Transactions on power delivery* 21.4 (2006), pp. 2058–2063 (ver p. 12).
- [24] N. R. Babu e B. J. Mohan. «Fault classification in power systems using EMD and SVM». Em: *Ain Shams Engineering Journal* 8.2 (2017), pp. 103–111 (ver p. 12).
- [25] O. A. Youssef. «An optimised fault classification technique based on Support-Vector-Machines». Em: *2009 IEEE/PES Power Systems Conference and Exposition*. IEEE. 2009, pp. 1–8 (ver p. 12).
- [26] V. Malathi e N. Marimuthu. «Multi-class support vector machine approach for fault classification in power transmission line». Em: *2008 IEEE International Conference on Sustainable Energy Technologies*. IEEE. 2008, pp. 67–71 (ver p. 13).
- [27] A. Ukil e R. Zivanovic. «Abrupt change detection in power system fault analysis using wavelet transform». Em: *International Conference on Power Systems Transients*. 2005, pp. 1–5 (ver pp. 15, 17, 19, 38, 43).
- [28] S. d. C. Mendes. «Transformada de Wavelet aplicada a protecções digitais». Dissertação de Mestrado. Porto: Faculdade de Engenharia da Universidade do Porto, 2008 (ver pp. 16–18).
- [29] I. Daubechies. *Ten lectures on wavelets*. Philadelphia, Pa: SIAM, 1992 (ver p. 18).
- [30] D. Zhang. «Wavelet transform». Em: *Fundamentals of image data mining*. Springer, 2019, pp. 35–44 (ver p. 19).
- [31] K. Gurney. *An introduction to neural networks*. Londres: CRC press, 2018 (ver p. 21).
- [32] S. Haykin. *Neural Networks and Learning Machines*. Neural networks and learning machines vol. 10. Prentice Hall, 2009. ISBN: 9780131471399. URL: https://books.google.pt/books?id=K7P36lKzI%5C_QC (ver pp. 21, 22, 28).
- [33] V. T. Cortez. «Aplicação de redes neuronais artificiais à deteção e isolamento de falhas em processos industriais». Tese de doutoramento. Lisboa: Instituto Superior de Engenharia de Lisboa, 2015 (ver pp. 21, 25).
- [34] P. Cortez e J. Neves. *Redes neuronais artificiais*. Braga: Universidade do Minho, 2000 (ver pp. 21, 23, 24, 26).
- [35] A. Géron. *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems*. Farnham: "O'Reilly Media, Inc.", 2019 (ver p. 26).
- [36] IBM. *What is overfitting?* URL: <https://www.ibm.com/topics/overfitting>. (accedido: 4.08.2022) (ver p. 27).
- [37] REN. *Redes Energéticas Nacionais. Caracterização da Rede Nacional de Transporte para efeitos de acesso à rede. Situação a 31 de dezembro de 2021*. 2021 (ver pp. 34, 72).

- [38] REN. *Eletricidade*. URL: <https://datahub.ren.pt/pt/redes/>. (acedido: 22.07.2022) (ver p. 34).
- [39] I. Baqui et al. «High impedance fault detection methodology using wavelet transform and artificial neural networks». Em: *Electric Power Systems Research* 81.7 (2011), pp. 1325–1333 (ver p. 38).
- [40] Google. *Normalization*. URL: <https://developers.google.com/machine-learning/data-prep/transform/normalization>. (acedido: 10.08.2022) (ver p. 53).
- [41] S. Karsoliya. «Approximating number of hidden layer neurons in multiple hidden layer BPNN architecture». Em: *International Journal of Engineering Trends and Technology* 3.6 (2012), pp. 714–717 (ver p. 54).

Características das linhas de transmissão selecionadas

Neste anexo estão apresentadas as características das linhas selecionadas de uma forma mais detalhada na tabela I.1.

ANEXO I. CARACTERÍSTICAS DAS LINHAS DE TRANSMISSÃO SELECIONADAS

Tabela I.1: Características das linhas selecionadas de uma forma mais detalhada [37].

Barramento inicial	Barramento final	Tensão (kV)	Comprimento (km)	R (pu)	X (pu)	B (pu)	Capacidade térmica máxima de projeto (MVA)		
							Primavera	Verão	Inverno
Carrapatelo	Estarreja 3	220	50,9	0,00311	0,03080	0,09461	941	897	1021
Carregado	Rio Maior 1	220	40,2	0,00650	0,03510	0,05270	400	382	435
Carvoeira	Trajouce	220	46	0,00719	0,04008	0,05857	400	382	435
Fernão Ferro	Ribatejo	400	83,9	0,00154	0,01688	0,47566	1386	1321	1386
Ferreira do Alentejo	Ourique	150	44,5	0,02445	0,08166	0,02747	186	164	206
Ferreira do Alentejo	Sines	400	59,4	0,00110	0,01238	0,32679	1386	1361	1386
Pedralva	Vila Fria 2	150	41,7	0,02192	0,07804	0,02533	204	195	222
Pocinho	Chafariz 1	220	61,9	0,00985	0,05518	0,07982	364	333	381
Porto Alto	Palmela 2	150	36,5	0,02040	0,06930	0,02210	204	191	222
Riba D'Ave	Oleiros	150	35,2	0,01638	0,06453	0,02191	123	104	153
Sines	Portimão 3	400	97,8	0,00188	0,01980	0,56096	1386	1386	1386
Vieira do Minho	Pedralva 1	400	33	0,00058	0,00534	0,23072	1386	1386	1386

Análise dos ficheiros COMTRADE de configuração gerados

Neste anexo é indicado o que representa cada um dos campos presentes nos ficheiros COMTRADE de configuração gerados. Um exemplo de um ficheiro de configuração gerado está apresentado na figura II.1.

```
a) ScopeView
b) 6,6A,0D
c) 1,LCVRTJ_Di1.Ia,,,A,0.20228689375190737,-42.310302734375,0.0,-32767,32767
d) 2,LCVRTJ_Di1.Ib,,,A,0.01588545671414845,96.32785034179688,0.0,-32767,32767
e) 3,LCVRTJ_Di1.Ic,,,A,0.24583568030203326,21.369384765625,0.0,-32767,32767
f) 4,LCVRTJ.Va_s58,,,V,5.7248984321355,-17805.625,0.0,-32767,32767
g) 5,LCVRTJ.Vb_s58,,,V,5.4868393320363165,-128.0234375,0.0,-32767,32767
h) 6,LCVRTJ.Vc_s58,,,V,5.47729505226215,704.375,0.0,-32767,32767
i) 50.0
j) 1
k) 20000.0,30001
l) 06/26/22,13:16:27.051
m) 06/26/22,13:16:27.066000
n) ASCII
```

Figura II.1: Informações contidas no ficheiro COMTRADE de dados.

A informação de cada um dos campos não nulos contidos neste ficheiro é a seguinte:

- a) Nome da subestação¹;
- b) Total de canais, número de canais analógicos, número de canais digitais;
- c),..., h) Índice do canal analógico, identificador do canal, unidades, multiplicador, *offset*, desvio de tempo do canal em relação ao começo do período de amostragem, valor mínimo permitido para os dados, valor máximo permitido para os dados;
- i) Frequência da rede;

¹Neste caso, como os dados são simulados, o nome faz referência ao *software* que se usou para visualizar a oscilografia.

ANEXO II. ANÁLISE DOS FICHEIROS COMTRADE DE CONFIGURAÇÃO GERADOS

- j) Número de frequências de amostragem usadas;
- k) Frequência de amostragem, número da última amostra;
- l) Data em que se gravou o primeiro valor no ficheiros de dados;
- m) Data do disparo da proteção;
- n) Tipo do ficheiro de dados.

Exemplo de segmentação dos sinais de defeito

Na figura III.1, apresenta-se o resultado final da segmentação dos sinais de defeito apresentada no capítulo 4 para as tensões e correntes das três fases.




Figura III.1: Resultado final da segmentação dos sinais de defeito das correntes e tensões das três fases.

Resultados obtidos pela RNA na fase de teste

Na tabela IV.1 estão expostos os resultados obtidos pelo modelo da RNA desenvolvido na dissertação, para 20 defeitos FT na linha Carvoeira - Trajouce. Como se pode observar, o modelo classificou corretamente estes 20 casos, uma vez que o neurónio com valor perto de 1, corresponde ao tipo de defeito pretendido e os restantes neurónios, têm um valor perto de 0. A conversão dos resultados obtidos para os valores lógicos 0 e 1, está demonstrada na tabela IV.2. Se o modelo obteve à saída um valor superior a 0,5 essa saída foi convertida para o valor lógico 1 e fez-se o contrário para valores menores que 0,5.

Tabela IV.1: Resultados obtidos na linha Carvoeira - Trajouce para 20 defeitos FT.

Tipo de defeito	Resultado obtida pelo modelo para cada neurónio de saída						
	A-T	B-T	C-T	A-B-T	A-C-T	B-C-T	A-B-C-T
A-T	0.985275	0.0221961	-0.0484917	0.0150022	0.0174114	0.00478049	0.0187596
A-T	0.989158	0.0909379	-0.0223471	0.0322015	0.0341343	-0.109198	-0.011931
A-T	0.964412	0.0842257	-0.0195861	0.037645	0.055656	-0.088474	-0.0169001
A-T	0.767008	0.12293	-0.00220585	0.205536	0.132201	-0.131387	-0.0740516
B-T	0.00845288	0.918262	-0.0222554	0.0363984	0.012118	-0.00758366	0.042684
B-T	-0.0504431	1.03738	-0.0423198	-0.061787	0.0830009	-0.0157721	0.0341429
B-T	-0.0354589	1.07852	-0.0525989	-0.0895487	0.0708336	-0.0394099	0.0506543
B-T	0.00957369	1.08865	-0.0603414	-0.0941163	0.0252775	-0.0601271	0.0737993
B-T	-0.024356	1.11077	-0.062131	-0.11502	0.0620629	-0.0569359	0.0677634
B-T	-0.00467617	1.04244	-0.0407687	-0.048069	0.0367881	-0.0344535	0.0336797
B-T	-0.0346813	1.01049	-0.0472962	-0.0591304	0.0665092	0.00429864	0.0457525
B-T	-0.0370354	1.03477	-0.0506168	-0.0694657	0.0704227	-0.00978768	0.0473031
B-T	0.0119654	0.974531	-0.0321345	0.00702996	0.0123339	-0.0246326	0.0374212
B-T	0.0219868	1.01181	-0.0357851	-0.0177005	0.00714891	-0.0333108	0.0315619
B-T	-0.0260595	1.01507	-0.0307408	-0.0327153	0.0573019	-0.0120451	0.0146243
B-T	-0.0449445	0.990453	-0.0303869	-0.0304286	0.0735025	0.0021348	0.0251356
B-T	-0.0352266	1.04766	-0.0417928	-0.0646503	0.0685353	-0.0241756	0.0333015
C-T	-0.0598752	-0.0452452	0.865569	0.0701822	0.0340865	-0.0475777	0.175395
C-T	-0.107192	-0.0742313	0.856527	0.109089	0.146414	-0.0958075	0.1594
C-T	-0.112357	-0.0767271	0.827432	0.111492	0.170043	-0.0987489	0.173499
C-T	-0.0637428	-0.0483359	0.876979	0.074352	0.0369535	-0.0504508	0.166759

Tabela IV.2: Conversão dos resultados obtidos pelo modelo para os valores lógicos 0 e 1.

Tipo de defeito	Resultado obtida pelo modelo para cada neurónio de saída						
	A-T	B-T	C-T	A-B-T	A-C-T	B-C-T	A-B-C-T
A-T	1	0	0	0	0	0	0
A-T	1	0	0	0	0	0	0
A-T	1	0	0	0	0	0	0
A-T	1	0	0	0	0	0	0
B-T	0	1	0	0	0	0	0
B-T	0	1	0	0	0	0	0
B-T	0	1	0	0	0	0	0
B-T	0	1	0	0	0	0	0
B-T	0	1	0	0	0	0	0
B-T	0	1	0	0	0	0	0
B-T	0	1	0	0	0	0	0
B-T	0	1	0	0	0	0	0
B-T	0	1	0	0	0	0	0
B-T	0	1	0	0	0	0	0
B-T	0	1	0	0	0	0	0
B-T	0	1	0	0	0	0	0
B-T	0	1	0	0	0	0	0
C-T	0	0	1	0	0	0	0
C-T	0	0	1	0	0	0	0
C-T	0	0	1	0	0	0	0
C-T	0	0	1	0	0	0	0

