



MONITORAMENTO DE DEFEITOS EM DUTOS RÍGIDOS LONGOS POR
PARÂMETROS DE EMISSÃO ACÚSTICA E REDES NEURAIAS

Luiza Ribeiro Marnet

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Engenharia Elétrica, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Luiz Pereira Calôba

Rio de Janeiro

Junho de 2018

MONITORAMENTO DE DEFEITOS EM DUTOS RÍGIDOS LONGOS POR
PARÂMETROS DE EMISSÃO ACÚSTICA E REDES NEURAIAS

Luiza Ribeiro Marnet

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO
LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA (COPPE)
DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS
REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE EM
CIÊNCIAS EM ENGENHARIA ELÉTRICA.

Examinada por:

Prof. Luiz Pereira Calôba, Dr.Ing.

Prof. Carlos Fernando Carlim Pinto, D.Sc.

Prof. João Baptista de Oliveira e Souza Filho, D.Sc.

Prof. Sergio Damasceno Soares, D.Sc.

RIO DE JANEIRO, RJ - BRASIL

JUNHO DE 2018

Marnet, Luiza Ribeiro

Monitoramento de Defeitos em Dutos Rígidos Longos por Parâmetros de Emissão Acústica e Redes Neurais/
Luiza Ribeiro Marnet. – Rio de Janeiro: UFRJ/COPPE, 2018.

XV, 95 p.: il.; 29,7 cm.

Orientador: Luiz Pereira Calôba

Dissertação (mestrado) – UFRJ/ COPPE/ Programa de Engenharia Elétrica, 2018.

Referências Bibliográficas: p. 93-95.

1. Reconhecimento de Padrões. 2. Redes Neurais. 3. Emissão Acústica. I. Calôba, Luiz Pereira. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Elétrica. III. Título.

Dedicatória

A Deus, pela vida.

Aos meus pais, Robson e Moema, que sempre incentivaram meus estudos, me fizeram acreditar em mim e me guiaram para que eu chegasse até aqui. Sem eles não seria possível. E ao meu irmão Filipe, para que se lembre do meu amor pelos três.

Agradecimentos

Ao meu orientador, Luiz Pereira Calôba, por ter me escolhido para fazer parte do projeto, pelo incentivo e segurança transmitidos ao longo de todo o trajeto e pela oportunidade de adquirir parte do seu conhecimento, transmitido sempre com tanta dedicação.

Ao Carlos Fernando Carlim Pinto, a quem eu considero meu coorientador, por também ter me escolhido para fazer parte do projeto, permitindo que eu continuasse suas pesquisas. Pelo auxílio ao longo de todos esses meses e pelos conhecimentos transmitidos.

A Francesco Nosedá e Luiz Rennó Costa, que também participam do projeto, pelas ideias e conhecimentos compartilhados.

Ao Programa de Engenharia Elétrica, à COPPE e à UFRJ pela oportunidade de realizar o mestrado.

Aos professores e aos colegas de curso, pelos conhecimentos, ideias e incentivos.

Aos integrantes da banca examinadora, por aceitarem o convite para participar deste processo de avaliação.

À PETROBRAS pelo projeto de pesquisa e ao Sergio Damasceno Soares, da PETROBRAS, pelas dúvidas esclarecidas sobre o tema do projeto.

À CAPES e à COPPETEC pelas bolsas de estudo e de pesquisa concedidas.

E, por fim, à amiga Patricia Santos Macedo, sem ela eu não teria sequer me candidatado ao mestrado. E aos amigos Caroline Quaresma Daflon e Davi Dominguez, pelas tantas vezes que me acolheram em sua casa ao longo destes dois anos.

“Entrega o teu caminho ao Senhor; confia nele, e ele tudo fará.”

(BIBLIA, 1977)

Resumo da Dissertação apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

MONITORAMENTO DE DEFEITOS EM DUTOS RÍGIDOS LONGOS POR PARÂMETROS DE EMISSÃO ACÚSTICA E REDES NEURAIIS

Luiza Ribeiro Marnet

Junho/2018

Orientador: Luiz Pereira Calôba

Programa: Engenharia Elétrica

Monitorar os equipamentos em tempo real é de fundamental importância em sistemas de produção que apresentam riscos à segurança e ao meio ambiente. O método de Emissão Acústica se destaca entre os ensaios não destrutivos pela possibilidade de analisar a integridade de equipamentos durante o seu uso. Utilizar redes neurais para analisar os sinais de emissão acústica provenientes de trincas pode ser uma forma de monitorar falhas em equipamentos em tempo real e sem a necessidade da análise de especialistas. A propagação de trincas pode ser classificada em diversas fases, e é importante parar a produção para reparo antes que a falha no equipamento entre na fase de propagação instável. O objetivo deste trabalho é o uso de redes neurais supervisionadas e não supervisionadas para realizar uma divisão automática da fase de propagação de trincas em dutos rígidos de 40 metros e, em seguida, treinar redes neurais supervisionadas para classificar os dados previamente categorizados pela metodologia automática desenvolvida. Dois conjuntos de dados provenientes de ensaios hidrostáticos diferentes foram utilizados nesta pesquisa. Para um deles, as redes neurais supervisionadas atingiram, em média, aproximadamente 82% de acerto na classificação das fases de propagação da trinca para o conjunto de teste e, para o outro, em torno de 90%.

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

MONITORING OF DEFECTS IN LONG PIPELINES BY ACOUSTIC EMISSION
PARAMETERS AND NEURAL NETWORKS

Luiza Ribeiro Marnet

June/2018

Advisor: Luiz Pereira Calôba

Department: Electrical Engineering

Monitoring equipments in real time is of fundamental importance in production systems that pose risks to safety and the environment. The Acoustic Emission method stands out among nondestructive tests for the possibility of analyzing the integrity of equipments during its use. Using neural networks to analyze acoustic emission signals from cracks can be a way to monitor equipment failures in real time and without the need for expert analysis. Crack propagation can be classified into several phases, and it is important to stop production for repair before a failure of the equipment enters in the unstable propagation phase. The objective of this work is the use of supervised and unsupervised neural networks to perform an automatic division of the crack propagation phase into 40 meter pipelines and then train supervised neural networks to classify the data previously categorized by the developed automatic methodology . Two sets of data from different hydrostatic tests were used in this research. For one of them, the supervised neural networks achieved, on average, approximately 82% accuracy in the classification of the crack propagation phases for the test data set and, for the other, around 90%.

Sumário

1. INTRODUÇÃO	1
1.1. <i>OBJETIVO</i>	3
1.1.1. <i>Objetivos específicos</i>	4
2. REVISÃO TEÓRICA	5
2.1. <i>EMISSÃO ACÚSTICA</i>	5
2.1.1. <i>Detecção dos Sinais de Emissão Acústica</i>	7
2.2. <i>REDES NEURAIS</i>	9
2.2.1. <i>Redes Perceptron Multicamadas</i>	12
2.2.1.1. <i>Treinamento Backpropagation</i>	13
2.2.2. <i>MAPAS AUTO-ORGANIZÁVEIS DE KOHONEN</i>	17
3. REVISÃO BIBLIOGRÁFICA	22
3.1. <i>APRENDIZADO SUPERVISIONADO</i>	22
3.2. <i>APRENDIZADO NÃO SUPERVISIONADO</i>	26
4. METODOLOGIA	31
4.1. <i>AQUISIÇÃO DOS DADOS</i>	31
4.2. <i>TRATAMENTO DOS DADOS</i>	35
4.3. <i>DEFINIÇÃO DAS CLASSES</i>	40
4.4. <i>REDE NEURAL FEEDFORWARD</i>	43
4.5. <i>REDE DO MAPA AUTO-ORGANIZÁVEL DE KOHONEN</i>	44
4.6. <i>ANÁLISE EM CONJUNTO</i>	45
4.7. <i>RELEVÂNCIA DAS VARIÁVEIS</i>	46
5. RESULTADOS	49

5.1.	<i>PRÉ-PROCESSAMENTO DOS DADOS</i>	49
5.2.	<i>DIVISÃO DAS CLASSES</i>	60
5.2.1.	<i>Análise das Regiões das Classes</i>	63
5.3.	<i>Redes Neurais FeedForward</i>	69
5.3.1.	<i>Dimensionamento das Redes</i>	69
5.3.2.	<i>Desempenho das Redes</i>	75
5.4.	<i>ANÁLISE EM CONJUNTO</i>	80
5.5.	<i>RELEVÂNCIA DE PARÂMETROS</i>	84
6.	CONCLUSÕES	89
7.	TRABALHOS FUTUROS	91
	REFERÊNCIAS	93

Índice de Ilustrações

Figura 1 – Propagação de uma Emissão Acústica (MIX, 2005).	6
Figura 2 – Parâmetros de Tempo para a Detecção de Eventos de Emissão Acústica (Jacques, 2009).	8
Figura 3 – Parâmetros Extraídos dos Eventos de Emissão Acústica (Physical Acoustics Corporation, 2011).	9
Figura 4 – Representação da Aprendizagem Supervisionada (HAYKIN, 2001).	11
Figura 5 – Representação da Aprendizagem não Supervisionada (HAYKIN, 2001). ...	11
Figura 6 – Representação da Rede Perceptron Multicamadas (Da SILVA <i>et al.</i> , 2010).	12
Figura 7 – Notação dos Elementos do Algoritmo <i>Backpropagation</i>	13
Figura 8 – Mapa Auto-Organizável de <i>Kohonen</i> (HAYKIN, 2001).	18
Figura 9 – Gráficos da Pressão e da Deformação ao Longo do Tempo dos Testes Hidrostáticos dos Ensaios CP3 e CP4.	32
Figura 10 – Posicionamento dos sensores ao longo do duto.	33
Figura 11 – Fluxograma do Passo a Passo do Pré-Processamento dos Dados de Cada Ensaio.	35
Figura 12 – Fluxograma do Passo a Passo da Limpeza através da similaridade do Cosseno.	38
Figura 13 – Exemplo de processo de limpeza dos registros utilizando similaridade do cosseno.	39
Figura 14 – Três Primeiros e Dois Últimos Subconjuntos de Dados Utilizados para Avaliar Possíveis Pontos de Corte para os Dados de um Ensaio Hipotético.	41

Figura 15 – Fluxograma do Passo a Passo da Divisão Automática das Fases de Propagação da Trinca.	43
Figura 16 – Fluxograma das Etapas Realizadas ao Longo do Trabalho de Pesquisa.....	49
Figura 17 – Valor do <i>Threshold</i> (THR) ao Longo do Tempo para o Ensaio CP3.....	51
Figura 18 – Valor do <i>Threshold</i> (THR) ao Longo do Tempo para o Ensaio CP4.....	51
Figura 19 – Histograma de Intervalo de Tempo entre Sinais Consecutivos Captados...	52
Figura 20 – Histograma do Intervalo de Tempo entre os Grupos de 5 Sinais.....	53
Figura 21 – Amplitudes dos Registros do Ensaio CP3 - Canal 2.....	54
Figura 22 – Amplitudes dos Registros do Ensaio CP4 - Canal 2.....	55
Figura 23 – <i>Data Image</i> da Similaridade do Cosseno dos Dados de CP3 e CP4.....	57
Figura 24 – <i>Data Image</i> da Similaridade do Cosseno dos Dados de CP3 e CP4 após Limpeza.	58
Figura 25 – Erro de Classificação por Ponto de Corte Testado para o Ensaio CP3.....	61
Figura 26 – Erro de Classificação por Ponto de Corte Testado para o Ensaio CP4.....	62
Figura 27 – Mapa de Distâncias dos Neurônios para o Ensaio CP3.	64
Figura 28 – Mapa de Ativação dos Neurônios para o Ensaio CP3.....	65
Figura 29 – Mapa de Distâncias dos Neurônios para o Ensaio CP4.	67
Figura 30 – Mapa de Ativação dos Neurônios para o Ensaio CP4.....	68
Figura 31 – Relevância dos Parâmetros para as Redes Treinadas.....	85

Índice de Tabelas

Tabela 1 – Resumo dos Ensaios realizados pelo LAMEF (CLARKE e JACQUES, 2016)	33
Tabela 2 – Parâmetros de Emissão Acústica	34
Tabela 3 – Número de Registros por Canal.....	50
Tabela 4 – Quantidade de Registros Retirados do Canal 2 após Cada Etapa de Limpeza do Conjunto de Dados de Cada Ensaio	59
Tabela 5 – Quantidade de Registros Restantes no Canal 2 após a Última Limpeza dos Dados	59
Tabela 6 – Parâmetros Utilizados no Algoritmo SOM.....	63
Tabela 7 – Quantidade de Registros por Classe	69
Tabela 8 – Média e Desvio Padrão do Desempenhos das Redes Treinadas com Gradiente Descendente Adaptativo – CP3	70
Tabela 9 – Média e Desvio Padrão do Desempenhos das Redes Treinadas com <i>Levenberg-Marquardt</i> – CP3.....	71
Tabela 10 – Média e Desvio Padrão do Desempenhos das Redes Treinadas com Gradiente Descendente – CP3	72
Tabela 11 – Média e Desvio Padrão do Desempenhos das Redes Treinadas com Gradiente Descendente Adaptativo – CP4	73
Tabela 12 – Média e Desvio Padrão do Desempenhos das Redes Treinadas com <i>Levenberg-Marquardt</i> – CP4.....	73

Tabela 13 – Média e Desvio Padrão do Desempenhos das Redes Treinadas com Gradiente Descendente – CP4	74
Tabela 14 – Desempenhos das Redes Treinadas com os Dados de CP3 para os Conjuntos de Treino	75
Tabela 15 – Desempenhos das Redes Treinadas com os Dados de CP4 para os Conjuntos de Treino	76
Tabela 16 – Desempenhos das Redes Treinadas com os Dados de CP3 para os Conjuntos de Teste	76
Tabela 17 – Desempenhos das Redes Treinadas com os Dados de CP4 para os Conjuntos de Teste	76
Tabela 18 – Desempenhos das Redes Treinadas com os Dados de CP3 para os Dados do Ruído Retirado da Matriz de Similaridade do Cosseno	78
Tabela 19 – Desempenhos das Redes Treinadas com os Dados de CP4 para os Dados do Ruído Retirado da Matriz de Similaridade do Cosseno	78
Tabela 20 – Desempenhos das Redes Treinadas com os Dados de CP4 para o Conjunto de Dados de CP3.....	79
Tabela 21 – Desempenhos das Redes Treinadas com os Dados de CP3 para o Conjunto de Dados de CP4.....	79
Tabela 22 – Resultado da Análise em Conjunto das Saídas das Redes Treinadas com os Dados de CP3 para os Conjuntos de Treino	81
Tabela 23 – Resultado da Análise em Conjunto das Saídas das Redes Treinadas com os Dados de CP3 para os Conjuntos de Teste	81
Tabela 24 – Resultado da Análise em Conjunto das Saídas das Redes Treinadas com os Dados de CP4 para os Conjuntos de Treino	81

Tabela 25 – Resultado da Análise em Conjunto das Saídas das Redes Treinadas com os Dados de CP4 para os Conjuntos de Teste	82
Tabela 26 – Resultado da Análise em Conjunto das Saídas das Redes Treinadas com os Dados de CP3 para os Dados do Ruído Retirado da Matriz de Similaridade do Cosseno Junto com os Dados Limpos.....	83
Tabela 27 – Resultado da Análise em Conjunto das Saídas das Redes Treinadas com os Dados de CP4 para os Dados do Ruído Retirado da Matriz de Similaridade do Cosseno Junto com os Dados Limpos.....	83
Tabela 28 – Relevância dos Parâmetros por Classe de Propagação – Ensaio CP3.	86
Tabela 29 – Relevância dos Parâmetros por Classe de Propagação – Ensaio CP4.	87

1. INTRODUÇÃO

Os ensaios não destrutivos (ENDs) são exames, avaliações ou testes realizados em um objeto sem causar qualquer forma de alteração no mesmo. Exemplos de ensaios não destrutivos são inspeções visuais, líquido penetrante, partículas magnéticas, ensaios ultrassônicos, radiografia, corrente de *Foucault*, teste infravermelho térmico e de emissão acústica (HELLIER, 2003). Esse tipo de ensaio é de fundamental importância dentro da indústria, pois permite a análise da integridade dos materiais, diminuindo o risco de acidentes e, assim, aumentando a segurança dos processos.

Dentre os métodos de ensaio não destrutivo, o de Emissão Acústica (EA) se diferencia dos outros por ser o único em que o material sob inspeção emite sinais quando alguma falha está para acontecer. Este método se baseia no fato de que materiais sólidos emitem sinais acústicos quando sofrem deformações devido a estresses mecânicos ou térmicos. Quando comparado a outros ENDs, a EA possui como uma de suas vantagens a possibilidade de monitorar os equipamentos em tempo real e sob qualquer condição de operação. Além do mais, em operações com gases ou líquidos, desperdícios de material e recursos financeiros são minimizados pelo fato de não ser necessário esvaziar o equipamento para realizá-los. Também se torna possível identificar problemas de corrosão, diminuindo ou eliminando a necessidade de inspeções internas. Por outro lado, apenas os defeitos em formação ou propagação podem ser identificados por testes de EA, e os ruídos gerados pelo processo causam grande influência nos resultados dos ensaios realizados (MIX, 2005).

Como já foi demonstrado por PINTO (2011, 2014), é possível identificar as fases de propagação de trincas a partir da aplicação de métodos de análise de dados aos sinais acústicos emitidos pela propagação deste defeito. Em seus trabalhos, PINTO (2011, 2014) demonstrou ser possível classificar através de redes neurais *feedforward* e de mapas neurais auto-organizáveis (*self organizing maps* - SOM) de *Kohonen* as fases de propagação de trincas em dutos pressurizados de pequeno comprimento (1,81 m).

De acordo com PINTO (2011, 2014), a propagação de deformações pode ser dividida em três fases: a fase inicial, em que não há propagação, a fase intermediária, em que ocorre uma deformação estável, e a última, na qual ocorre a deformação instável. Em determinados equipamentos, como dutos pressurizados, é importante identificar quando uma deformação instável está para ocorrer, de forma que se interrompa o processo de produção para reparo antes de um defeito entrar nesta fase de propagação, o que causaria um acidente, mas sem pará-lo precocemente, o que geraria uma diminuição desnecessária da produção.

O sinal de Emissão Acústica sofre perda de amplitude a medida em que o mesmo se propaga ao longo do material que está em teste, se tornando uma possível limitação quanto a distância máxima que o sensor responsável por captar os sinais precisa estar da deformação para que a falha ainda consiga ser identificada (HELLIER, 2003).

Para saber se os métodos utilizados por PINTO (2011, 2014) em dutos curtos podem ser empregados para identificar as fases de propagação de trincas em dutos longos, uma pesquisa similar à desenvolvida por este autor deveria ser realizada utilizando dutos de maior comprimento. Para este estudo da atenuação dos sinais de emissão acústica, deveriam ser posicionados diversos sensores sobre o duto, a diferentes distâncias da trinca. Para, desta forma, identificar o quão longe o sensor pode ser posicionado de forma

que redes neurais treinadas com os sinais por ele captados ainda sejam capazes de identificar as fases de propagação. Além disso, também é necessário estudar a possibilidade de redes neurais treinadas com dados provenientes de sensores posicionados a determinada distância da trinca identificarem corretamente os sinais de sensores colocados a outra distância.

1.1. OBJETIVO

Nos estudos anteriores (PINTO, 2011, 2014) foram utilizados dutos curtos de 1,81m, enquanto no presente projeto foram utilizados dutos longos de 40 m.

O objetivo do projeto aqui descrito é estudar a classificação da fase de propagação de trincas em dutos rígidos pressurizados através da análise dos parâmetros de sinais de Emissão Acústica (EA) por redes neurais (PINTO, 2014) em dutos longos, isto é, identificar se a atenuação da amplitude do sinal de EA influencia a classificação da trinca. Para isso, foram empregadas metodologias já apresentadas em projetos anteriores, além de um novo método para definir o ponto de transição entre as classes de maneira automática.

1.1.1. Objetivos específicos

- Definir de forma autônoma, através de redes neurais *feedforward*, os pontos de transição entre as fases de propagação de trincas, utilizando os dados dos ensaios realizados para este projeto;
- Treinar redes neurais *feedforward* que classifiquem os sinais de emissão acústica em suas diferentes fases, utilizando a divisão encontrada pela classificação automática;
- Observar se as redes de mapas neurais auto-organizáveis de *Kohonen* são capazes de gerar mapas que formam regiões distintas, uma para cada classe de propagação da deformação.

2. REVISÃO TEÓRICA

2.1. EMISSÃO ACÚSTICA

Quando um material sólido está se deformando devido à pressão térmica ou mecânica, o mesmo gera emissões acústicas sônicas ou ultrassônicas. É nessa propriedade de emitir pulsos acústicos durante as deformações que os testes de emissão acústica se baseiam, sendo os únicos testes não destrutivos em que o próprio material emite os sinais de que uma falha está ocorrendo. Por outro lado, as emissões acústicas só acontecem durante a deformação, de forma que falhas já existentes, que não estão se propagando, não emitem novos pulsos (MIX, 2005).

De acordo com HELLIER (2003), a tensão pode ser calculada pela força aplicada dividida pela área na qual se aplica a mesma, sendo como um campo interno de forças que equilibra as forças externas aplicadas a uma estrutura. Segundo este autor, como reação à pressão aplicada, uma estrutura tem a sua forma modificada, podendo ser uma alteração elástica (temporária) ou, caso a pressão seja suficientemente grande, plástica (permanente). Nas deformações plásticas, ocorre uma mudança permanente na estrutura atômica do material, e essa mudança gera emissões acústicas.

A propagação de um evento de EA se dá em todas as direções e não pode ser interrompida. Ou seja, quando ocorre um deslocamento atômico devido à pressão, gerando uma EA, uma onda elástica, cuja origem é o ponto de deslocamento, ocorre em

todas as direções, sendo atenuada ao longo do tempo e à medida em que se afasta da sua origem. Em materiais planos, essa onda se dá como a propagação de diversos círculos concêntricos, como exemplificado pela Figura 1, em que sensores são posicionados em diversos pontos para identificar o mesmo evento de EA (MIX, 2005).

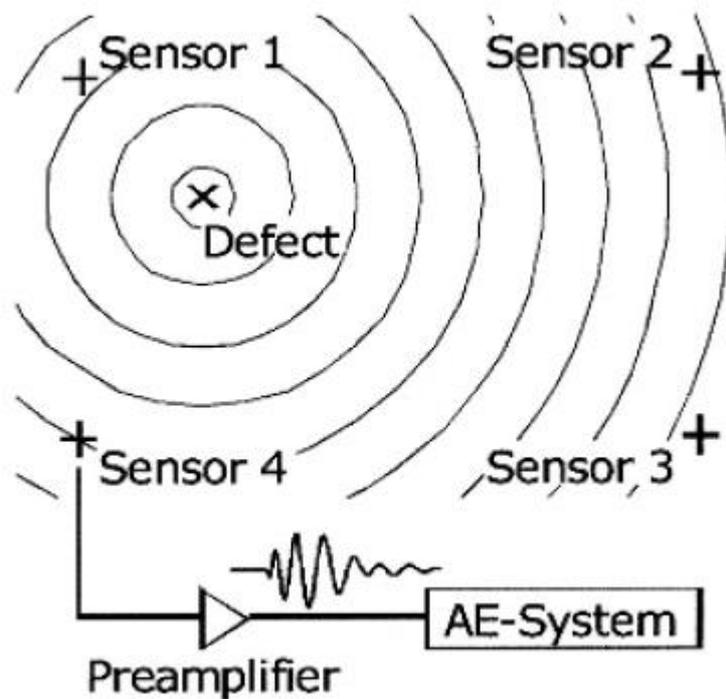


Figura 1 – Propagação de uma Emissão Acústica (MIX, 2005).

Ainda de acordo com MIX (2005), existem dois tipos de sinais de emissão acústica: transiente e contínuo. Sendo o sinal contínuo, um sinal em que, apesar de haver variação de frequência e de amplitude, os pontos iniciais e finais do sinal não são aparentes, de forma que o sinal de EA se confunde com o ruído. Já os sinais transientes possuem seu início e fim bem definidos e são facilmente diferenciáveis dos sinais de ruído. Para este trabalho, os sinais de EA provenientes da formação e propagação de trincas são considerados como sinais transientes.

2.1.1. *Detecção dos Sinais de Emissão Acústica*

Os sensores que detectam as emissões acústicas recebem a energia mecânica das ondas elásticas das EAs e a converte em sinais elétricos, podendo, assim, ser denominados de transdutores (Physical Acoustics Corporation, 2011).

De acordo com MIX (2005), os sistemas de emissão acústica, para transformar os sinais detectados em conjuntos de dados, estabelecem níveis limites (*thresholds*), positivos e negativos, que, ao serem ultrapassados, considera-se que houve a ocorrência de uma emissão acústica. Caso tais níveis não sejam ultrapassados, considera-se que apenas ocorreram ruídos.

Para se identificar os sinais de emissão acústica ao longo dos sinais elétricos gerados pelos sensores de EA, são necessários os seguintes parâmetros de tempo: *Hit Definition Time* (HDT), *Hit Lockout Time* (HLT) e *Peak Definition Time* (PDT). A Figura 2, a seguir, auxilia no entendimento desses três parâmetros. Um evento de emissão acústica começa a ser detectado quando a voltagem (nível do sinal) ultrapassa pela primeira vez, positiva ou negativamente, o valor de *threshold* pré-determinado. Após a primeira ultrapassagem, o tempo definido para PDT começa a ser contado regressivamente. Caso não ocorra nenhum outro pico de sinal com valor maior do que o do primeiro pico após a primeira ultrapassagem do *threshold* dentro dos PDT segundos, o primeiro pico é definido como a amplitude de pico máxima. Caso contrário, a contagem regressiva de PDT recomeça no momento em que o valor do pico máximo for ultrapassado. O parâmetro HDT serve para determinar o final de um evento de emissão acústica. Quando HDT segundos se passarem sem que o sinal ultrapasse novamente o

valor do *threshold*, o final do evento de emissão acústica é definido como o fim da última ultrapassagem ocorrida antes do início da contagem de HDT. Por último, para evitar que um evento de reflexão seja detectado como um novo evento de emissão acústica, ao longo de HLT segundos após o final da contagem de HDT segundos, nenhum outro evento é registrado (Physical Acoustics Corporation, 2011).

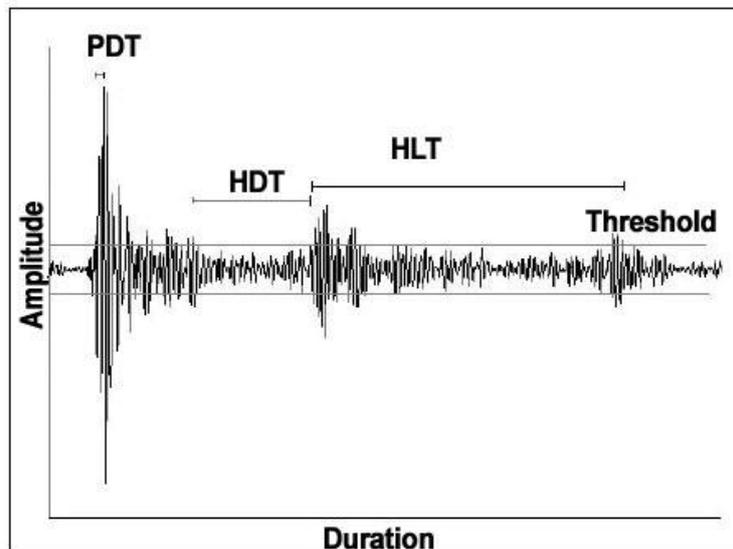


Figura 2 – Parâmetros de Tempo para a Detecção de Eventos de Emissão Acústica (Jacques, 2009).

A Figura 3 ajuda a clarear o entendimento de alguns dos parâmetros de emissão acústica retirados dos sinais captados. O valor de pico de amplitude máxima é a amplitude máxima apontada na Figura 3 como ‘AE Amplitude’. Os tempos de duração e de subida de um evento de EA estão definidos na Figura 3 como ‘AE Duration’ e ‘Rise Time’, respectivamente. E o tempo de chegada é o tempo do teste de emissão acústica em que um determinado evento começa a ser detectado, na Figura 3 definido como ‘Time of Hit’. Por fim, o número de contagens, ou contagens de pico, é o número de vezes que o valor de *threshold* é ultrapassado ao longo de um evento de EA. No caso da Figura 3, o número de contagens foi igual à 4.

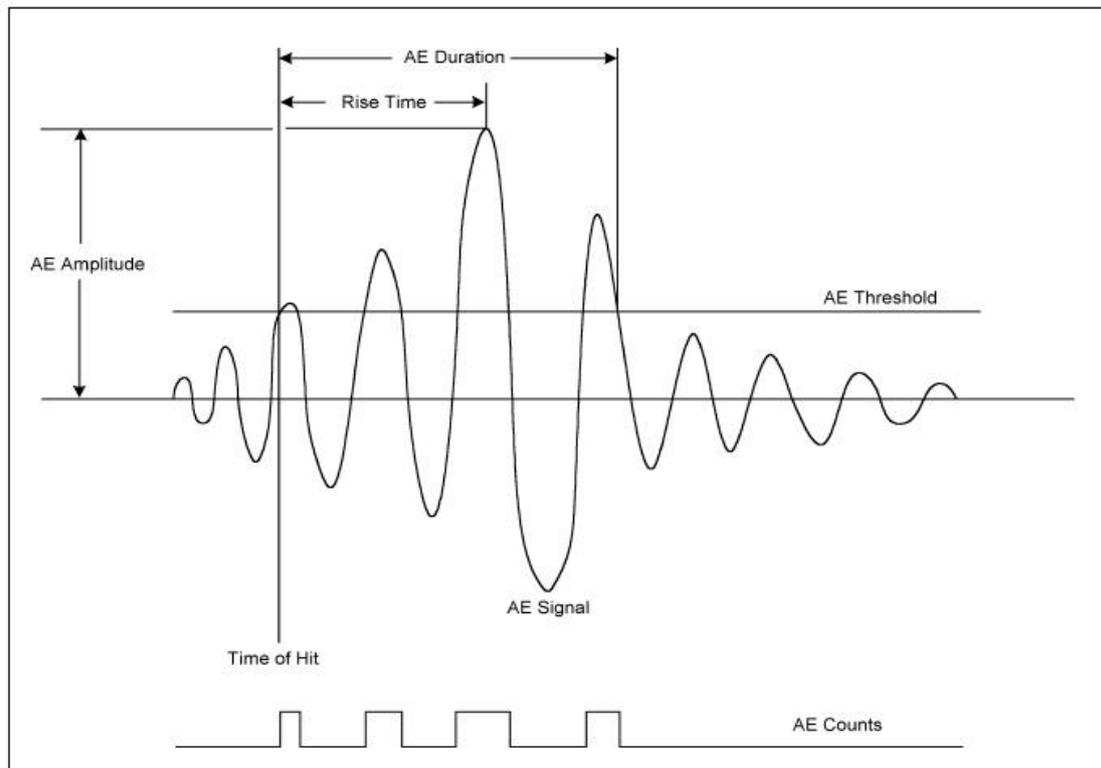


Figura 3 – Parâmetros Extraídos dos Eventos de Emissão Acústica (Physical Acoustics Corporation, 2011).

De acordo com MIX (2005), é possível identificar que alguns sinais de emissão acústica foram, possivelmente, causados por ruído através dos valores de contagem e de duração dos mesmos. Segundo ele, sinais com menos de 3 ultrapassagens do valor de *threshold* e menos de 3 μs são, provavelmente, devidos a sinais de ruído.

2.2. REDES NEURAIS

As redes neurais são processadores intensivos de dados que possuem unidades de processamento simples, os neurônios, e se assemelham ao cérebro humano por

adquirirem conhecimento acerca de seu ambiente através de processos de aprendizado que se baseiam na adaptação ordenada de pesos sinápticos que interligam os neurônios (HAYKIN, 2001).

HAYKIN (2001) aponta seis objetivos para a utilização de redes neurais artificiais: associação de padrões, reconhecimento de padrões, aproximação de funções, controle, filtragem e formação de feixe. Ainda segundo o autor, a associação de padrões pode requerer aprendizagem supervisionada ou não-supervisionada. Na associação de padrões com treinamento não-supervisionado, também chamada auto-associação, dados de diversos padrões são apresentados à rede, que deve aprender esses padrões e, mais tarde, ao receber um novo dado correspondente a um destes padrões, porém distorcido por ruído, deve identificar qual padrão o representa. Já no reconhecimento de padrões, diversos dados pertencentes a classes previamente conhecidas são apresentados a rede, que pode realizar um treinamento semi-supervisionado ou puramente supervisionado, e, por fim, novos dados de padrões similares aos dados anteriores são apresentados para que a rede identifique a classe dos mesmos. Nesta pesquisa, serão utilizados o reconhecimento de padrões com treinamento supervisionado e a auto-associação de padrões.

No treinamento supervisionado, Figura 4, de acordo com HAYKIN (2001), é como se existisse um professor que possui conhecimento acerca do ambiente sobre o qual a rede precisa conhecer. Assim, para cada vetor de dado fornecido à entrada da rede durante o período de treinamento, a mesma gera uma resposta de saída que é comparada com a resposta ideal fornecida pelo professor. A comparação entre a resposta da rede e a ideal gera um erro, que é utilizado para alterar as sinapses da rede. Esse treinamento deve ocorrer até que a rede obtenha o máximo de informação possível do professor.

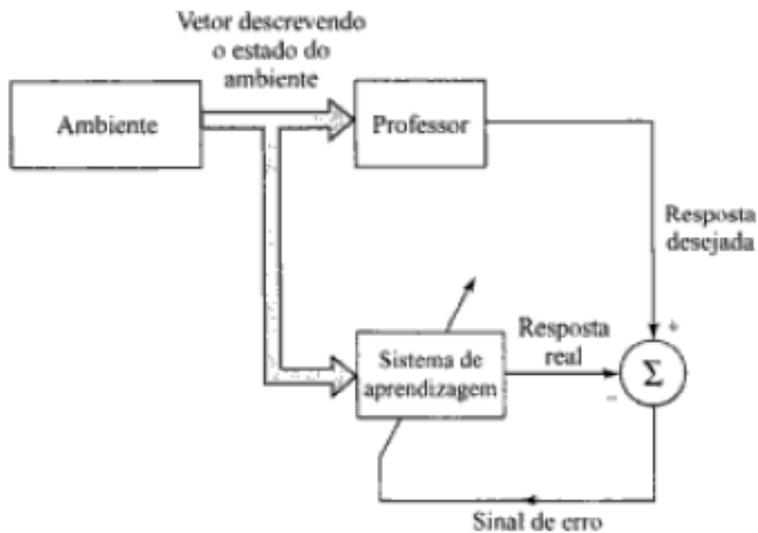


Figura 4 – Representação da Aprendizagem Supervisionada (HAYKIN, 2001).

No treinamento não supervisionado, por outro lado, não existe um professor, Figura 5. Nesse modo de aprendizagem, segundo BECKER (1991), os vetores de dados de entrada são fornecidos para a rede e, ao longo do treinamento, a mesma descobre os padrões estatísticos dos dados. A partir dessa descoberta, a rede consegue definir, sozinha, representações que explicitam características simplificadas dos dados, facilitando a interpretação dos mesmos. De acordo com BECKER (1991), a aprendizagem não supervisionada pode suprir a falta de similaridade entre a aprendizagem supervisionada e a forma de adquirir conhecimento do cérebro humano, uma vez que os padrões não são apresentados ao cérebro previamente rotulados.

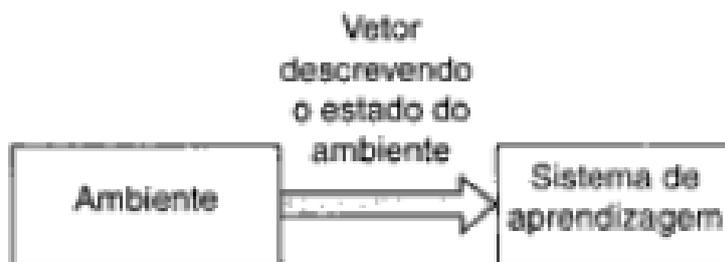


Figura 5 – Representação da Aprendizagem não Supervisionada (HAYKIN, 2001).

2.2.1. Redes Perceptron Multicamadas

De acordo com Da SILVA *et al.* (2010), as redes perceptron multicamadas (*Multi Layer Perceptron - MLP*), Figura 6, possuem o tipo de arquitetura *feedforward*, ou seja, o fluxo de informação ocorre sempre adiante, passando dos dados de entrada para a primeira camada intermediária, desta para a seguinte, e assim por diante, até chegar na saída da rede. Assim, a arquitetura original das redes MLP não possui nenhuma forma de realimentação de valores. O autor ainda ressalta que o treinamento das redes MLP se dá pelo algoritmo *backpropagation*, também conhecido como algoritmo de retropropagação do erro ou regra delta generalizada.

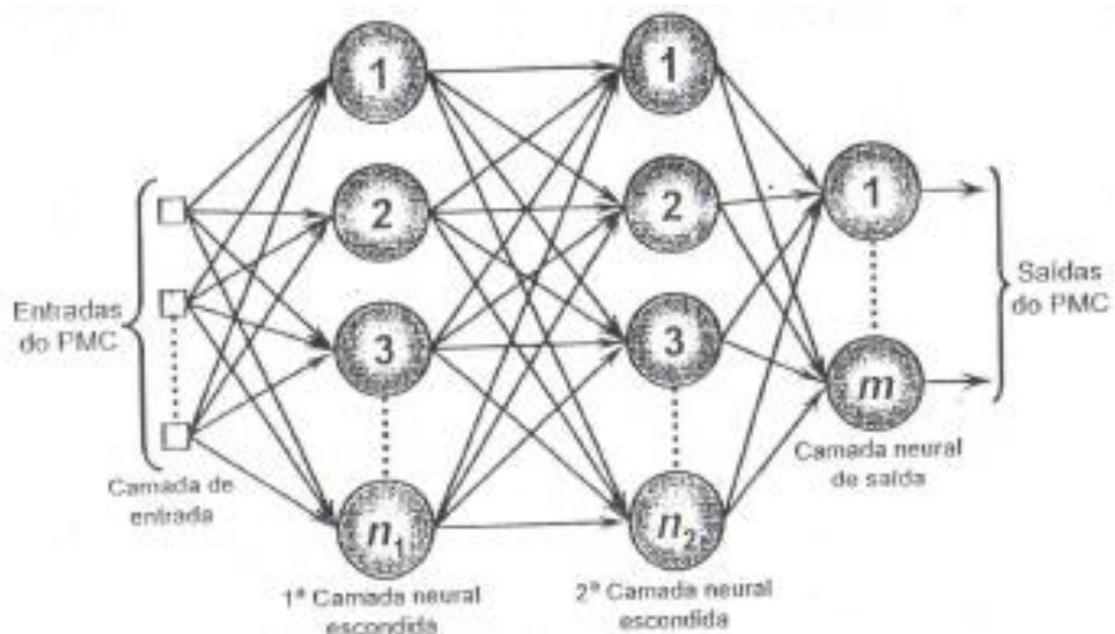


Figura 6 – Representação da Rede Perceptron Multicamadas (Da SILVA *et al.*, 2010).

2.2.1.1. Treinamento *Backpropagation*

O treinamento *backpropagation*, de acordo com Da SILVA *et al.* (2010), ocorre em duas etapas: a etapa de propagação adiante, ou *forward*, e a camada de propagação reversa, ou *backpropagation*.

Na etapa de propagação adiante, a informação é passada camada-a-camada, da entrada até a saída da rede. Observando a Figura 7, $W_{ji}^{(L)}$ representa a sinapse que liga a entrada do neurônio j da camada L à saída do neurônio i da camada $L - 1$ e $I_j^{(L)}$ e $Y_j^{(L)}$ são, respectivamente, a entrada e a saída do neurônio j da camada L . A camada 1 é a primeira camada escondida de neurônios; a camada 2, a segunda camada de neurônios, e assim por diante, até a última camada. Também se deve notar que a saída da rede é igual à saída dos neurônios da camada de saída.

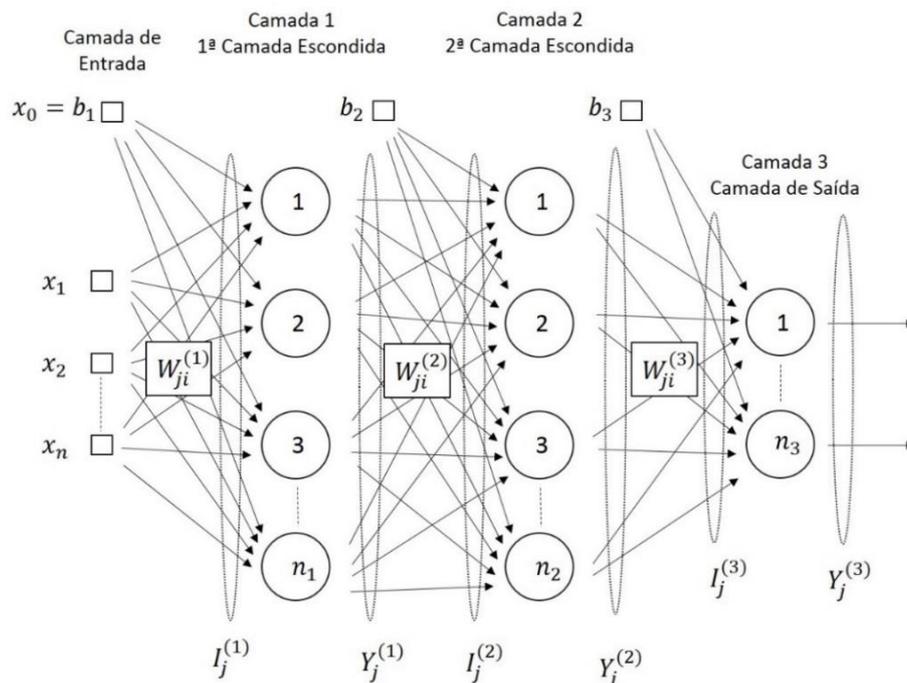


Figura 7 – Notação dos Elementos do Algoritmo *Backpropagation*.

As equações a seguir descrevem a formulação matemática de $I_j^{(L)}$ e $Y_j^{(L)}$ (Da SILVA *et al.*, 2010).

$$I_j^{(L)} = \sum_{i=0}^{n_y} W_{ji}^{(L)} * X_i , \quad (1)$$

$$Y_j^{(L)} = g(I_j^{(L)}) , \quad (2)$$

Onde n_y é o número de entradas da rede, no caso da primeira camada escondida, e o número de neurônios da camada anterior, no caso das demais camadas; e $g(.)$ é uma função de ativação contínua e diferenciável em todo o seu domínio. A variável X_i , quando $i = 0$, ou seja, quando $X_i = X_0$, é o limiar, ou bias (b), de cada camada, de forma que $W_{j0}^{(L)}$ é a sinapse que liga o neurônio j da camada L ao bias dessa camada.

Antes de iniciar a fase de *backpropagation*, devem ser calculados os erros das saídas da rede, em relação aos quais as sinapses serão atualizadas. O erro de cada saída para uma dada amostra $X(k)$ é calculado como a diferença entre a saída $Y_j^{(L)}$ da rede, para o neurônio j da camada L de saída (camada 3 no caso da Figura 7), e o valor ideal $d_j(k)$, esperado como saída para a amostra $X(k)$. A partir desses erros também é possível medir o desempenho da rede em relação a uma amostra como o erro quadrático:

$$E(k) = \frac{1}{2} \sum_{j=1}^m (d_j(k) - Y_j^{(L)})^2 \quad (3)$$

Na Equação (3), m é o número de neurônios da camada de saída; e $Y_j^{(L)}$ são as saídas desses neurônios. Dado que uma época corresponde a apresentação de todas as p amostras de treinamento por uma vez, o erro médio quadrático da rede ao final de uma determinada época é:

$$E_M = \frac{1}{p} \sum_{k=1}^p E(k) \quad (4)$$

Por fim, para calcular o quanto as sinapses da rede devem variar devido aos erros referentes a uma época de treinamento, o erro é retropropagado. De acordo com Da SILVA *et al.* (2010), as sinapses devem ser atualizadas na direção oposta ao gradiente do erro médio quadrático, pois se objetiva encontrar o valor mínimo para este erro. Além disso, o erro é retropropagado camada-por-camada, atualizando-se primeiro as sinapses que ligam a camada de saída à última camada intermediária e, por último, as que ligam a primeira camada intermediária às entradas da rede.

Para atualizar as sinapses que ligam a camada de saída à última camada intermediária, deve-se derivar o erro das saídas da rede em relação à estas sinapses. Para tanto, se faz necessário utilizar a regra da cadeia. Definindo $L = s$ para a camada de saída (Da SILVA *et al.*,2010):

$$\nabla E^{(s)} = \frac{\partial E}{\partial W_{ji}^{(s)}} = \frac{\partial E}{\partial Y_j^{(s)}} * \frac{\partial Y_j^{(s)}}{\partial I_j^{(s)}} * \frac{\partial I_j^{(s)}}{\partial W_{ji}^{(s)}} \quad (5)$$

Utilizando as Equações (3), (2) e (1), respectivamente, para se obter as três derivadas parciais, na ordem em que se apresentam na Equação (5), obtém-se:

$$\frac{\partial E}{\partial W_{ji}^{(s)}} = -(d_j - Y_j^{(s)}) * g'(I_j^{(s)}) * Y_i^{(s-1)} \quad (6)$$

Sendo $\delta_j^{(s)} = (d_j - Y_j^{(s)}) * g'(I_j^{(s)})$ o gradiente local relativo ao neurônio j da camada de saída, e como o incremento em $W_{ji}^{(s)}$ deve ser realizado em direção oposta ao gradiente, resulta:

$$\Delta W_{ji}^{(s)} = \eta * \delta_j^{(s)} * Y_i^{(s-1)}, \quad (7)$$

Onde η é igual ao valor da taxa de aprendizagem. E, assim:

$$W_{ji}^{(s)}(t + 1) = W_{ji}^{(s)}(t) + \Delta W_{ji}^{(s)} \quad (8)$$

Onde t é a t -ésima época de treinamento.

Em seguida, devem ser atualizadas as sinapses ligadas às entradas dos neurônios das camadas intermediárias. A lógica empregada é semelhante à realizada para as sinapses anteriormente atualizadas. Para as sinapses ligadas à entrada de cada neurônio das camadas intermediárias, o gradiente do erro é calculado como se segue (Da SILVA *et al.*, 2010):

$$\nabla E^{(L)} = \frac{\partial E}{\partial W_{ji}^{(L)}} = \frac{\partial E}{\partial Y_j^{(L)}} * \frac{\partial Y_j^{(L)}}{\partial I_j^{(L)}} * \frac{\partial I_j^{(L)}}{\partial W_{ji}^{(L)}} \quad (9)$$

Utilizando as Equações (2) e (1), respectivamente, para obter as duas últimas derivadas parciais da Equação (9), obtém-se:

$$\frac{\partial E}{\partial W_{ji}^{(L)}} = \frac{\partial E}{\partial Y_j^{(L)}} * g'(I_j^{(L)}) * Y_i^{(L-1)} \quad (10)$$

Para resolver a derivada parcial restante é necessário utilizar a regra da cadeia novamente:

$$\frac{\partial E}{\partial Y_j^{(L)}} = \sum_{k=1}^n \frac{\partial E}{\partial I_k^{(L+1)}} * \frac{\partial I_k^{(L+1)}}{\partial Y_j^{(L)}} = \sum_{k=1}^n \frac{\partial E}{\partial I_k^{(L+1)}} * \frac{\partial (\sum_{k=1}^n W_{kj}^{(L+1)} * \partial Y_j^{(L)})}{\partial Y_j^{(L)}} = \sum_{k=1}^n \frac{\partial E}{\partial I_k^{(L+1)}} * W_{kj}^{(L+1)} \quad (11)$$

Onde n é o número de neurônios da camada seguinte à camada L , ou seja, da camada

$L+1$. Como $\frac{\partial E}{\partial I_k^{(L+1)}} = \frac{\partial E}{\partial Y_k^{(L+1)}} * \frac{\partial Y_k^{(L+1)}}{\partial I_k^{(L+1)}} = -\sum_{k=1}^n \delta_k^{(L+1)} * W_{kj}^{(L+1)}$, tem-se que a

Equação (10) se torna:

$$\frac{\partial E}{\partial W_{ji}^{(L)}} = -\left(\sum_{k=1}^n \delta_k^{(L+1)} * W_{kj}^{(L+1)}\right) * g'(I_j^{(L)}) * Y_i^{(L-1)} \quad (12)$$

É importante ressaltar que $\delta_k^{(L+1)}$ é o valor do gradiente local relativo ao neurônio k da camada seguinte a camada L , já calculado na etapa anterior da retropropagação do erro, e $W_{kj}^{(L+1)}$ é o valor já atualizado da sinapse que liga a entrada do neurônio k da camada $L + 1$ à saída do neurônio j da camada L .

Sendo $\delta_j^{(L)} = \left(\sum_{k=1}^n \delta_k^{(L+1)} * W_{kj}^{(L+1)} \right) * g' \left(I_j^{(L)} \right)$ o gradiente local relativo ao neurônio j da camada L , e como o incremento em $W_{ji}^{(L)}$ deve ser realizado em direção oposta ao gradiente:

$$\Delta W_{ji}^{(L)} = \eta * \delta_j^{(L)} * Y_i^{(L-1)} \quad (13)$$

Onde η é igual ao valor da taxa de aprendizagem. E, assim:

$$W_{ji}^{(L)}(t + 1) = W_{ji}^{(L)}(t) + \Delta W_{ji}^{(L)} \quad (14)$$

2.2.2. MAPAS AUTO-ORGANIZÁVEIS DE KOHONEN

O mapa auto-organizável (*self organizing map* – SOM) de *Kohonen* tem como objetivo mapear vetores de dados de entrada de dimensão n em mapas uni ou bidimensionais topologicamente organizados, reduzindo a dimensionalidade dos dados. Os mapas auto-organizáveis de *Kohonen* são formados por neurônios totalmente ligados às entradas, sendo o posicionamento destes neurônios representativo das características

estatísticas dos padrões dos dados de entrada, formando um mapa de padrões (HAYKIN, 2001). A Figura 8 apresenta a ilustração de um mapa auto-organizável de *Kohonen*. O ‘Feixe de conexões sinápticas’ dessa imagem também pode ser denominado vetor de pesos sinápticos.

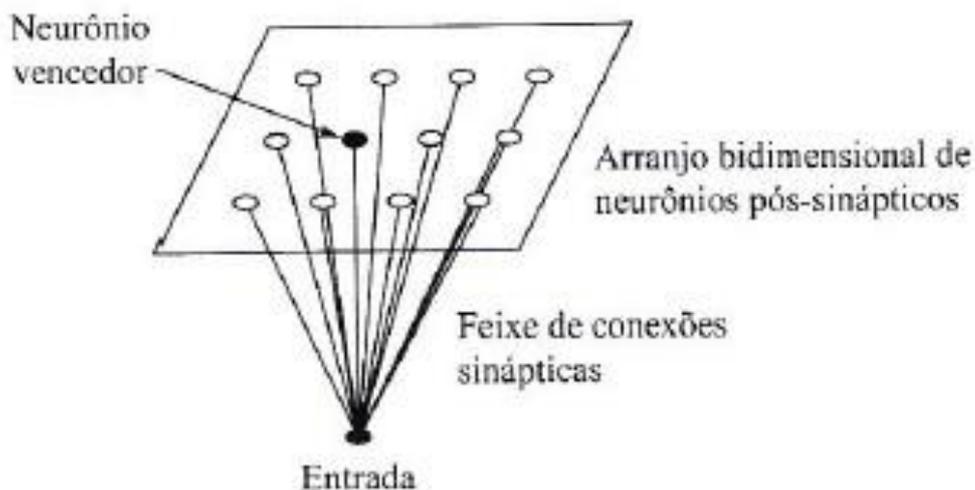


Figura 8 – Mapa Auto-Organizável de *Kohonen* (HAYKIN, 2001).

De acordo com HAYKIN (2001), para gerar um mapa auto-organizável são necessárias três ações: a competição, a cooperação e a adaptação sináptica, sendo que esta última possui duas fases, a etapa de ordenação e a etapa convergência. A seguir, serão explicadas estas ações de acordo com o autor citado.

Como já foi dito, cada neurônio do mapa está conectado a todas as dimensões do dado de entrada. Assim, considerando-se um vetor de entrada de n dimensões, cada neurônio possuirá n sinapses, ou um vetor de pesos sinápticos de n dimensões, para ligá-lo às entradas.

Na ação de competição, deseja-se encontrar qual o neurônio cujo vetor de pesos sinápticos é mais similar a cada um dos vetores de dados de entrada apresentados à rede. Para isso, pode ser utilizada a fórmula abaixo:

$$i(x) = \arg \min_j \|x - w_j\| , j = 1, 2, \dots, l , \quad (15)$$

Onde i representa o índice do neurônio mais similar a uma dada entrada x , ou seja, o neurônio vencedor para esta entrada; w_j é o vetor de pesos sinápticos do neurônio j ; e l é o número de neurônios do mapa. De acordo com o autor, i pode ser definido como o índice do neurônio vencedor ou como o vetor de pesos sinápticos do mesmo.

Após encontrar o neurônio vencedor para uma dada entrada, deve ser realizada a ação de cooperação. Essa ação é realizada com o intuito de aproximar o funcionamento da rede da inspiração neurobiológica, na qual, quando um determinado neurônio dispara, os neurônios próximos são mais fortemente excitados do que os distantes. Assim, é definida uma vizinhança para o neurônio vencedor, cujo centro é este neurônio. Esta vizinhança é definida de forma que, ao adaptar as sinapses ao longo do treinamento, o neurônio vencedor seja o que sofre maior alteração em uma determinada iteração, ainda que os neurônios da vizinhança também sofram alterações, porém o quanto mais distante estiverem do neurônio vencedor, menor seja a alteração sofrida. Além disso, no algoritmo SOM, a vizinhança deve ter um raio maior no início do algoritmo e diminuir até que poucos ou nenhum neurônio faça parte da vizinhança a medida que as iterações acontecem. Assim, uma função que comumente é escolhida para se definir a vizinhança de um neurônio vencedor é a função gaussiana, com um valor de desvio padrão que seja variável ao longo das iterações. Ao centrar a função gaussiana no neurônio vencedor, tem-se uma função cujo valor máximo está nessa posição, e que diminui gradativa e simetricamente a medida que se afasta deste centro. A Equação (16) descreve a função de vizinhança.

$$h_{j,i(x)}(t) = \exp\left(-\frac{\|r_j - r_i\|^2}{2 * \sigma^2(t)}\right), t = 1, 2, \dots \quad (16)$$

Na Equação (16), para uma dada entrada x , $h_{j,i(x)}(t)$ é o peso da vizinhança do neurônio vencedor i no neurônio j na iteração t ; $\sigma^2(t)$ é o termo responsável por fazer com que o raio de vizinhança decaia ao longo do tempo; e r_j e r_i correspondem a posição no mapa dos neurônios j e i , respectivamente. É comum que se escolha um decaimento exponencial da vizinhança ao longo do tempo, de forma que $\sigma(t)$ seja definido como:

$$\sigma(t) = \sigma_0 \exp\left(-\frac{t}{\tau_1}\right), t = 1, 2, \dots \quad (17)$$

Na Equação (17), a constante σ_0 é o valor inicial da vizinhança; e τ_1 é uma constante de tempo que influencia na velocidade do decaimento. A constante σ_0 é escolhida de forma que, no início da formação do mapa auto-organizável, quase todos os neurônios façam parte da vizinhança.

A ação seguinte, de adaptação, é aquela na qual as sinapses sofrem as alterações. Essas mudanças devem ser realizadas de forma que as sinapses do neurônio vencedor e dos neurônios de sua vizinhança se aproximem do vetor de entrada apresentado a rede SOM. Para isso, é utilizada a fórmula da Equação (18):

$$w_j(t+1) = w_j(t) + \eta(t) * h_{j,i(x)}(t) * (x - w_j(t)) \quad (18)$$

Na Equação (18), o vetor w_j contém os pesos sinápticos do neurônio j ; $h_{j,i(x)}(t)$ é o peso da vizinhança calculado pela Equação (16); x é o vetor do dado de entrada; e $\eta(t)$ é a taxa de aprendizagem no tempo de iteração t . A taxa de aprendizagem deve diminuir ao longo das iterações e pode ser calculada pela equação a seguir:

$$\eta(t) = \eta_0 * \exp\left(-\frac{t}{\tau_2}\right), t = 1, 2, \dots \quad (19)$$

Na Equação (19), a constante η_0 é o valor inicial da taxa de aprendizagem e τ_2 é uma constante de tempo.

Acerca das etapas de ordenação e convergência, HAYKIN (2001) explica que a ordenação topológica do mapa auto-organizável acontece durante a fase de ordenação, que deve durar, pelo menos, 1000 iterações. Já a fase de convergência, segundo HAYKIN (2001), é a responsável por realizar um ajuste fino das sinapses, de forma a melhorar a representação estatística dos padrões dos dados no mapa. A fase de convergência, segundo o autor, deve ter, no mínimo, 500 vezes o número de neurônios da rede. Ele ainda faz algumas observações quanto aos valores ideais dos parâmetros de tempo, do início da vizinhança e da taxa de aprendizagem. O autor define que a taxa de aprendizagem deve iniciar o treinamento do mapa com um valor próximo de 0,1 e estar na ordem de 0,01 durante a fase de convergência. Quanto a vizinhança, como já foi dito, a mesma deve começar abrangendo quase todos os neurônios e se reduzir a 1 ou nenhum neurônio na fase de convergência. Assim, HAYKIN (2001) sugere definir o valor inicial da vizinhança como o raio do mapa e calcular τ_1 para que durante a fase de convergência a mesma seja composta por 1 ou nenhum neurônio.

3. REVISÃO BIBLIOGRÁFICA

Com o objetivo de monitorar a integridade de equipamentos, diversos pesquisadores desenvolveram trabalhos que utilizam dados de emissão acústica em conjunto com métodos de análise de dados. As Seções 3.1 e 3.2, a seguir, apresentam, trabalhos que utilizaram técnicas de análise de dados com aprendizado supervisionado e com aprendizado não-supervisionado, respectivamente, tendo como finalidade analisar a integridade de equipamentos, os tipos de defeitos ocorridos e as fases destes defeitos.

3.1. APRENDIZADO SUPERVISIONADO

As redes neurais realizam um aprendizado supervisionado quando possuem um “professor” que fornece um conjunto correto de pares de entradas e saídas para treinar a rede. Em outras palavras, um conjunto de amostras de entrada é fornecido para a rede, e, para cada amostra, a rede gera um valor de saída que é comparado com o valor ideal apresentado pelo “professor”. Os valores de saída gerados pela rede e os esperados são comparados e sua diferença constitui o erro, que é, então, utilizado para ajustar os parâmetros da rede. Caso seja fornecida para o treinamento da rede uma quantidade suficiente de exemplos de pares de entrada e saída, e o treinamento ocorra por um tempo

longo o bastante, de forma que a rede consiga reproduzir adequadamente o conhecimento do professor, amostras de entrada não utilizadas no treinamento podem ser aplicadas na rede e a mesma fornecerá valores corretos de saída. (HAYKIN, 2001).

YUKI E HOMMA (1996) treinaram uma rede neural artificial utilizando como entrada formas de onda simuladas por um sensor piezoelétrico de cerâmica e conseguiram, com esta rede, determinar a forma de onda correta gerada por uma determinada propagação de trinca.

Da SILVA (2004) treinou redes neurais artificiais para classificar tipos de defeitos de solda presentes em radiografias de junta de solda. Como parâmetros de entrada da rede, foram utilizadas características geométricas calculadas a partir das radiografias empregadas na pesquisa. Através de um estudo da relevância dos parâmetros de entrada da rede, o autor demonstrou que era possível retirar alguns parâmetros de entrada sem afetar o seu desempenho, provando que o importante é a qualidade e não a quantidade de parâmetros a serem empregados.

Da SILVA *et al.* (2006) desenvolveram um trabalho em que sugerem que o crescimento de trincas em dutos pressurizados pode ser dividido em duas fases: sem propagação e com propagação. Em sua pesquisa, foram analisados parâmetros de emissão acústica gerados em um experimento no qual uma trinca foi inserida em um duto pressurizado. Redes neurais foram treinadas para classificar as fases de propagação do defeito, e se conseguiu obter 92% de sucesso na identificação das classes. Os parâmetros com os quais SILVA *et al.* trabalharam foram tempo de subida, contagem, energia, tempo de duração, amplitude e ASL (*Average Signal Level*), além da indicação de qual sensor havia captado o sinal EA, uma vez que foram utilizados diversos sensores posicionados em lugares diferentes do corpo de prova. Em suas pesquisas, PINTO (2012) propôs que

a classe com propagação fosse dividida em duas, uma de propagação estável e outra de propagação instável, e as redes neurais que treinou chegaram a alcançar até 86% de acerto de classificação. Mais tarde, PINTO (2014) sugeriu que, ao invés de realizar uma classificação rígida, em que um sinal só pode pertencer a uma classe, fosse feita uma classificação probabilística, desenvolvendo as curvas de Probabilidade de Propagação (PoP), que indicam a probabilidade que uma amostra tem de pertencer a determinada classe. Os parâmetros utilizados por Pinto (2012, 2014) como entradas dos classificadores foram os mesmos 19 parâmetros retirados dos sinais de EA utilizados no trabalho aqui desenvolvido, que serão descritos na Tabela 2 da Seção 4.1.

Em seus estudos, KRAL *et al.* (2013) começaram a pesquisar o desenvolvimento de um sistema de monitoramento em tempo real da integridade de aeronaves possível de ser utilizado durante voos. Os autores treinaram redes neurais *feedforward* capazes de calcular o comprimento que uma trinca cresce ao sofrer um estresse. Os dados utilizados na pesquisa foram obtidos em experimentos realizados com pratos chatos de alumínio como corpos de prova, na lateral de cada qual foi cortada uma trinca, e sobre os quais foi aplicada uma força de tração. Como entrada das redes foi utilizada uma medida desenvolvida pelos pesquisadores que se baseia no histograma das amplitudes dos eventos de emissão acústica ocorridos em uma determinada janela de tempo. Além de conseguirem desenvolver uma rede capaz de medir o crescimento da trinca, os autores também apresentaram fortes indícios de que é possível encontrar a posição da falha em um corpo de prova através da comparação da amplitude de uma mesma onda acústica captada por sensores posicionados em diferentes lugares em relação à trinca.

DAI *et al.* (2014) realizaram uma análise de quais parâmetros, retirados de sinais provenientes de emissões acústicas geradas por trincas em dutos, são mais relevantes para modelar e treinar uma rede neural *feedforward*, cujo objetivo é diferenciar sinais

provenientes de trincas com propagação dos sinais de trincas que não estão se propagando. Os parâmetros utilizados pelos autores foram: tempos de chegada, amplitude, taxa de energia, contagem, contagem de subida (ou contagem até o pico), tempo de duração, tempo de subida, tensão RMS, nível médio de sinal e energia.

O trabalho de YANG et al. (2015) conseguiu desenvolver um classificador capaz de identificar quatro diferentes tipos de trincas em revestimentos de barreira térmica. Para isso, foram obtidos os coeficientes de energia de *wavelet* dos sinais de emissão acústica provenientes das trincas, e utilizou-se esses coeficientes como entrada de uma rede neural treinada pelo algoritmo *backpropagation* com o objetivo de identificar os tipos de trinca.

Em suas pesquisas ZHANG et al. (2017) desenvolveram um classificador para avaliar a condição de trilhos ferroviários utilizando sinais de emissão acústica. Foi desenvolvida uma rede neural convolucional cujos parâmetros de entrada foram características de frequência extraídas de uma Transformada Rápida de *Fourier* dos sinais de emissão acústica e cuja saída classificava cada entrada como ‘estado seguro’ ou ‘estado não seguro’. Para evitar erros de avaliação da integridade do material causados por classificações errôneas do classificador, os autores desenvolveram uma avaliação probabilística dos resultados. Cada saída da rede neural convolucional é avaliada conjuntamente com um grupo de saídas da rede, cujas entradas são amostradas de emissão acústica temporalmente próximas do sinal que se deseja avaliar, e um cálculo de probabilidade é realizado para definir qual a provável classe do conjunto de amostras sob avaliação.

GAJA e LIOU (2018) utilizaram parâmetros de sinais de emissão acústica para identificar e classificar defeitos em peças construídas ou reparadas por deposição de metal a laser. Em seu trabalho, puderam observar que o nível dos sinais de ruído gerados nesse

tipo de aplicação é muito inferior ao nível dos sinais obtidos devido à formação de defeitos. Após identificar a ocorrência de defeitos através do nível dos sinais, os parâmetros dos sinais identificados como defeitos foram utilizados para desenvolver dois classificadores que deveriam ser capazes de identificar o tipo de defeito associado a cada sinal (poro ou trinca). Um dos classificadores utilizou o método de regressão logística e o outro de rede neural treinada pelo algoritmo *backpropagation*, e ambos foram capazes de identificar o tipo de defeito em questão. Os parâmetros de EA utilizados foram amplitude, curtose, energia, contagem, duração, tempo de subida e frequência de pico.

3.2. APRENDIZADO NÃO SUPERVISIONADO

O aprendizado não supervisionado, de acordo com HAYKIN (2001) é uma forma de aprendizado sem professor, não existindo exemplos a serem aprendidos pelas redes. Segundo BECKER (1991), após as redes não-supervisionadas terem aprendido os padrões estatísticos do conjunto de dados de entrada, as mesmas conseguem criar representações para estes dados, possivelmente, tornando-os mais fáceis de serem interpretados.

GODIN *et al.* (2004) utilizaram a análise de sinais de emissão acústica para identificar defeitos em corpos de prova de resina pura e de compósitos de fibra de vidro/poliéster unidirecional que foram submetidos a testes de tensão. Para auxiliar a identificar os tipos de danos e para definir quais as classes dos dados, foram realizadas clusterizações através dos métodos não-supervisionados *k-means* e mapa auto-

organizável de *Kohonen*. Os dados classificados de acordo com as técnicas não-supervisionadas foram utilizados para desenvolver classificadores supervisionados pelo método de *k*-vizinhos mais próximos (*k-Nearest Neighbours*). Em um segundo trabalho, GODIN *et al.* (2005) utilizaram a mesma metodologia para identificar danos em compósitos de vidro/epóxi submetidos a testes de tensão. Durante os testes foram adquiridos sinais de EA, que foram atribuídos a três diferentes tipos de danos identificados ao longo dos testes. Novamente, os pesquisadores treinaram um mapa auto-organizável de *Kohonen* e, em seguida, clusterizaram os neurônios do mapa utilizando o algoritmo de *k-means* para identificar quais regiões do mapa eram ativadas por qual tipo de defeito. O número ideal de *clusters* a ser empregado foi definido através da análise do índice de *Davies Bouldin*. De acordo com os autores, essa metodologia poderia servir como uma perspectiva de como monitorar danos em componentes estruturais em tempo real. Em ambos os trabalhos, as variáveis utilizadas foram amplitude, duração, tempo de subida, contagem, contagem até o pico e energia.

Em sua pesquisa MAREC *et al.* (2009) desenvolveram um classificador para identificar falhas em materiais de concreto-polímero. Para desenvolver o classificador foi utilizado o método não-supervisionado de clusterização *c-means fuzzy*, conjuntamente com o método de análise de componentes principais (*Principal Component Analysis - PCA*). Como entrada do classificador, foram utilizados diversos parâmetros de emissão acústica, como amplitude, energia, tempo de duração, tempo de subida e contagem. A partir dos resultados obtidos com o classificador, os autores puderam observar o desenvolvimento, ao longo do tempo, dos tipos de falha ao longo dos testes realizados até a fratura dos materiais.

PINTO (2014) sugeriu que fosse utilizado o algoritmo de *k-means* para identificar sinais de emissão acústica que foram, possivelmente, gerados por ruído ou erroneamente

classificados entre as classes de propagação de trincas em dutos rígidos. Os dados limpos deveriam, em seguida, ser aplicados no treinamento de uma rede neural supervisionada. Para isso, 19 parâmetros de EA foram aplicados ao algoritmo *k-means* com diferentes quantidades de *clusters*. Os parâmetros utilizados foram os mesmos empregados neste trabalho e que estão descritos na Tabela 2 da Seção 4.1. Em seguida, os dados de cada *cluster* foram analisados de acordo com a classificação previamente definida da fase de propagação da trinca. Apenas os sinais de *clusters* compostos por dados de apenas uma classe foram mantidos no conjunto de dados, o restante foi excluído, por acreditar se tratar de dados de ruído ou de sinais cuja classe não foi corretamente identificada, se tratando de dados que, possivelmente, atrapalhariam o treinamento de um classificador. Como resultado, o autor encontrou uma maior performance de classificação das redes treinadas de maneira supervisionada com o conjunto de dados limpo do que com o conjunto de dados que incluía os dados excluídos.

CRIVELLI *et al.* (2014) desenvolveram um classificador não-supervisionado, utilizando conjuntamente o mapa auto-organizável de *Kohonen* e *k-means*, para identificar diferentes tipos de falhas em corpos de prova de fibra de vidro pultrudada. Para treinar o mapa auto-organizável de *Kohonen*, foram utilizados como entradas da rede parâmetros de sinais de emissão acústica captados em teste de tração realizados com amostras desse material. Os parâmetros mencionados foram: amplitude, tempo de chegada, tempo de duração, contagem, energia, frequência de pico e centro de massa da Transformada Rápida de *Fourier*. O mapa das distâncias entre neurônios obtido foi clusterizado utilizando o algoritmo *k-means*, sendo a quantidade de *clusters* definida a partir da análise de índices que medem o desempenho da clusterização. Os diferentes *clusters* encontrados no mapa de distâncias dos neurônios mostraram correspondência com diferentes tipos de defeitos. Mesmo ao se testar dados provenientes de ensaios não

utilizados no treinamento da rede SOM, foi possível identificar corretamente a que tipo de falha correspondia cada sinal de EA.

BOUSSETA *et al.* (2017) realizaram uma pesquisa para identificar tipos de defeitos em enrolamento de filamento de compósito de vidro/poliéster através da análise de sinais de emissão acústica. Para isso, realizaram a identificação dos tipos de defeitos ocorridos em um corpo de prova durante um teste de tensão e captaram os sinais de emissão acústica gerados ao longo do teste. Utilizando como entradas os parâmetros de emissão acústica tempo de subida, energia, tempo de duração, frequência média, tensão RMS, frequência de reverberação e frequência de iniciação, os autores aplicaram os métodos *k-means* e mapa auto-organizável de *Kohonen* para identificar *clusters* formados por cada um dos tipos de defeitos ocorridos. Também nesse trabalho, a quantidade ideal de *clusters* a ser utilizado no algoritmo de *k-means* foi definido através do índice de *Davies Bouldin*. Ao final do trabalho, os autores concluíram que ambos os métodos apresentaram o mesmo resultado.

GAJA e LIOU (2017) analisaram a formação de defeitos em peças formadas por deposição de metal a laser. Para isso, estes pesquisadores aplicaram o algoritmo *k-means* a sete parâmetros de sinais de emissão acústica: amplitude, duração, curtose, energia, contagem, tempo de subida e frequência de pico. O objetivo do trabalho foi separar em *clusters* os sinais detectados e identificar se os mesmos se tratavam de sinais provenientes de poros ou de trincas. Com esse estudo, provaram ser possível detectar a presença desses defeitos e identificar de qual dos dois tipos se tratava. Os autores realizaram ainda uma análise das características dos parâmetros de sinais de emissão acústica dos defeitos em questão.

KIM *et al.* (2018) realizaram testes de tensão em diferentes materiais metálicos, obtendo a curva de tensão pela deformação e os sinais de emissão acústica de cada um deles. Em seguida, aplicaram aos parâmetros amplitude, energia e frequência de pico, retirados dos sinais de EA de cada um dos testes, separadamente, o algoritmo do mapa auto-organizável de *Kohonen*. Todos os mapas obtidos para o algoritmo SOM indicaram 3 *clusters* com características distintas. Ao comparar as curvas de tensão pela deformação com os sinais de emissão acústica registrados, os autores puderam constatar que os sinais de EA foram agrupados de forma similar as fases das curvas de todos os testes realizados.

4. METODOLOGIA

A seguir são descritas as etapas utilizadas no desenvolvimento do trabalho.

4.1. AQUISIÇÃO DOS DADOS

Os dados utilizados foram obtidos em ensaios realizados no Laboratório de Metalurgia Física (LAMEF) da Universidade Federal do Rio Grande do Sul (UFRGS). Os mesmos fazem parte do projeto “Inspeção de Dutos Rígidos”, realizado em conjunto com o CENPES (Centro de Pesquisa Leopoldo Américo Miguez de Mello) da Petrobras (Petróleo Brasileiro S.A.) e a UFRGS. Os relatórios apresentados pelo LAMEF à Petrobras descrevem a parte experimental empregada (CLARKE e JACQUES, 2016). A dimensão da trinca foi monitorada por um transdutor de TOFD (transdutor de ultrassom) e os parâmetros de emissão acústica foram adquiridos pelo controlador Disp 16C com 4 sensores R151-AST do fabricante PAC (*Physical Acoustic*).

Em cada experimento foi utilizado um corpo de prova de aço API XL série 60, 20 polegadas de diâmetro, 0,0145 m de espessura e 40 m de comprimento, no qual foi inserida uma pré trinca. Os experimentos consistiram de testes hidrostáticos, um total de quatro, nos quais a pressão foi elevada de acordo com as normas. Foram intercalados períodos de aumento de pressão com períodos de pressão estabilizada até ocorrer o

rompimento do duto, como pode ser visto na Figura 9. Por questões da logística empregada nos ensaios, apenas o terceiro e o quarto ensaios foram capazes de adquirir dados com o equipamento do fabricante PAC. O terceiro ensaio foi denominado de CP3 e o quarto ensaio de CP4.

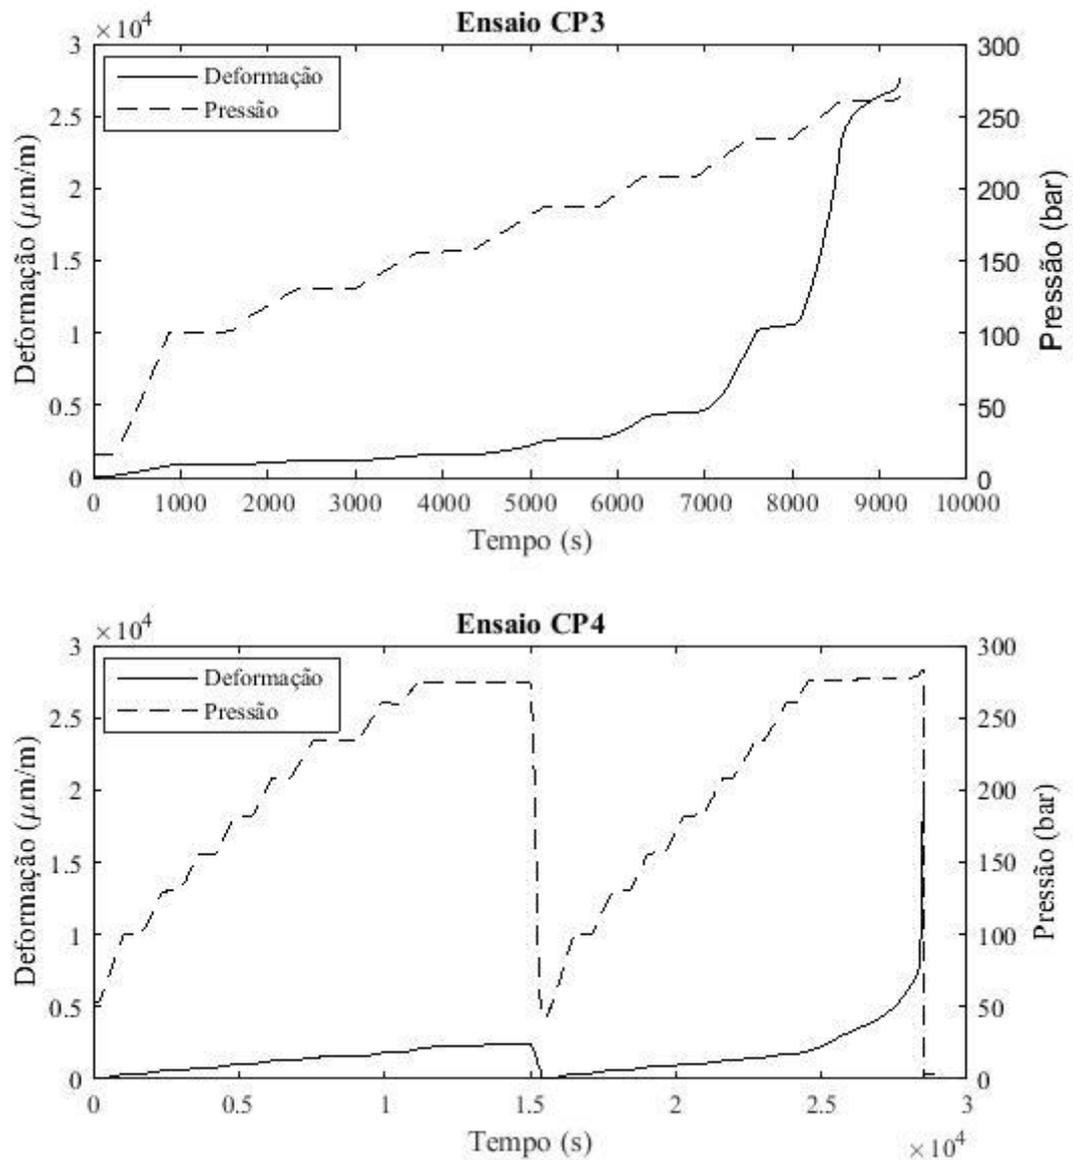


Figura 9 – Gráficos da Pressão e da Deformação ao Longo do Tempo dos Testes

Hidrostáticos dos Ensaios CP3 e CP4.

No caso do ensaio CP4, em que o duto não rompeu até a ultrapassagem da pressão máxima na qual se esperava que o rompimento ocorresse, o duto foi despressurizado e o teste reiniciado.

A Tabela 1, abaixo, descreve os ensaios que geraram os dados utilizados por este trabalho.

Tabela 1 – Resumo dos Ensaios realizados pelo LAMEF (CLARKE e JACQUES, 2016)

Ensaio	Data	Profundidade Inicial da trinca (mm)	Observações	Pressão Ruptura
Ensaio 3	06/11/2015	6,6	Ruptura no 1º ciclo	264 bar
Ensaio 4	23/05/2016	7,0	Ruptura no 2º ciclo	283 bar

Os quatro sensores da PAC utilizados nos ensaios CP3 e CP4 foram posicionados de forma simétrica em relação a trinca pré inserida em cada um dos dutos, de forma que dois dos sensores estivessem a uma mesma distância da trinca e os outros dois também estivessem a uma distância igual, porém diferente da dos dois primeiros. A Figura 10 apresenta uma representação simbólica da disposição dos sensores nos corpos de prova.

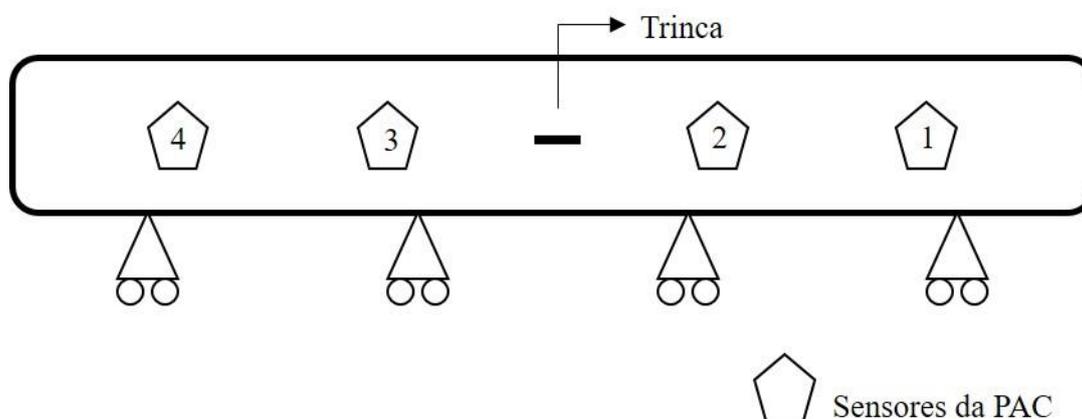


Figura 10 – Posicionamento dos sensores ao longo do duto.

Os 19 parâmetros de emissão acústica adquiridos podem ser vistos a seguir na Tabela 2 (Physical Acoustics Corporation, 2011).

Tabela 2 – Parâmetros de Emissão Acústica

Parâmetro	Descrição
Tempo de Subida	Intervalo de tempo entre a primeira ultrapassagem do <i>threshold</i> e a amplitude máxima de um evento de emissão acústica.
Contagem	Número de vezes que o sinal ultrapassa o <i>threshold</i> durante um evento de emissão acústica.
Energia	A mesma definição de <i>Sig-Strength</i> , porém com diferente sensibilidade, tamanho e <i>range</i> .
Duração	Intervalo de tempo entre a primeira ultrapassagem do <i>threshold</i> e o final da última ultrapassagem do <i>threshold</i> em um evento de emissão acústica.
Amplitude	Amplitude máxima de um evento de emissão acústica, medida em dB.
A-Freq	Frequência média, definida como: (Contagem / Duração).
RMS	<i>Root Mean Square</i> (RMS) é a média do sinal retificado, medida em volts.
ASL	<i>Average Signal Level</i> (ASL) é uma medida parecida com RMS, porém é uma medida da média da variação de amplitude, medida em dB.
Contagem até o Pico	Número de vezes que o sinal ultrapassa o <i>threshold</i> do início de um evento de emissão acústica até o pico de amplitude máxima.
R-Freq	Frequência de reverberação, definida como: (Contagem – Contagem até o Pico) / (duração – tempo de subida).
I-Freq	Frequência de iniciação, definida como: (Contagem até o Pico / Tempo de Subida).
<i>Sig-Strength</i>	Integral do sinal de tensão retificado sobre a duração da forma de onda da emissão acústica.
Energia Absoluta	Parâmetro derivado da integral do sinal de tensão ao quadrado sobre a duração da forma de onda da emissão acústico dividida pela resistência de referência (10 K Ω).
PPF-1	Parâmetro de potência parcial 1 (<i>Partial Power Feature 1</i>) é um parâmetro calculado como uma porcentagem. Ele é definido como a soma do espectro da potência em uma faixa de frequência, especificada pelo responsável pela execução do ensaio de EA, dividida pela potência total, considerando todas as frequências, e o resultado multiplicado por 100. PPF-1 é a porcentagem calculada para a primeira faixa do espectro.
PPF-2	Parâmetro de potência parcial 2, em que é calculada a porcentagem para a segunda faixa do espectro.
PPF-3	Parâmetro de potência parcial 3, em que é calculada a porcentagem para a terceira faixa do espectro.
PPF-4	Parâmetro de potência parcial 4, em que é calculada a porcentagem para a quarta faixa do espectro.

C-Freq	Neste parâmetro é calculada uma Transformada Rápida de <i>Fourier</i> (<i>Fast Fourier Transform</i> - FFT), e, para cada elemento da FFT é realizado o seguinte cálculo: $\Sigma(\text{magnitudo} * \text{frequência}) / \Sigma(\text{magnitudo})$.
P-Freq	Frequência de pico, definida como o ponto do espectro de frequência que possui a maior magnitude.

4.2. TRATAMENTO DOS DADOS

A fase de pré-processamento dos dados seguiu as etapas apresentadas no fluxograma da Figura 11.

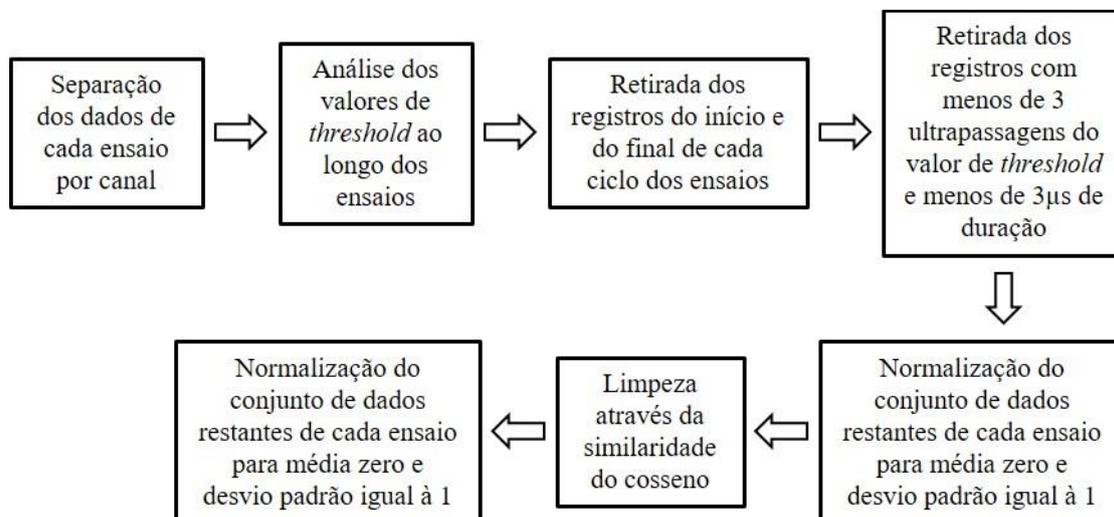


Figura 11 – Fluxograma do Passo a Passo do Pré-Processamento dos Dados de Cada Ensaio.

Como apresentado no fluxograma da figura a cima, a fase de pré-processamento dos dados iniciou-se por separar, para cada ensaio, os registros provenientes de cada sensor (canal), analisando-se a quantidade de dados disponível para cada um deles.

Em seguida, foram analisados os valores de *threshold* ao longo dos ensaios, e o tempo de chegada de cada sinal, a fim de buscar a identificação de possíveis sinais de ruído.

Como passo subsequente, foram retirados os registros das fases iniciais de enchimento dos dutos e os registros dos finais dos ciclos, a partir do momento em que os dutos começam a ser despressurizados. Esses registros foram retirados por se tratarem de ruídos gerados pelo atrito do líquido com o duto.

Depois, considerando a explicação de MIX (2005), segundo a qual sinais com menos de 3 ultrapassagens do valor de *threshold* e menos de 3 μ s são relacionados a ruídos, todos os registros, tanto do ensaio CP3 quanto do CP4, que não ultrapassaram o valor de *threshold* por no mínimo 3 vezes e também duraram menos de 3 μ s foram eliminados.

Em seguida, como a faixa de valores de cada umas das 19 variáveis é muito diferente, os dados foram normalizados para média zero e desvio padrão 1, de forma a garantir que todas as variáveis tivessem a mesma influência no treinamento das redes.

Por fim, como forma de visualizar a similaridade e a limpeza dos dados, decidiu-se por utilizar a técnica de *data image*. A técnica de *data image* consiste em uma forma visual de apresentar matrizes de similaridade ou de distância dos registros, sendo, segundo MARCHETE (2003), um bom método para identificar *outliers*. Neste trabalho decidiu-se por utilizar a similaridade do cosseno, que é definida como (HAN, 2012):

$$sim_c(v, u) = \frac{\langle v, u \rangle}{\|v\| \|u\|}, \quad (20)$$

Onde:

$$\langle v, u \rangle = \sum_{i=1}^p v_i * u_i \quad (21)$$

$$\|v\| = \sqrt{\langle v, v \rangle} \quad (22)$$

Para a qual v e u são dois dos registros do conjunto de dados, e p é o número de atributos (parâmetros) de tais registros.

As matrizes apresentadas pelo método de *data image* são matrizes quadradas, com dimensões iguais à quantidade de registros do conjunto de dados e simétricas em relação à diagonal principal. Essas matrizes apresentam o valor da similaridade de cada registro do conjunto de dados em relação a todos os outros. Quanto mais próximo de 1 for o valor da similaridade do cosseno, mais semelhantes são dois registros, por outro lado, quanto mais próximo de -1, menos parecidos são os mesmos. Os valores da diagonal principal se referem à similaridade de cada registro em relação a ele mesmo, de forma que precisam apresentar valor igual à 1. Mas a observação mais importante a ser feita nessas matrizes se refere à qualidade dos agrupamentos encontrados no conjunto de dados.

Como, segundo a hipótese levantada, as fases de propagação da trinca evoluem ao longo do tempo, passando de sem propagação, para com propagação estável e, por fim, terminando em propagação instável, e os registros foram inseridos na matriz de similaridade do cosseno na mesma ordem em que foram captados no tempo, era esperado que os registros próximos possuíssem uma maior similaridade do que os distantes, e que agrupamentos fossem visualizados nas proximidades da diagonal principal.

Na tentativa de se realizar uma limpeza dos dados, foi desenvolvida uma metodologia baseada na similaridade dos registros próximos. Como é esperado que cada registro seja mais similar aos registros pertencentes à mesma classe que a dele, ou seja, aos registros próximos, aqueles mais similares a registros distantes do que a próximos foram eliminados. Para se fazer essa análise, as similaridades do cosseno calculadas em relação a cada registro foram divididas em 10 partições, a primeira partição sendo

formada pelas similaridades em relação ao primeiro décimo de registros captados, a segunda partição em relação ao segundo décimo, e assim por diante. Em seguida, foram calculadas as médias dos valores das similaridades do cosseno presentes em cada partição. A partição com o valor mais alto de média de similaridade significa que o registro é, em média, mais próximo aos registros com os quais o mesmo está sendo comparado dentro desta partição do que com os registros das demais partições. Assim, o ideal é que a maior média seja obtida pela partição formada pelo décimo de registros que também contém a comparação com o próprio registro em análise. Foram considerados como sinais de emissão acústica os registros cuja partição que obteve a maior média foi a que contém o próprio registro ou uma das partições que eram vizinhas imediatas. O restante dos registros foi considerado como ruído e eliminado.

Foi decidido utilizar 10 partições por ter sido a quantidade de partições utilizadas, após testar algumas quantidades diferentes, que proporcionou a visualização de agrupamentos mais fortes próximo à diagonal principal, após a realização desta limpeza.

O fluxograma da Figura 12 apresenta o passo a passo das etapas necessárias para a realização desta limpeza através da similaridade do cosseno.

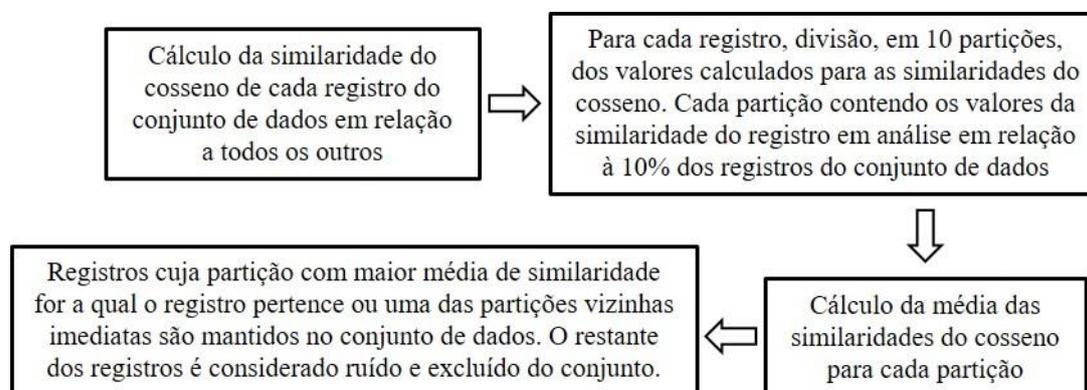


Figura 12 – Fluxograma do Passo a Passo da Limpeza através da similaridade do Cosseno.

A Figura 13 tenta exemplificar a metodologia de limpeza empregada.

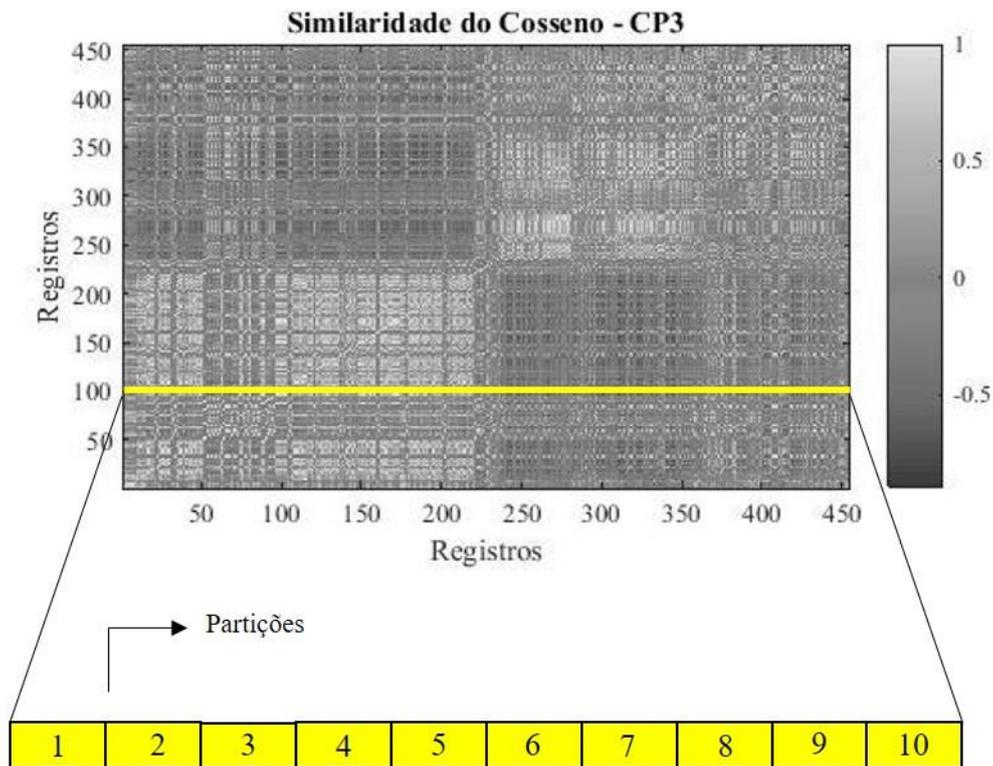


Figura 13 – Exemplo de processo de limpeza dos registros utilizando similaridade do cosseno.

A matriz de similaridade do cosseno utilizada na Figura 13 é uma das matrizes de similaridade do cosseno apresentadas na seção de resultados para os dados do ensaio CP3. Como pode ser notado pela figura, esta matriz está invertida, ou seja, o eixo horizontal está orientado da esquerda para a direita e o eixo vertical de baixo para cima. Nesta imagem, a linha em amarelo representa os pontos da matriz da similaridade do cosseno do registro de número 100 em relação a todos os outros registros. Como o tamanho do conjunto é igual à 455 (que também é a dimensão da matriz), algumas partições são compostas por 45 e outras por 46 registros, já que 455 dividido por 10 resulta em 45,5. Dessa forma, a partição 1 possui o valor das similaridades do cosseno do registro 100 em relação aos registros 1 até 45, a partição 2 em relação aos registros 46 até 91, a partição

3 em relação aos registros 92 até 136, e assim por diante. Como o registro de número 100 pertence à partição 3, o mesmo não será considerado ruído se a partição com maior valor de média de similaridade do cosseno for a 2, a 3 ou a 4. Esse processo é realizado para cada um dos registros do conjunto de dados.

Os dados restantes após essa última limpeza foram, novamente, normalizados para média zero e desvio padrão 1.

4.3. DEFINIÇÃO DAS CLASSES

De acordo com PINTO (2014), as fases de propagação de trincas em corpos metálicos podem ser definidas como sem propagação (SP), com propagação estável (PE) e com propagação instável (PI). Segundo essa teoria, a fase sem propagação consiste na região em que, mesmo com um esforço mecânico sendo aplicado sobre o corpo, a dimensão da falha não se altera macroscopicamente. A fase com propagação estável é aquela na qual ocorre um aumento macroscópico da trinca a medida que o esforço mecânico aumenta, enquanto na fase de propagação instável, a trinca se amplia, se a pressão não diminuir, ainda que a mesma não aumente.

Para se encontrar os pontos de transição entre as classes, foram treinadas redes neurais para classificar os sinais em duas classes, variando o ponto de corte entre essas classes no tempo, e encontrando qual apresentava o menor erro de classificação. Para treinar cada uma dessas redes, e garantir o balanceamento entre as classes, para cada ponto de corte testado, foram selecionadas a mesma quantidade de dados de antes e de

depois do ponto, sendo os dados de antes pertencentes a classe de teste 1 e os de depois a classe de teste 2. O primeiro ponto de corte testado para os dados de cada um dos ensaios foi 10º sinal captado nos respectivos ensaios, dentre os dados restantes após todas as limpezas realizadas. Assim, para este primeiro ponto, foram utilizadas as 10 primeiras amostras para a classe de teste 1 e as 10 seguintes para a classe de teste 2. O ponto seguinte foi o 15º registro, e, logo, as 15 primeiras amostras compuseram a classe de teste 1 e as 15 seguintes a classe de teste 2. E assim por diante, sempre variando o ponto de corte de 5 em 5, até o final do conjunto de amostras. Além disso, em determinado momento, a quantidade de amostras disponíveis a frente do ponto de corte passa a ser menor do que a quantidade de antes. Nesse instante, o subconjunto de dados utilizados para o treinamento passa a conter todas as amostras de depois do ponto de corte para a classe de teste 2 e essa mesma quantidade de dados é selecionada imediatamente antes do ponto de corte para formar a classe de teste 1.

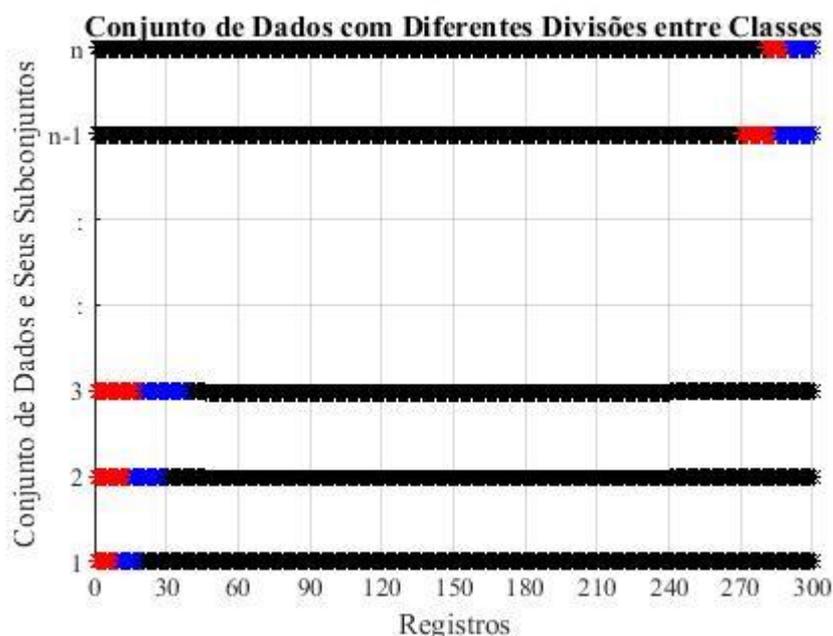


Figura 14 – Três Primeiros e Dois Últimos Subconjuntos de Dados Utilizados para Avaliar Possíveis Pontos de Corte para os Dados de um Ensaio Hipotético.

A Figura 14 ilustra os registros que compõem as 3 primeiras (1 a 3) e as duas últimas (n e $n-1$) duplas de subconjuntos utilizados para treinar, validar e testar as redes neurais responsáveis por avaliar os três primeiros e os dois últimos pontos testados para a divisão de classes dos registros de um ensaio hipotético composto por 300 registros. Os pontos em preto se referem aos registros que não foram utilizados para treinar, testar ou validar as redes responsáveis por avaliar um dado ponto de corte. Os seguimentos em vermelho são os registros do subconjunto formado por dados de antes do ponto de corte (classe de teste 1) e os seguimentos em azul se referem aos registros que formam o subconjunto com dados de depois do ponto de corte a ser testado (classe de teste 2).

O objetivo é que quando o ponto de corte fizer com que dados de uma das classes SP, PE ou PI estejam presentes em ambos os subconjuntos de antes e de depois do ponto de corte utilizados no treinamento das redes que testam o ponto de corte em questão, o percentual de acerto dessas redes seja menor, já que dados com um mesmo padrão numérico vão estar em ambos os subconjuntos utilizados para treinar as redes, fazendo com que as mesmas não sejam capazes de diferenciá-los. Assim, quando o ponto escolhido como transição dividir os dados de forma com que de um lado fiquem só os dados de uma das classes (SP, PE ou PI) e do outro os dados de uma ou de duas das outras duas classes restantes, o erro de classificação das redes treinadas para este ponto de corte vai atingir um mínimo quando comparado ao erro das outras redes. Como existe um ponto ideal que divide as classes SP e PE e outro que divide as classes PE e PI, a ideia é que sejam encontrados dois pontos de corte em que as redes treinadas para os mesmos apresentem valores de erro de classificação relativamente menores do que das outras redes treinadas com pontos de transição diferentes. Ao se plotar um gráfico do erro de classificação das redes pelo ponto de corte testado para as classes, é esperado que esse gráfico apresente dois vales, um para cada um desses dois pontos de transição ideais.

A Figura 15 apresenta um fluxograma do resumo do passo a passo a ser seguido para a realização da divisão automática das fases de propagação da trinca.

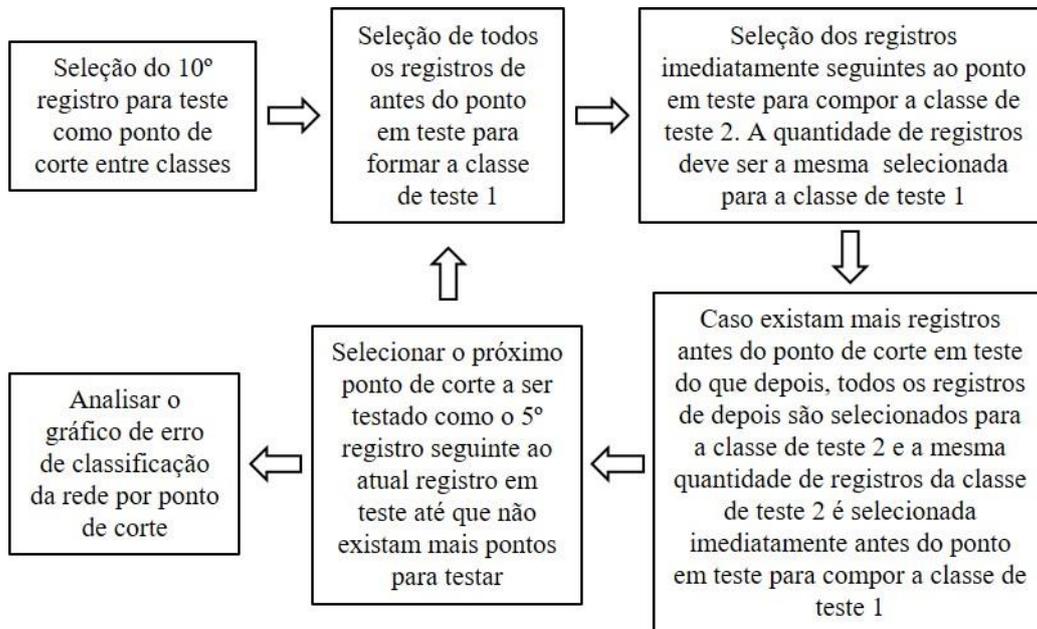


Figura 15 – Fluxograma do Passo a Passo da Divisão Automática das Fases de Propagação da Trinca.

4.4. REDE NEURAL FEEDFORWARD

As redes neurais *feedforward* utilizadas para encontrar os pontos de corte entre as classes foram compostas por 6 neurônios na camada intermediária e dois neurônios na camada de saída, todos com tangente hiperbólica como função de ativação, de forma que as saídas da rede variaram entre -1 e 1. O tipo de treinamento foi o *backpropagation*, com gradiente descendente adaptativo com passo de treinamento inicial igual a 0,05, variando com fator de incremento de 1,05 e fator de decremento de 0,9.

As redes classificadoras utilizadas para classificar os registros em uma das classes de propagação possuíram a mesma quantidade de neurônios na camada de saída que a quantidade de classe existentes. Para encontrar o número ideal de neurônios na camada intermediária, foram testadas redes variando o número de neurônios de 1 até 15. A função de ativação de todos os neurônios também foi tangente hiperbólica. E, para o treinamento, foi testado o algoritmo *backpropagation* com gradiente descendente adaptativo com passo de treinamento inicial igual a 0,05, variando com fator de incremento de 1,05 e fator de decremento de 0,9, o algoritmo *backpropagation* com gradiente descendente com passo de treinamento constante e igual à 0,01 e o algoritmo *backpropagation* com otimização de *Levenberg-Marquardt*.

Os critérios de parada do treinamento das redes foram atingir dez mil épocas de treinamento ou o erro de validação aumentar por 6 épocas consecutivas.

Para validar os resultados, foi utilizado o método de validação cruzada com 5 partições, com 60% dos dados para treinamento, 20% para validação e 20% para teste.

4.5. REDE DO MAPA AUTO-ORGANIZÁVEL DE KOHONEN

Foram testadas algumas configurações de mapas auto-organizáveis de *Kohonen*, como mapas dimensionados com 3x4, 4x4, 3x5, 4x5, 5x5, 4x6, 5x6 e 6x6 neurônios. A vizinhança inicial foi escolhida de forma que, no início, todo o mapa fizesse parte da

vizinhança de todos os neurônios, portanto, começando por um valor que abrangesse a distância entre os dois neurônios mais afastados. A função de distância escolhida foi a euclidiana. Em relação ao número de épocas das fases de ordenação e de convergência, as mesmas foram definidas como iguais ou maiores que os valores mínimos recomendados por HAYKIN (2001), descritos na Seção 2.2.2.

Para o treinamento dessas redes foram utilizados, para cada um dos ensaios, todos os registros restantes após a limpeza de dados, normalizados para média zero e desvio padrão igual à 1.

4.6. ANÁLISE EM CONJUNTO

Considerando que podem ocorrer ruídos dentro do conjunto de dados mesmo após a limpeza dos registros e, também, para diminuir o percentual de registros erroneamente classificados pelas redes, foi realizada uma análise das saídas da rede em pequenos grupos.

Para cada registro que se desejava classificar, foram avaliadas conjuntamente com a saída da rede para este, as saídas da rede correspondentes aos 4 registros captados imediatamente antes do registro em questão durante o ensaio de Emissão Acústica.

Para cada registro em análise, e para cada neurônio da rede, foram somadas as saídas apresentadas para este registro e para os 4 registros imediatamente anteriores. A classe representada pelo neurônio que obteve o maior valor neste somatório foi

considerada como a classe do respectivo registro. Essa metodologia pode ser expressa pela Equação (23). Nesta equação, $c(x)$ é a classe definida para o registro x_n pela análise em conjunto, $Y_j(x_n)$ é a saída do neurônio j para o registro x_n , $Y_j(x_{n-i})$ é a saída do neurônio j para o registro x_{n-i} , e l é o número de neurônios da camada de saída, que é igual ao número de fases de propagação da trinca. As variáveis x_{n-4} a x_{n-1} são os quatro registros captados imediatamente antes do registro x_n durante o ensaio de emissão acústica.

$$c(x_n) = \underset{j}{\operatorname{arg\,max}} \|Y_j(x_n) + \sum_{i=1}^4 Y_j(x_{n-i})\|, \quad j = 1, 2, \dots, l \quad (23)$$

4.7. RELEVÂNCIA DAS VARIÁVEIS

Por último, foi realizado um estudo da relevância das variáveis de entrada da rede.

Para isso, foi utilizado o cálculo da Equação (24), a seguir:

$$R_i = \frac{1}{n} * \sum_{n=1}^N (m_n - M_{in}) , \quad (24)$$

Onde R_i é a relevância do parâmetro i , m_n é o total de acerto da rede n e M_{in} é a porcentagem de acertos atingida pela rede n ao se substituir o valor do parâmetro i de cada registro de entrada pelo valor médio deste parâmetro para todos os registros do conjunto de dados. O valor de N é igual à quantidade de redes treinadas que estão sendo utilizadas para estudar a relevância dos parâmetros. Nesta pesquisa, foram utilizadas no estudo da relevância das variáveis, para cada ensaio, todas as redes neurais *feedforward* treinadas na validação cruzada para realizar a classificação das fases de propagação de

trincas. Como foi realizada validação cruzada de 5 partições, cada partição com 20% dos dados, e foram utilizados 60% dos dados para treinamento, 20% para validação e 20% para teste, o que resulta em três partições para treinamento, uma para validação e uma para teste, a validação cruzada resultou no treinamento de 20 redes, que é igual ao número de combinações possíveis de partições nestas condições.

De acordo com SEIXAS *et al.* (1996), o teste de relevância mede o quão dependente a rede é de um parâmetro. Segundo os autores, ao substituir os valores de um parâmetro por seu valor médio para todos os registros, o objetivo é procurar quais parâmetros causam a maior diferença no desempenho da rede. Estes serão os parâmetros mais relevantes.

Quanto maior o valor absoluto de R_i , maior a influência do parâmetro i no resultado da rede. Caso esse valor seja positivo, significa que a sua retirada piora o percentual de acertos da rede. Por outro lado, se o valor for negativo, significa que a retirada desse parâmetro faz com que a rede melhore seu desempenho. Assim, quanto mais positivo for o valor de R_i , mais necessária é a sua utilização para o treinamento das redes.

Além de calcular a relevância dos parâmetros para a rede de uma forma geral, decidiu-se também por analisar a influência dos mesmos na eficiência de classificação de cada classe. Para isso, foi utilizada a seguinte equação:

$$R_{ij} = \frac{1}{n} * \sum_{n=1}^N (m_{jn} - M_{ijn}) , \quad (25)$$

Onde R_{ij} é a relevância do parâmetro i para a classe j , m_{jn} é o percentual de acertos da rede n para a classe j , e M_{ijn} é a porcentagem de acertos da rede n para a classe j ao se substituir o valor do parâmetro i de cada registro de entrada pelo valor médio deste

parâmetro para todos os registros do conjunto de dados. Novamente, N é a quantidade de redes treinadas que estão sendo utilizadas para estudar a relevância dos parâmetros.

5. RESULTADOS

As próximas seções apresentam os resultados obtidos para cada etapa realizada ao longo deste trabalho, a medida que foram aplicadas as etapas descritas na seção de metodologia. O fluxograma da Figura 16 apresenta a sequência de ações realizadas.

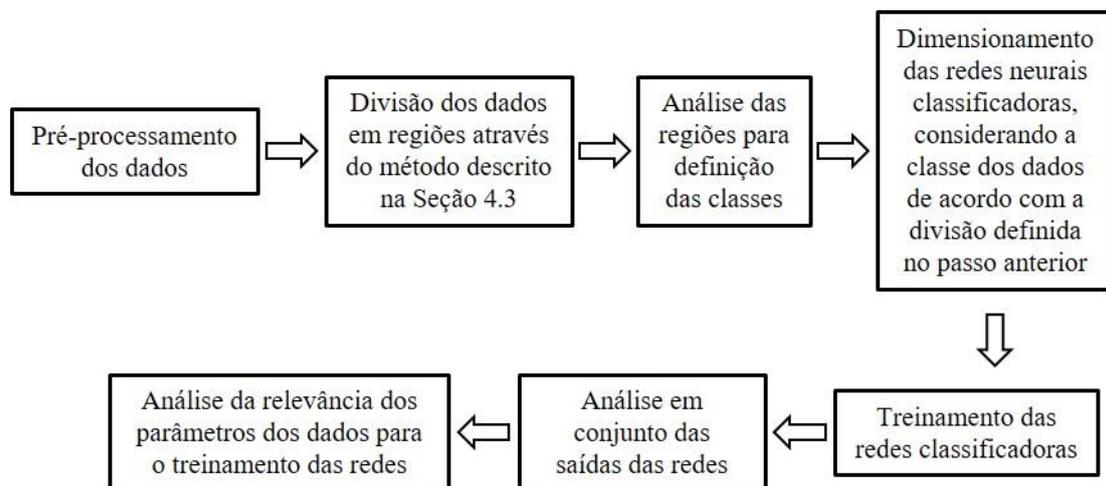


Figura 16 – Fluxograma das Etapas Realizadas ao Longo do Trabalho de Pesquisa.

5.1. PRÉ-PROCESSAMENTO DOS DADOS

Antes do início da análise dos dados, foi montada uma tabela da quantidade de registros por canal (sensor), a Tabela 3. Assim, foi possível observar que os canais 1, 3 e

4 apresentavam uma quantidade baixa de registros, quando comparado à quantidade de registros do canal 2

Tabela 3 – Número de Registros por Canal

Canal	CP3	CP4	
	Número de Registros	Número de Registros	
		Ciclo 1	Ciclo 2
1	297	60	343
2	31777	60031	65458
3	206	44	265
4	644	34	102

Como foi comentado anteriormente, os sensores foram posicionados de forma simétrica em relação à trinca, estando os sensores 1 e 4 a uma mesma distância da trinca e os sensores 2 e 3 também a uma mesma distância, porém diferente da distância dos sensores 1 e 4. Sendo assim, era esperado que, mesmo ocorrendo atenuação dos sinais de emissão acústica com a distância, ao menos os sensores que estavam posicionados à mesma distância da trinca captassem quantidades próximas de registros. Como todos os outros sensores captaram uma quantidade de registros muito inferior à quantidade captada pelo sensor 2, sugeriu-se que os sensores 1, 3 e 4 pudessem estar defeituosos.

Em seguida, foram plotados os valores do *threshold* por canal ao longo do tempo para os ensaios CP3 e CP4, Figuras 17 e 18, respectivamente. É importante notar que os valores de *threshold* plotados nos gráficos se referem a dados registrados pelos sensores, sendo assim, não é possível saber, por esses dados, em que momento o *threshold* foi variado.

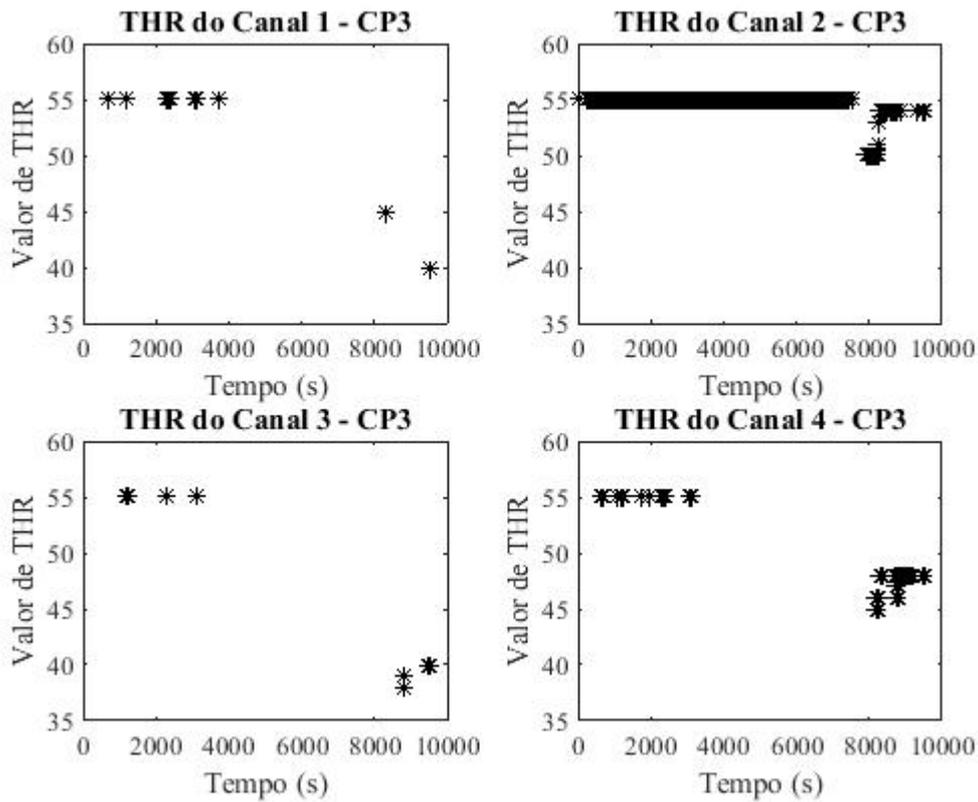


Figura 17 – Valor do *Threshold* (THR) ao Longo do Tempo para o Ensaio CP3.

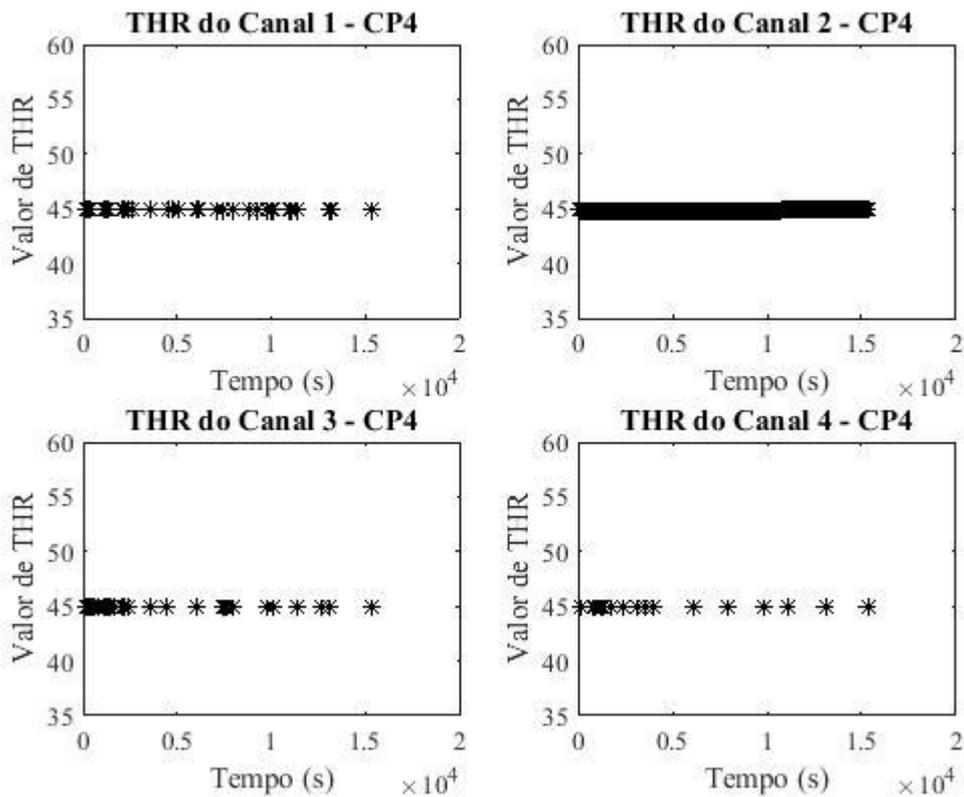


Figura 18 – Valor do *Threshold* (THR) ao Longo do Tempo para o Ensaio CP4.

Como pode ser observado na Figura 17, o valor de *threshold* foi modificado ao longo do ensaio CP3. Ao se fazer essa observação, levantou-se a hipótese de que os canais não estivessem defeituosos, porém com valor de *threshold* muito elevado e que, ao perceber que esses canais não captavam sinais, se tenha tentado reduzir este valor. No entanto, o ensaio CP4 já iniciou com um valor de *threshold* reduzido e, mesmo assim, os canais 1, 3 e 4 apresentaram quantidades bem menores de sinais captados do que o sensor 2. Devido a dúvida sobre os outros sensores estarem defeituosos, decidiu-se por trabalhar inicialmente apenas com os dados do canal 2.

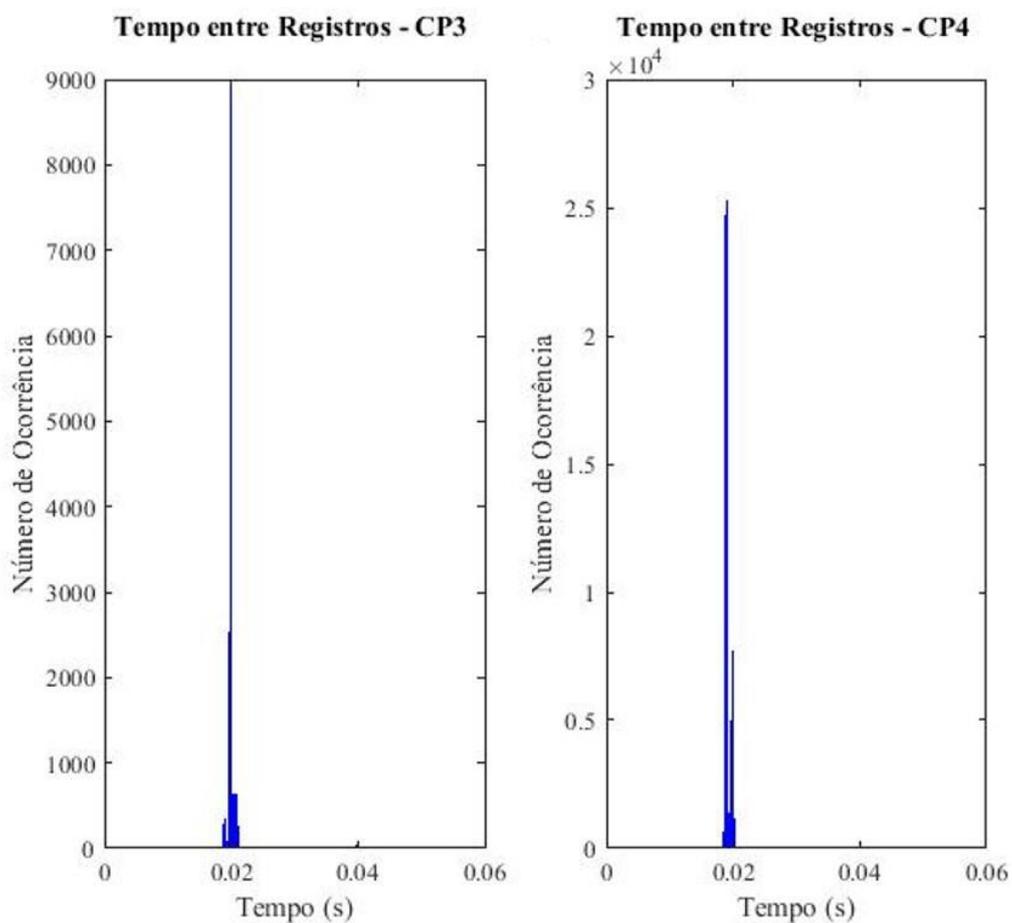


Figura 19 – Histograma de Intervalo de Tempo entre Sinais Consecutivos Captados.

Em seguida, observou-se o tempo de chegada dos sinais no sensor 2. Ao se realizar esta análise, foi possível perceber o intervalo de tempo entre dois sinais consecutivos captados por este sensor. Como pode ser observado pelo gráfico da Figura 19, a maioria

dos sinais chegou a intervalos de aproximadamente 0,02 s, mais especificamente $0,0203 \pm 0,002$ s. Como não é esperado que tantos sinais cheguem a um intervalo tão regular de tempo, foi investigado o motivo desse fenômeno.

Ao se observar o tempo de chegada entre registros, percebeu-se que a maioria dos sinais captados pelo sensor 2 chegavam em grupos de cinco, com intervalo de tempo entre si de 0,002s e intervalos regulares de tempo, de aproximadamente 1 segundos, entre cada grupo de cinco sinais, conforme Figura 20. Após consultar os relatórios dos ensaios, descobriu-se que o transdutor de TOFD emite sinais acústicos a cada segundo. Sendo assim, assumiu-se que esses sinais que chegam em grupos de 5, são, na verdade, sinais de TOFD e, portanto, os mesmos foram retirados.

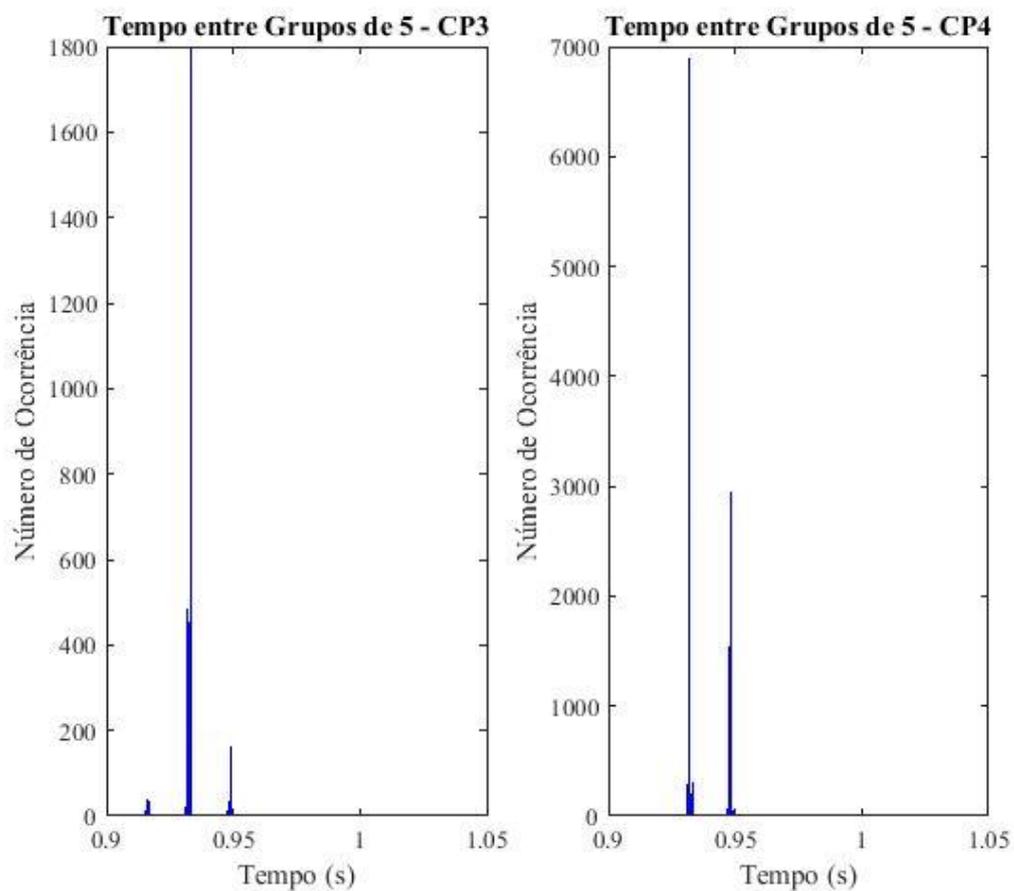


Figura 20 – Histograma do Intervalo de Tempo entre os Grupos de 5 Sinais.

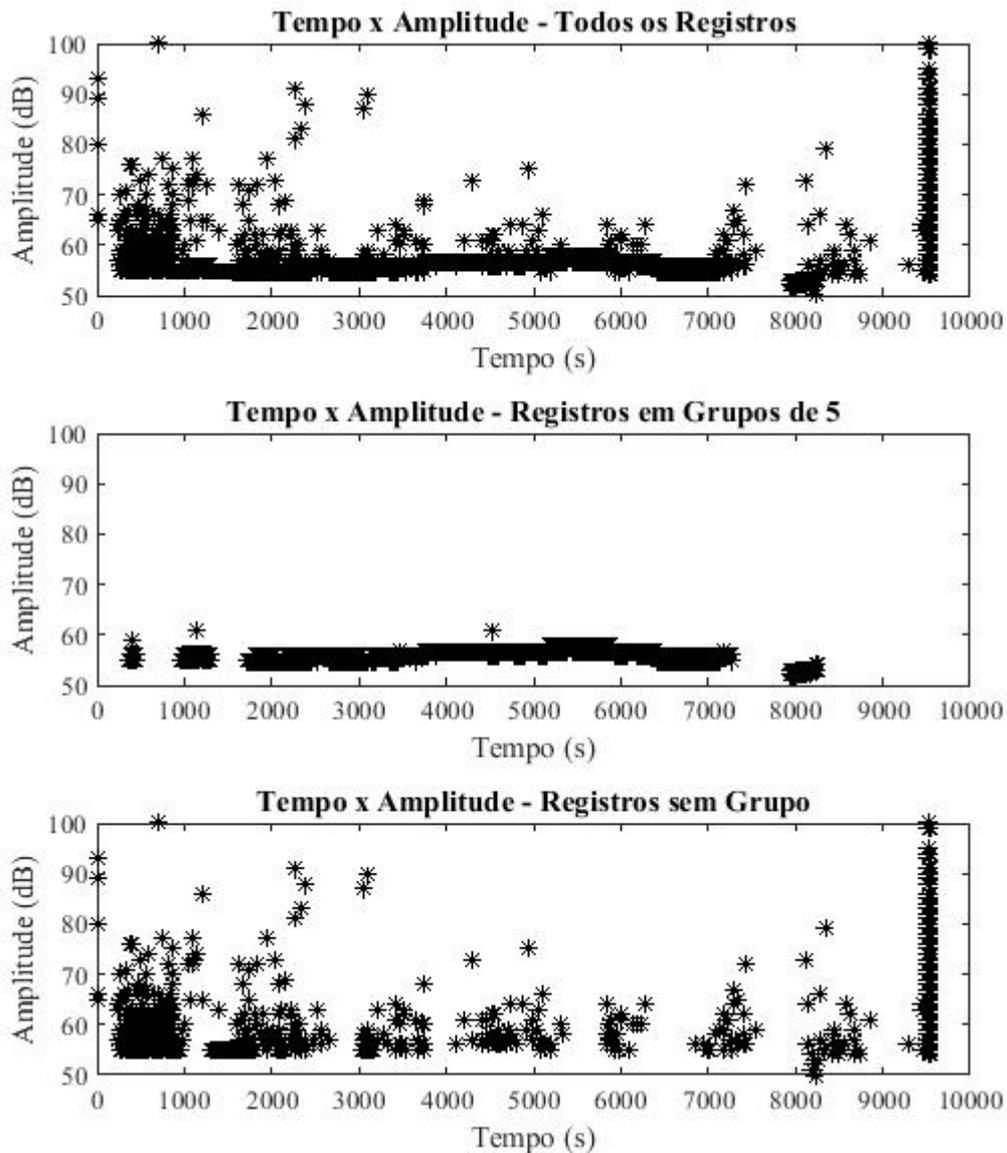


Figura 21 – Amplitudes dos Registros do Ensaio CP3 - Canal 2.

Como uma última análise dos sinais que chegaram em grupos de 5, foram plotados gráficos da amplitude dos registros. Nas Figuras 21 e 22, referentes aos ensaios CP3 e CP4, respectivamente, é possível ver os gráficos das amplitudes de todas as amostras, das amostras que chegaram em grupos de 5 e das amostras que não chegaram em grupos. Como é possível perceber ao analisá-los, existe uma “faixa” de amplitudes praticamente constante ao longo do gráfico das amplitudes de todos os registros. Ao se plotar em dois gráficos diferentes os registros que não chegaram em grupos de 5 e os registros que chegaram em grupos de 5, percebe-se que esta “faixa” se refere às amostras que chegaram

em grupos. Não é esperado que os sinais de emissão acústica causados pela deformação do material permaneçam tão constantes ao longo de todo o ensaio, não apresentando diferenças significativas nem mesmo no final do ensaio, onde os sinais se tornam mais intensos (provável região de PI). Esse comportamento das amplitudes dos registros dos grupos de 5 nos leva a confirmar a hipótese de que realmente estes sinais não são emissões acústicas causadas pela deformação do duto e devem ser eliminados.

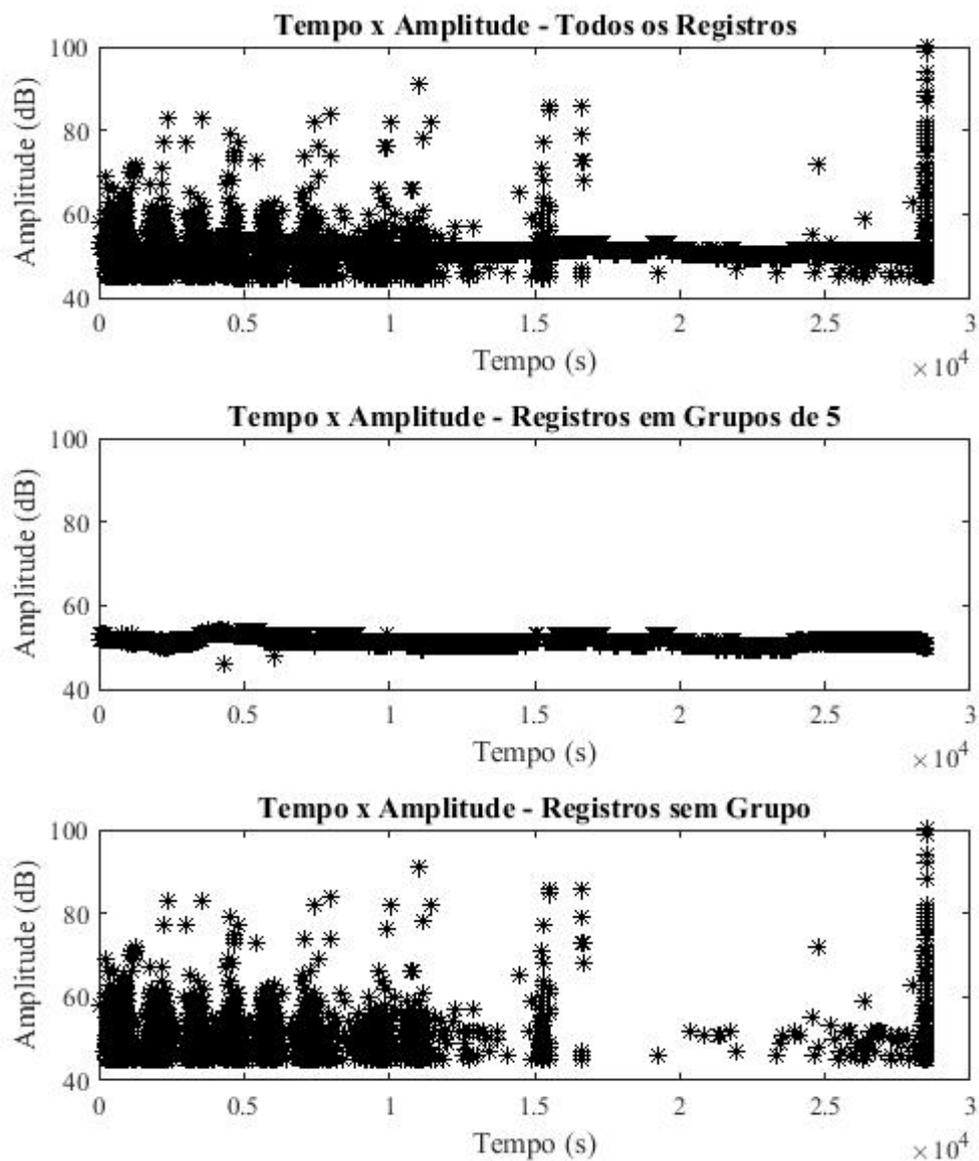


Figura 22 – Amplitudes dos Registros do Ensaio CP4 - Canal 2.

Seguindo os passos da metodologia, se teve o cuidado de retirar os registros das fases iniciais de enchimento dos dutos e os registros dos finais dos ciclos 1 e 2 do ensaio CP4, a partir do momento em que os dutos começam a ser despressurizados. Os registros do final do ensaio CP3 não precisaram ser retirados, pois o ensaio acabou antes de o duto começar a ser despressurizado.

Em seguida, foram eliminados todos os registros, tanto do ensaio CP3 quanto do CP4, que, além de não ultrapassarem o valor de *threshold* por no mínimo 3 vezes, também duraram menos de 3 μ s. Nesse processo, foram retirados 316 registros do ensaio CP3, 345 registros do ciclo 1 e 21 do ciclo 2 do ensaio CP4.

Por fim, foi realizada a normalização de cada um dos conjuntos para média zero e desvio padrão igual a 1 e gerada a *data image* de cada conjunto de dados. A Figura 23 apresenta as matrizes de similaridade dos conjuntos de dados dos ensaios CP3 e CP4 após a limpeza dos dados realizada até o momento.

Na matriz de similaridade dos registros do ensaio CP3 consegue-se perceber que os registros que foram captados mais próximos no tempo são mais semelhantes que os captados mais distante, mas na matriz de similaridade dos dados de CP4 isso não foi possível de se visualizar. Foi levantada a hipótese de que um ruído poderia estar misturado aos dados de emissão acústica, especialmente no caso de CP4.

Na tentativa de se realizar uma limpeza dos dados, foi aplicada a metodologia de limpeza baseada na similaridade dos registros próximos, explicada na seção 4.2. A *data imagem* da matriz de similaridade do cosseno para os dados restantes após a aplicação da retirada do ruído através desse método, tanto para os dados de CP3 quanto para os dados de CP4, pode ser observada na Figura 24.

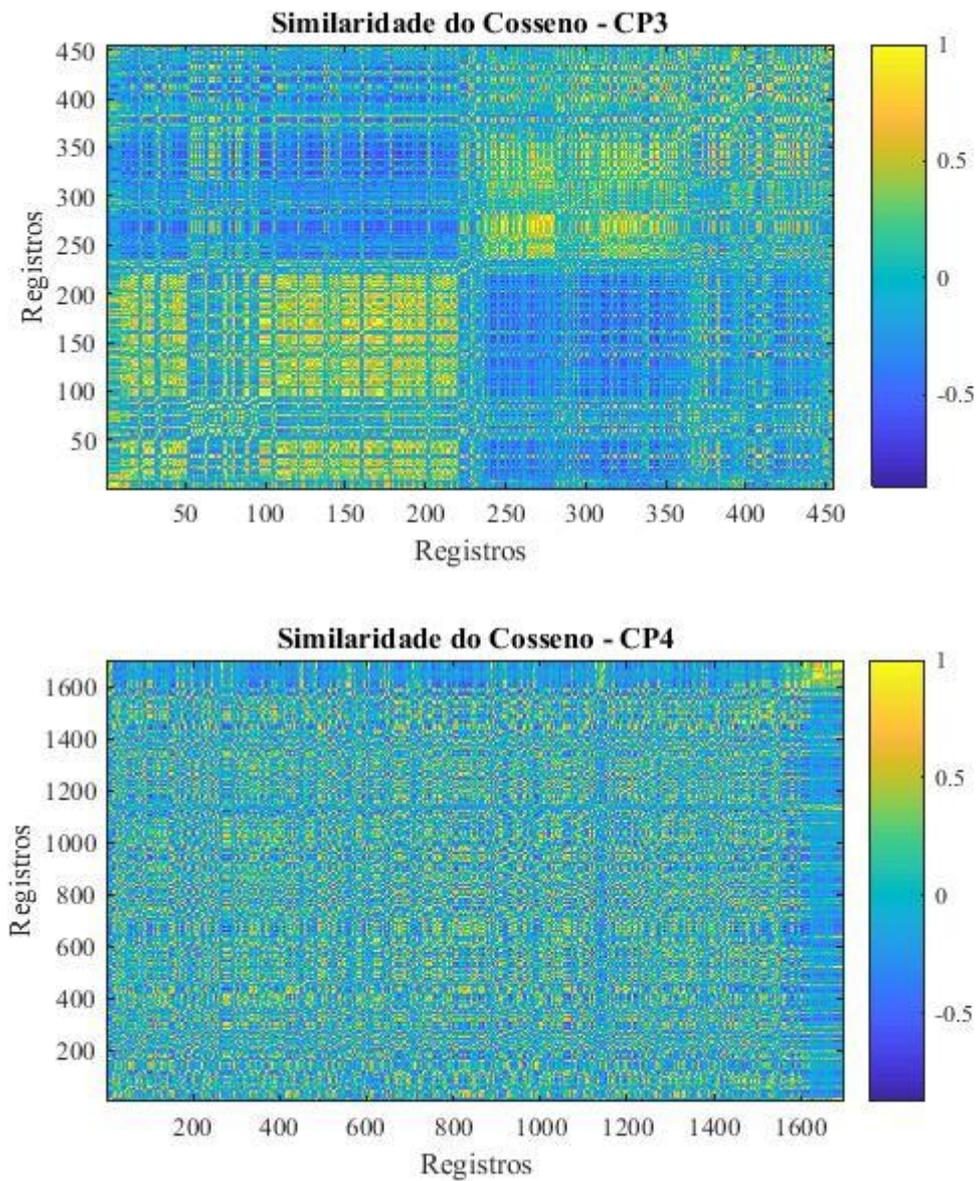


Figura 23 – *Data Image* da Similaridade do Cosseno dos Dados de CP3 e CP4.

Como é possível observar na Figura 24, após se realizar esta última limpeza, tornou-se possível identificar mais facilmente agrupamentos de dados próximos à diagonal secundária da *data image* dos dados de cada ensaio.

Para cada um dos ensaios, os dados restantes foram mais uma vez normalizados para média zero e desvio padrão igual à 1. Estes foram os dados utilizados para encontrar o corte entre classes e aplicados às redes neurais classificadoras. A partir desse ponto do

trabalho, quando houver referências ao índice dos registros (registro de número 1, 2, 3, etc...), será considerado como o índice de cada um a ordem em que os mesmos foram captados dentre os registros restantes após todas as limpezas, ou seja, os mesmos índices apresentados nas *data image* da Figura 24.

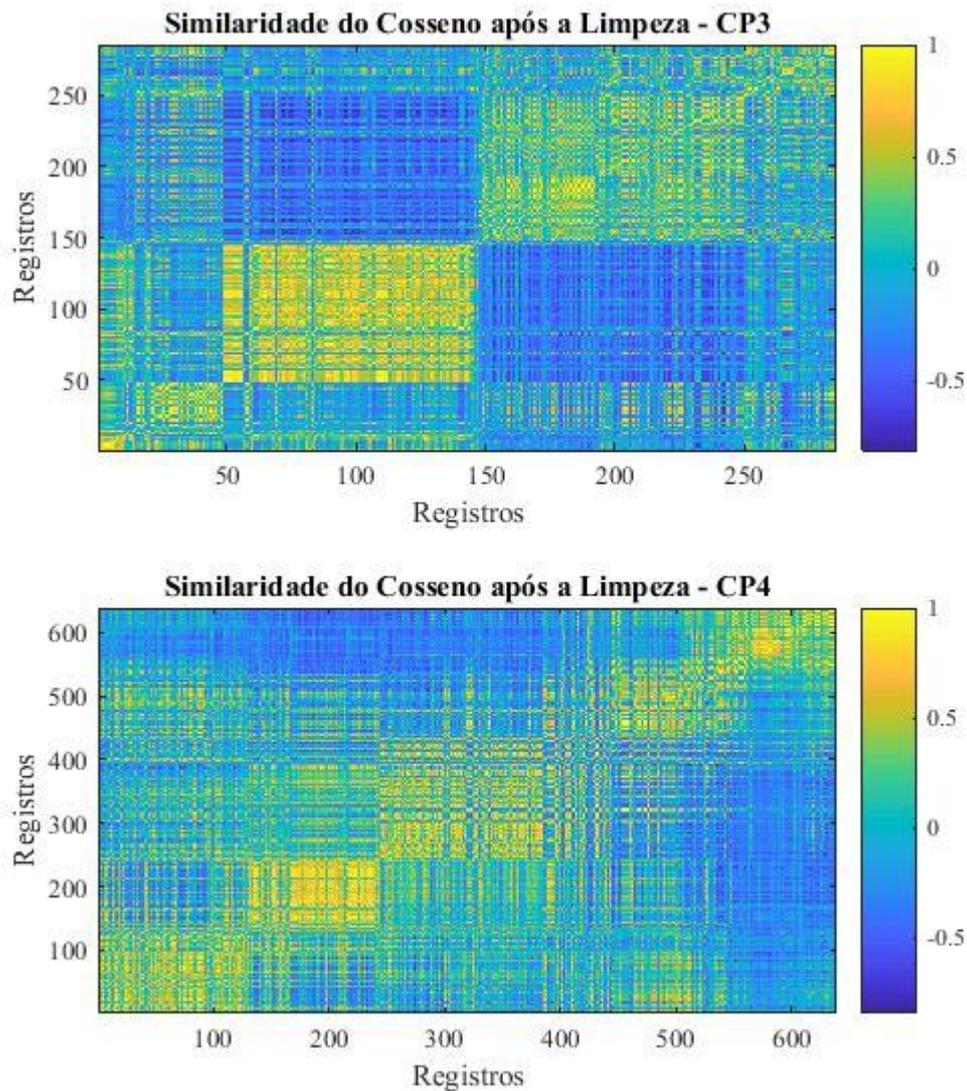


Figura 24 – *Data Image* da Similaridade do Cosseno dos Dados de CP3 e CP4 após Limpeza.

Lembrando que foi decidido utilizar apenas os dados do sensor 2 neste trabalho, a Tabela 4 mostra a quantidade de registros deste sensor retirados após a realização de cada etapa de limpeza dos dados.

Tabela 4 – Quantidade de Registros Retirados do Canal 2 após Cada Etapa de Limpeza do Conjunto de Dados de Cada Ensaio

Etapa de Limpeza	Registros Retirados de CP3	Registros Retirados de CP4	
		Ciclo 1	Ciclo 2
Retirada dos sinais gerados pelo Transdutor de Ultrassom (TODF)	30649	57704	64823
Retirada dos registros do início e do final de cada ciclo dos ensaios	357	501	395
Retirada dos registros com menos de 3 ultrapassagens do valor de <i>threshold</i> e menos de 3 μ s de duração	316	345	21
Limpeza através da similaridade do cosseno	170	1018	44

A Tabela 5 mostra a quantidade de registros restantes após a realização de todas as limpezas de dados.

Tabela 5 – Quantidade de Registros Restantes no Canal 2 após a Última Limpeza dos Dados

Canal	CP3	CP4	
	Número de Registros	Número de Registros	
		Ciclo 1	Ciclo 2
2	285	463	175

5.2. DIVISÃO DAS CLASSES

Para cada ponto de transição testado, foram treinadas redes neurais utilizando-se o método de validação cruzada com 5 partições, cada partição com 20% dos dados de cada classe. Cada rede foi treinada com 60% dos dados para treinamento, 20% para validação e 20% para teste. Devido à validação cruzada empregada, foram treinadas 20 redes para cada ponto de transição testado. Para cada rede treinada, os registros foram de uma das duas classes correspondentes a um dos dois subconjuntos em que se estava testando dividir o conjunto de dados.

Como já foi explicado na Seção 4.3., o objetivo era encontrar os dois pontos de divisão do conjunto de dados que proporcionassem à rede neural artificial os menores erros de classificação. A Figura 25 apresenta o resultado encontrado para a divisão automática das classes do ensaio CP3. O gráfico superior na Figura 25 mostra a divisão de classes em relação ao índice do registro, enquanto o gráfico inferior mostra a divisão em relação ao tempo em que o respectivo registro foi captado.

Ao contrário do que era esperado, o gráfico da divisão automática das classes dos dados do ensaio CP3 apresentou diversos vales. Para melhor compreender este comportamento dos dados, foram traçadas linhas horizontais nos gráficos da Figura 25, dividindo-se os gráficos em regiões de acordo com os vales apresentados. Como pode ser observado comparando os gráficos em relação ao índice do registro e em relação ao tempo, as regiões 1, 2 e 3 acontecem mais próximas ao início do ensaio e com um maior tempo de duração cada uma. Já as regiões, 4, 5 e 6, acontecem praticamente no final do ensaio e duram microssegundos.

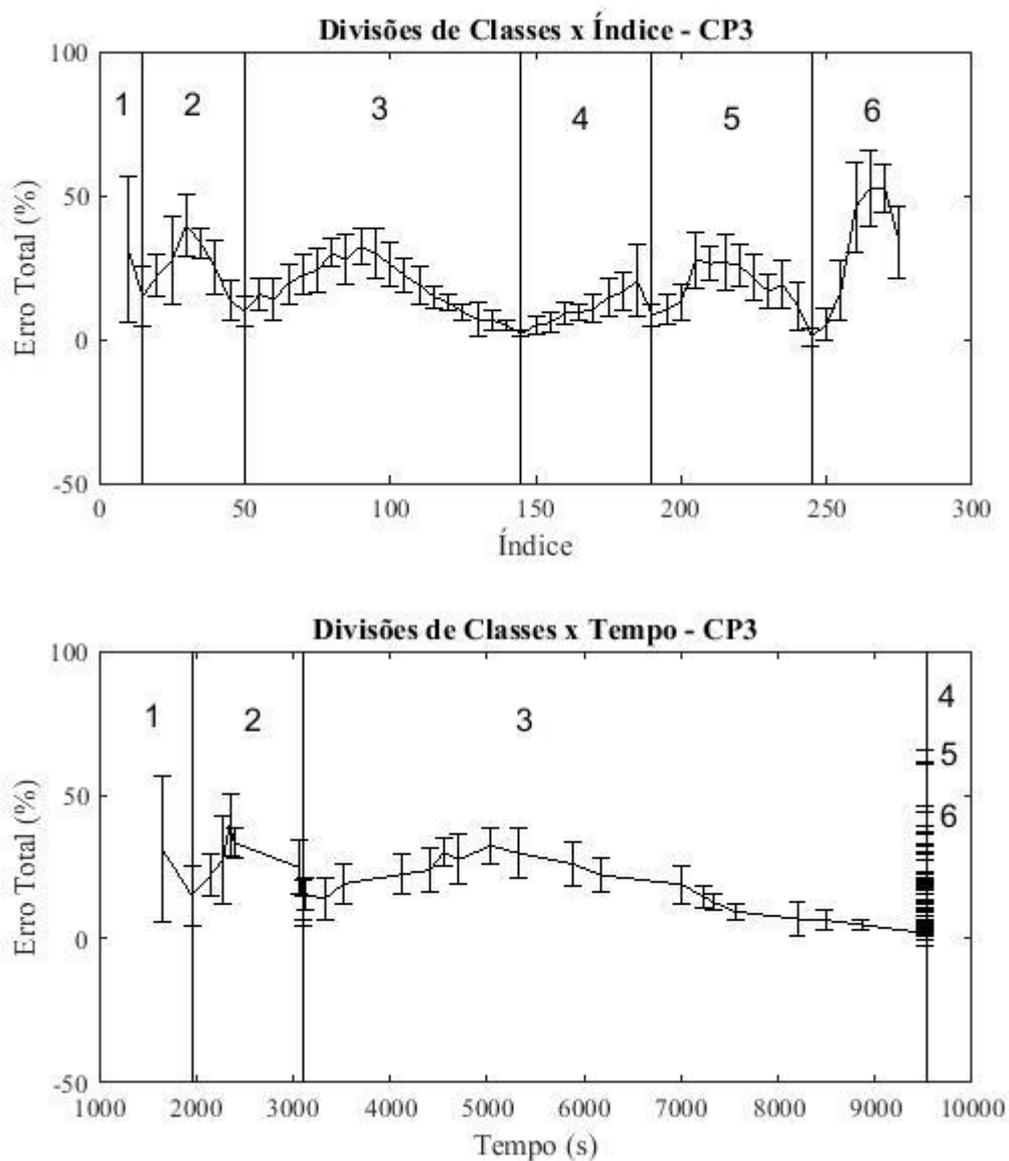


Figura 25 – Erro de Classificação por Ponto de Corte Testado para o Ensaio CP3.

O gráfico da parte superior da Figura 26 apresenta o resultado encontrado para a divisão automática das classes do ensaio CP4 em relação ao índice do registro e o gráfico inferior em relação ao tempo. Como pode ser observado, assim como para o ensaio CP3, o gráfico da divisão automática entre classes para os dados do ensaio CP4 apresentou diversos vales. As regiões sinalizadas nos gráficos da Figura 26 como 1, 2 e 3 fazem parte do ciclo 1 do ensaio CP4. A região 4 começa no ciclo 1 e se prolonga até o ciclo 2. E as

regiões 5 e 6 estão localizadas no ciclo 2. Além disso, as regiões 5 e 6 acontecem muito próximas ao final do ensaio CP4 e duram apenas alguns microssegundos.

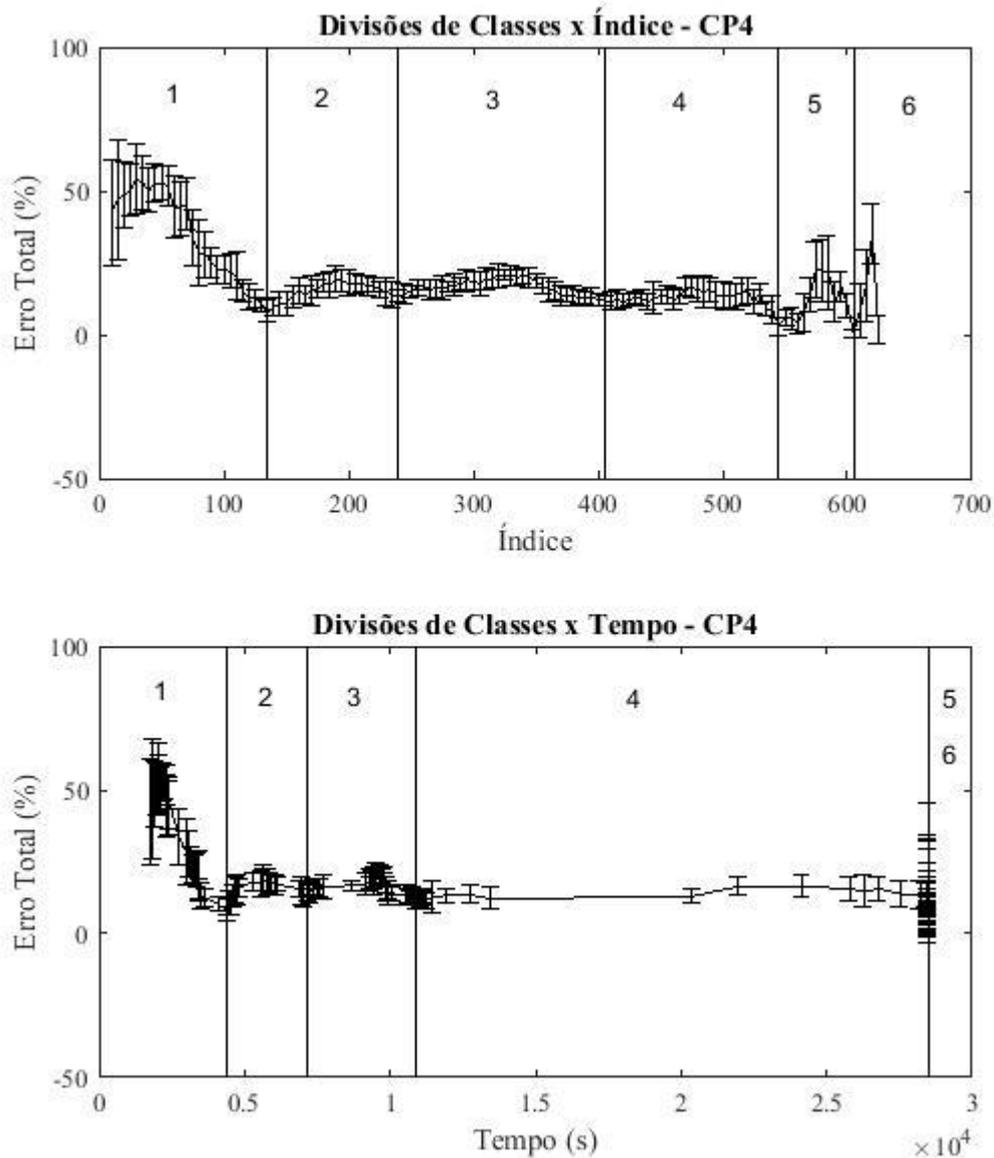


Figura 26 – Erro de Classificação por Ponto de Corte Testado para o Ensaio CP4.

Para melhor entender o comportamento apresentado pelos dados, estas regiões encontradas nos dois ensaios foram analisadas através dos mapas auto-organizáveis de *Kohonen*.

5.2.1. *Análise das Regiões das Classes*

Os parâmetros utilizados no algoritmo SOM podem ser vistos na Tabela 6:

Tabela 6 – Parâmetros Utilizados no Algoritmo SOM

Número Total de Épocas	20000
Número de Épocas da fase de Ordenação	5000
Vizinhança inicial	6
Topologia do Mapa	Hexagonal
Função de Distância dos Neurônios	Distância euclidiana
Dimensão do mapa	4 x 4

Foram testados mapas de diferentes tamanhos e definiu-se que a melhor configuração foi o mapa de 4x4 neurônios, pois mapas maiores ficavam muito esparsos e apresentavam diversos espaços vazios, e mapas menores não eram capazes de apresentar regiões de divisão entre os dados.

A Figura 27 mostra o mapa de distâncias entre os neurônios após o treinamento pelo algoritmo SOM utilizando os dados do ensaio CP3. Nesse mapa de distâncias, a escala de cor indica a proximidade entre os neurônios. Quanto mais perto estiverem dois neurônios, mais similares são os dados que os ativam. Como é possível observar no mapa, existem duas grandes regiões mais facilmente observadas, uma formada por neurônios mais próximos e outra por neurônios mais distantes.

Para verificar se as regiões encontradas pelo método de separação automática de classes desenvolvido representam agrupamentos no mapa auto-organizável de *Kohonen*, foram plotados mapas de ativação de neurônios. Nos mapas de ativação, o tamanho do hexágono colorido de cada neurônio é diretamente proporcional à quantidade de amostras

que ativaram este neurônio, ou seja, quanto mais ativações ocorreram, maior o tamanho do hexágono. Para se conseguir identificar quais foram os neurônios ativados por cada região, foi plotado um mapa de ativação para cada uma das seis regiões encontradas para os dados de CP3. A Figura 28 apresenta o resultado obtido.

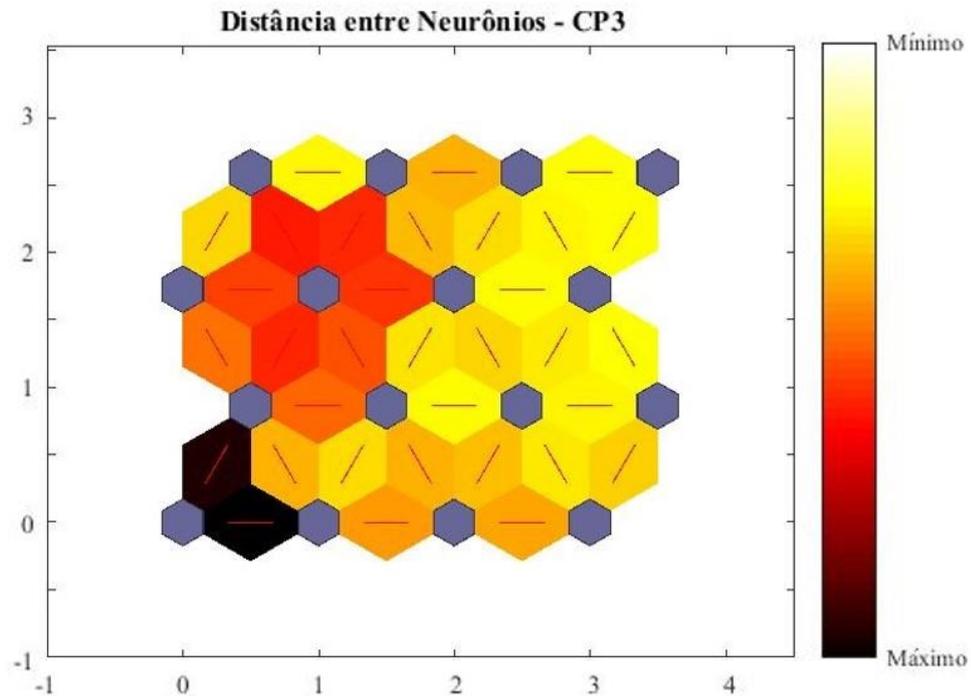


Figura 27 – Mapa de Distâncias dos Neurônios para o Ensaio CP3.

Como se sabe, os neurônios no mapa se arrumam de forma que os neurônios vizinhos são ativados por amostras mais semelhantes. Como pode ser observado na Figura 28, isso se confirmou nos mapas de ativação, já que os registros de cada região ativaram neurônios próximos.

Ao observar os mapas de ativação das regiões 4, 5 e 6, é possível perceber que, tirando algumas exceções, os mesmos neurônios são ativados pelos dados dessas regiões. Além disso, os neurônios ativados por essas três regiões se encontram, em sua maioria, na região de neurônios mais esparsos do mapa de distâncias da Figura 27. Como disse

PINTO (2014), os dados da classe PI possuem a característica de serem mais dispersos entre si do que os dados de SP e PE. Essas observações levaram a suposição de que as regiões 4, 5 e 6 formam a classe de PI.

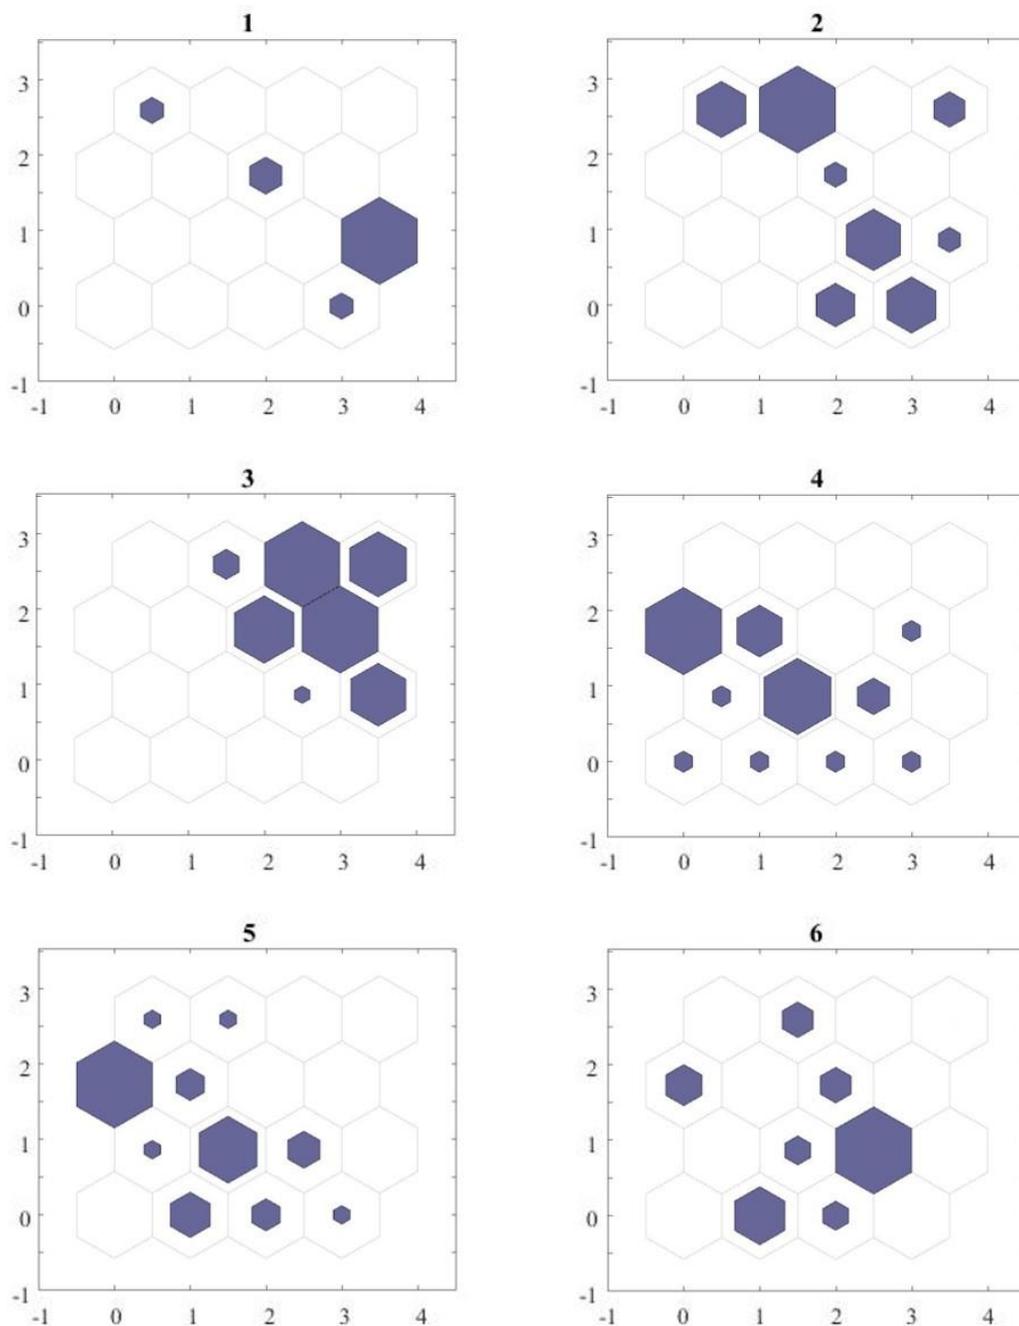


Figura 28 – Mapa de Ativação dos Neurônios para o Ensaio CP3.

As regiões 1, 2 e 3 ativaram os neurônios da região de maior proximidade do mapa de distâncias. Analisando o gráfico gerado para a divisão automática das classes e os

mapas de ativação, e fazendo uma comparação com a matriz de similaridade do cosseno, decidiu-se por trabalhar com 4 classes, ao invés das três planejadas originalmente. Dessa forma, foram definidas três classes compondo as regiões de sem propagação e com propagação estável e uma quarta classe correspondente a PI. A primeira classe foi chamada de SP, a segunda de SP/PE e a terceira de PE, e foram definidas, respectivamente, como as regiões 1, 2 e 3 marcadas no gráfico da Figura 25. Como, de acordo com PINTO (2014), as classes SP e PE se encontram em uma região de neurônios próximos no mapa auto-organizável de *Kohonen* e são as duas primeiras classes a ocorrerem, decidiu-se por essa nomenclatura por se acreditar que a primeira classe corresponde à fase sem propagação e que a terceira corresponde a classe de PE, ambas utilizadas por PINTO (2014). E que a segunda classe, provavelmente, se trata de uma fase de transição entre SP e PE.

Considerando essa divisão escolhida, os dados registrados entre o início do ensaio CP3 e o tempo de 1958 s passaram a formar a classe SP, a classe SP/PE se estendeu dos 1958 s até os 3106 s, a classe PE de 3106 s até 9536 s e a classe PI de 9536 s até o final do ensaio aos 9540 s.

Em seguida, o mesmo procedimento foi realizado para os dados do ensaio CP4. A Figura 29 mostra o mapa de distâncias entre os neurônios para os dados do ensaio CP4. Apesar de menos evidente, ainda é possível identificar uma região com neurônios mais próximos, em amarelo mais claro, e uma região de neurônios mais esparsos, em amarelo mais escuro no mapa.

Assim como para os dados do ensaio CP3, foram plotados mapas de ativação de neurônios para cada uma das regiões encontradas na divisão automática das classes dos dados do ensaio CP4. Os mapas encontrados podem ser vistos na Figura 30.

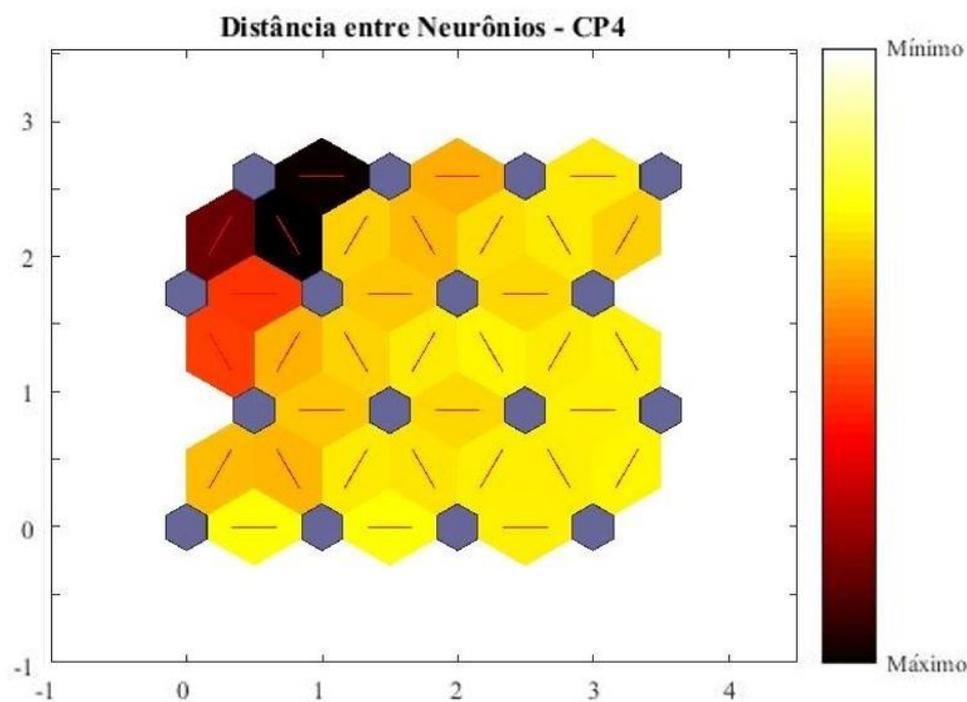


Figura 29 – Mapa de Distâncias dos Neurônios para o Ensaio CP4.

Fazendo uma comparação entre o mapa de distâncias dos neurônios e os mapas de ativação por região, foi possível perceber que as regiões 5 e 6 ativam os neurônios da região com neurônios mais esparsos do mapa de distâncias. Além disso, os neurônios ativados por essas duas regiões são praticamente os mesmos. Assim, de forma similar a análise feita para as regiões correspondentes dos dados do ensaio CP3, as regiões 5 e 6 dos dados de CP4 foram definidas como pertencentes a classe PI.

Os neurônios da região de maior proximidade do mapa de distância entre neurônios foram ativados pelas regiões 1, 2, 3 e 4. Apesar de os dados de todas as regiões ativarem alguns neurônios em comum, é possível perceber que as regiões 1 e 2 ativaram neurônios em áreas diferentes do mapa. Assim, estas regiões foram definidas como as classes SP e SP/PE, respectivamente. Os neurônios ativados pelas regiões 3 e 4, no entanto, foram, com poucas exceções, os mesmos. Como, além disso, se tratam de regiões

que ocorreram em sequência no tempo, se decidiu por definir que estas duas regiões compõem uma mesma classe, a classe PE. Assim, mais uma vez foram identificadas quatro classes ao invés das três esperadas previamente.

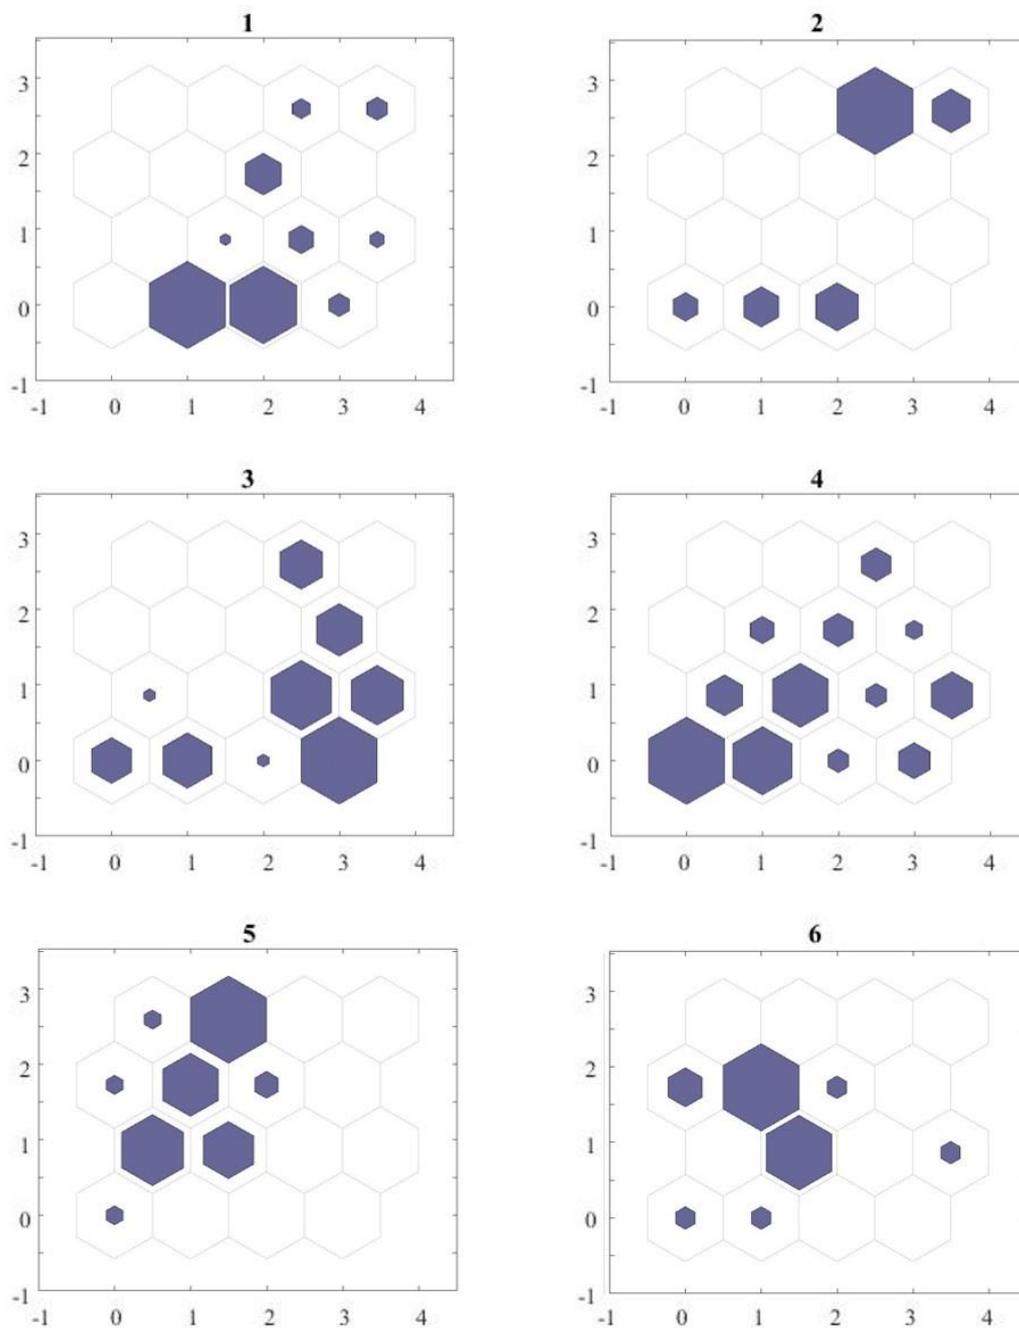


Figura 30 – Mapa de Ativação dos Neurônios para o Ensaio CP4.

De acordo com a divisão de classes determinada, a classe SP se estendeu do início do ensaio CP4 até o tempo de 4373 s, a classe SP/PE foi de 4373 s até 7183 s, a classe PE

ocorreu entre 7183 s e 28491 s e a classe PI foi de 28491 s até o final do ensaio aos 28498 s.

A Tabela 7, a seguir, mostra a quantidade de dados que compõem cada uma das classes definidas para os dados de cada um dos dois ensaios.

Tabela 7 – Quantidade de Registros por Classe

Ensaio CP3				Ensaio CP4			
SP	SP/PE	PE	PI	SP	SP/PE	PE	PI
15	35	95	140	135	105	305	93

5.3. Redes Neurais FeedForward

Além de dimensionar a quantidade ideal de neurônios na camada intermediária das redes neurais classificadoras, nessa etapa também foi decidido se o treinamento com o algoritmo *backpropagation* usaria gradiente descendente, gradiente descendente adaptativo ou *Levenbarg-Marquardt*.

5.3.1. Dimensionamento das Redes

Foram treinadas redes com camadas intermediárias contendo de 1 até 15 neurônios. Para cada quantidade de neurônios testada na camada intermediária, foi

realizada validação cruzada com 5 partições, com 60% dos dados para treinamento, 20% para validação e 20% para teste. Como a quantidade de dados em cada classe é altamente desbalanceada, foi decidido, após alguns testes de qual esquema de balanceamento apresentava um melhor resultado para o treinamento da rede, por selecionar, para a realização do treinamento utilizando validação cruzada das redes neurais para os dados do ensaio CP3, todos os dados da classe SP e todos os dados da classe SP/PE, e a mesma quantidade de dados presente na classe SP/PE para as duas outras classes restantes, ou seja, 35 registros de PE e 35 de PI. Para o treinamento com validação cruzada das redes neurais para os dados do ensaio CP4, foi selecionada a mesma quantidade de dados da classe com menos registros para todas as classes, ou seja, 93 registros, exceto para a classe PE, para a qual foram selecionados 186 registros. Todos os dados foram selecionados de maneira uniforme dentro do espaço de cada região.

As Tabelas 8, 9 e 10 mostram os resultados de média (Méd.) e desvio padrão (DP) dos acertos de classificação obtidos pelas redes na validação cruzada para cada dimensionamento de rede testada aplicando o treinamento com gradiente descendente adaptativo, *Levenberg Marquardt* e gradiente descendente, respectivamente, aos dados do ensaio CP3. Estes resultados foram obtidos ao inserir nas redes o conjunto de dados utilizado para teste das redes juntamente com todos os registros restantes, que, devido ao balanceamento de dados empregado, não foram selecionados para realizar a validação cruzada.

Tabela 8 – Média e Desvio Padrão do Desempenhos das Redes Treinadas com Gradiente Descendente Adaptativo – CP3

Neur.	Méd. (%)	DP (%)						
	SP	SP	SP/PE	SP/PE	PE	PE	PI	PI
1	0,00	0,00	47,14	27,07	89,70	19,11	91,16	17,14
2	5,00	16,31	85,71	12,26	91,12	5,36	90,49	5,51

3	50,00	35,04	85,71	11,35	90,75	4,15	90,54	4,98
4	66,67	32,44	86,43	10,85	90,67	3,35	90,36	5,80
5	65,00	29,57	87,14	11,26	91,19	2,86	90,63	5,38
6	68,33	25,31	86,43	11,79	90,97	3,12	90,94	5,25
7	63,33	32,26	85,71	10,36	91,72	3,12	90,40	4,93
8	66,67	28,61	85,00	9,80	91,27	3,15	90,94	4,96
9	76,67	21,90	86,43	9,80	90,82	3,33	91,29	4,88
10	75,00	21,29	87,14	10,26	91,34	3,01	90,58	4,43
11	71,67	19,57	85,71	9,27	90,82	3,40	91,21	4,79
12	71,67	22,36	87,14	10,26	91,12	3,47	90,67	4,60
13	73,33	23,20	86,43	9,80	91,19	3,21	91,34	4,87
14	71,67	19,57	87,14	10,26	90,52	3,36	90,94	4,82
15	71,67	24,84	86,43	9,80	90,82	3,15	91,29	5,09

Tabela 9 – Média e Desvio Padrão do Desempenhos das Redes Treinadas com
Levenberg-Marquardt – CP3

Neur.	Méd. (%)	DP (%)	Méd. (%)	DP (%)	Méd. (%)	DP (%)	Méd. (%)	DP (%)
	SP	SP	SP/PE	SP/PE	PE	PE	PI	PI
1	0,00	0,00	70,71	26,00	76,94	28,74	69,20	37,08
2	13,33	29,42	81,43	12,35	90,15	4,73	90,71	5,28
3	56,67	32,62	82,86	9,94	85,00	8,55	89,73	6,79
4	66,67	28,61	80,71	13,33	87,24	7,11	89,11	6,59
5	73,33	25,59	81,43	12,35	85,60	4,75	91,56	4,78
6	76,67	26,71	82,14	13,01	85,07	6,55	91,38	4,01
7	70,00	28,41	85,71	14,66	85,60	4,92	91,96	5,05
8	71,67	24,84	82,86	11,91	86,87	5,62	91,25	5,47
9	66,67	21,63	84,29	13,83	87,01	5,15	91,43	3,17
10	70,00	21,36	83,57	9,58	85,60	6,11	90,27	4,90
11	71,67	24,84	80,71	10,65	86,57	6,35	90,89	4,62
12	71,67	22,36	86,43	11,79	86,12	5,63	91,70	5,03
13	66,67	28,61	81,43	10,47	82,84	6,58	91,07	5,08
14	73,33	25,59	81,43	12,35	84,03	5,65	92,19	4,31
15	68,33	25,31	86,43	11,79	84,40	5,49	91,96	5,38

Tabela 10 – Média e Desvio Padrão do Desempenhos das Redes Treinadas com Gradiente Descendente – CP3

Neur.	Méd. (%) SP	DP (%) SP	Méd. (%) SP/PE	DP (%) SP/PE	Méd. (%) PE	DP (%) PE	Méd. (%) PI	DP (%) PI
1	0,00	0,00	61,43	20,26	88,06	17,30	93,75	3,85
2	1,67	7,45	80,71	11,61	92,24	3,77	92,19	3,08
3	45,00	40,86	80,71	11,61	90,00	5,01	92,50	3,22
4	56,67	36,03	80,00	9,72	89,55	4,17	92,63	2,59
5	58,33	33,98	81,43	10,47	89,25	3,77	92,46	3,04
6	61,67	36,31	80,71	9,58	89,85	3,86	92,37	2,72
7	68,33	33,29	83,57	10,65	90,15	3,86	91,83	3,00
8	58,33	38,81	80,71	9,58	90,82	3,73	91,88	2,65
9	60,00	35,21	82,86	10,97	90,52	3,26	91,83	3,11
10	66,67	34,20	82,14	10,23	90,30	3,19	92,86	3,00
11	66,67	34,20	82,14	9,12	90,22	3,23	92,68	2,86
12	68,33	31,48	83,57	11,61	90,75	3,16	92,32	2,63
13	66,67	32,44	82,86	10,97	90,67	3,02	92,68	2,65
14	63,33	35,71	81,43	10,47	90,60	2,99	92,59	2,69
15	71,67	31,11	82,14	11,23	91,12	2,96	92,68	2,79

Como o dimensionamento e o treinamento que obteve os melhores resultados de média e desvio padrão para a classificação foi a rede com nove neurônios na camada intermediária treinada utilizando gradiente descendente adaptativo, essa foi a opção escolhida para as redes do ensaio CP3. Observando a Tabela 8, de gradiente descendente adaptativo, é possível perceber que aplicando o treinamento com esta função, aumentar a quantidade de neurônios não resulta em uma melhora significativa no desempenho da rede.

As Tabelas 11, 12 e 13 mostram os resultados obtidos para o dimensionamento e teste de tipo de treinamento das redes para os dados do ensaio CP4. Os resultados obtidos nas tabelas a seguir se referem as amostras de teste, sendo estas compostas dos conjuntos

de teste da validação cruzada, juntamente com os dados excluídos do treinamento devido ao balanceamento das classes.

Tabela 11 – Média e Desvio Padrão do Desempenhos das Redes Treinadas com Gradiente Descendente Adaptativo – CP4

Neur.	Méd. (%)	DP (%)						
	SP	SP	SP/PE	SP/PE	PE	PE	PI	PI
1	0,00	0,00	0,00	0,00	96,22	1,49	98,33	2,63
2	41,83	27,27	73,46	10,03	83,86	7,55	93,24	6,27
3	72,33	7,32	73,54	6,64	83,35	4,14	91,83	6,83
4	74,06	4,90	74,34	4,83	83,93	2,43	93,70	7,07
5	73,76	5,84	74,71	5,35	86,69	3,04	93,37	6,13
6	74,32	5,74	74,03	5,60	86,08	3,49	94,29	4,97
7	74,32	4,02	73,72	5,53	85,69	3,22	95,08	5,12
8	74,90	4,85	75,66	4,59	85,40	3,43	94,29	3,40
9	74,57	5,51	74,68	4,85	86,46	2,33	93,99	4,13
10	74,33	4,94	75,34	4,86	86,72	3,82	93,96	4,55
11	75,30	5,61	75,34	4,86	85,92	3,12	94,81	4,61
12	76,57	4,29	75,51	4,64	86,27	2,73	94,23	5,72
13	74,89	4,38	74,51	5,99	86,10	3,22	95,37	3,68
14	74,97	3,99	75,18	5,27	86,08	3,15	94,55	4,45
15	75,48	4,77	75,01	5,60	86,27	2,88	95,63	3,91

Tabela 12 – Média e Desvio Padrão do Desempenhos das Redes Treinadas com Levenberg-Marquardt – CP4

Neur.	Méd. (%)	DP (%)						
	SP	SP	SP/PE	SP/PE	PE	PE	PI	PI
1	34,83	36,93	30,67	33,20	90,14	4,93	93,79	7,29
2	72,13	15,73	76,18	8,89	78,24	8,09	84,60	11,19
3	76,09	10,96	76,68	6,13	83,45	5,02	86,72	10,71
4	75,34	10,21	77,34	5,08	87,00	3,53	90,96	9,33
5	78,14	8,60	75,62	8,67	86,33	4,47	88,59	10,12
6	77,70	10,04	76,98	5,91	87,04	4,09	90,93	6,84
7	78,56	9,31	76,82	5,12	88,29	2,35	87,51	9,94
8	78,58	7,39	76,62	5,27	87,90	3,91	90,40	10,10
9	79,90	6,14	77,94	7,10	88,54	4,09	88,30	11,99

10	77,90	7,83	77,47	6,63	88,67	2,64	86,98	9,05
11	79,31	6,47	78,29	5,25	87,93	3,73	85,90	10,43
12	80,03	8,81	77,67	5,66	89,86	3,74	90,43	8,12
13	79,49	6,46	77,83	5,50	88,54	3,99	89,81	10,14
14	82,62	5,74	77,81	5,96	88,80	2,66	88,03	10,64
15	79,39	8,39	77,96	4,80	88,51	3,44	87,32	11,35

Tabela 13 – Média e Desvio Padrão do Desempenhos das Redes Treinadas com Gradiente Descendente – CP4

Neur.	Méd. (%) SP	DP (%) SP	Méd. (%) SP/PE	DP (%) SP/PE	Méd. (%) PE	DP (%) PE	Méd. (%) PI	DP (%) PI
1	0,00	0,00	0,00	0,00	95,52	2,48	94,58	7,64
2	60,24	27,86	70,90	17,73	84,13	6,01	93,30	7,35
3	72,79	17,53	71,50	18,40	86,91	5,40	93,47	7,86
4	76,48	3,91	74,39	6,72	86,85	5,15	92,59	8,60
5	77,15	4,40	74,87	6,04	88,77	2,54	93,17	7,81
6	76,24	4,09	75,19	6,93	88,45	3,53	93,44	8,40
7	76,55	4,47	74,91	7,35	89,34	3,34	93,17	8,69
8	77,05	3,37	75,18	7,13	89,63	2,97	93,73	8,53
9	76,97	3,89	76,32	6,27	88,74	3,79	92,91	8,93
10	77,05	3,81	76,67	6,75	89,41	3,24	93,14	9,18
11	76,39	3,74	76,51	6,61	89,34	2,83	93,17	8,26
12	76,48	3,95	76,35	6,87	88,83	2,91	93,44	8,04
13	77,22	4,00	76,33	6,49	89,34	2,78	93,44	8,18
14	77,05	4,07	76,35	7,41	88,96	3,52	93,47	8,27
15	77,55	4,16	76,17	6,67	88,96	3,26	93,17	9,06

Ao comparar as redes que obtiveram os melhores desempenhos para cada tipo de treinamento para os dados do ensaio CP4, evidenciadas em negrito nas tabelas acima, pode-se perceber que as redes treinadas utilizando gradiente descendente e gradiente descendente adaptativo obtiveram resultados ligeiramente melhores, considerando que o maior objetivo do trabalho é separar o final da classe PE do início de PI. A classe PE foi melhor classificada pelas redes que utilizaram gradiente descendente e a classe PI pelas

redes que utilizaram gradiente descendente adaptativo. Como essas diferenças de performance de classificação foram muito pequenas, e o treinamento utilizando gradiente descendente adaptativo é mais rápido do que utilizando gradiente descendente, decidiu-se por utilizar o primeiro. Colocar mais de sete neurônios na camada intermediária com o treinamento com a função escolhida não representaria uma melhora significativa para a rede. Assim, para treinar os dados de CP4, foram escolhidas redes com sete neurônios na camada intermediária e treinamento com gradiente descendente adaptativo.

5.3.2. *Desempenho das Redes*

As Tabelas 14 e 15 apresentam as matrizes de confusão do desempenho para os conjuntos de treino das redes treinadas para os ensaios CP3 e CP4, respectivamente, enquanto as Tabelas 16 e 17 apresentam os desempenhos obtidos para os conjuntos de teste. Os conjuntos de teste foram formados por 20% dos dados selecionados para realizar a validação cruzada e mais os dados retirados no balanceamento das classes.

Tabela 14 – Desempenhos das Redes Treinadas com os Dados de CP3 para os Conjuntos de Treino

	Média de Acertos (%)				Desvio-Padrão (%)			
	SP	SP/PE	PE	PI	SP	SP/PE	PE	PI
SP	93,33	6,67	0,00	0,00	5,58	5,58	0,00	0,00
SP/PE	5,71	88,57	5,71	0,00	2,93	4,48	2,93	0,00
PE	0,00	0,00	100,00	0,00	0,00	0,00	0,00	0,00
PI	0,00	0,48	0,00	99,52	0,00	1,47	0,00	1,47
Total	95,69				1,18			

Tabela 15 – Desempenhos das Redes Treinadas com os Dados de CP4 para os Conjuntos de Treino

	Média de Acertos (%)				Desvio-Padrão (%)			
	SP	SP/PE	PE	PI	SP	SP/PE	PE	PI
SP	87,96	3,48	8,55	0,00	4,25	2,28	3,99	0,00
SP/PE	6,47	82,41	11,12	0,00	2,41	4,38	4,45	0,00
PE	6,68	2,42	89,73	1,17	2,99	1,77	3,65	1,13
PI	0,00	0,00	1,89	98,11	0,00	0,00	2,65	2,65
Total	89,61				1,24			

Tabela 16 – Desempenhos das Redes Treinadas com os Dados de CP3 para os Conjuntos de Teste

	Média de Acertos (%)				Desvio-Padrão (%)			
	SP	SP/PE	PE	PI	SP	SP/PE	PE	PI
SP	76,67	8,33	8,33	6,67	21,90	14,81	18,34	13,68
SP/PE	6,43	86,43	7,14	0,00	7,29	9,80	7,33	0,00
PE	2,61	5,45	90,82	1,12	2,05	1,21	3,33	2,51
PI	0,22	7,72	0,76	91,29	0,49	4,42	1,20	4,88
Total	90,71				3,33			

Tabela 17 – Desempenhos das Redes Treinadas com os Dados de CP4 para os Conjuntos de Teste

	Média de Acertos (%)				Desvio-Padrão (%)			
	SP	SP/PE	PE	PI	SP	SP/PE	PE	PI
SP	74,32	3,81	21,87	0,00	4,02	2,49	3,50	0,00
SP/PE	14,57	73,72	11,71	0,00	2,12	5,53	5,99	0,00
PE	7,26	4,32	85,69	2,72	2,85	2,21	3,22	1,53
PI	0,00	0,00	4,92	95,08	0,00	0,00	5,12	5,12
Total	82,38				2,37			

Como pode ser notado pelas tabelas acima, a maior confusão apresentada pelas redes, tanto para o ensaio CP3, quanto para o ensaio CP4, é em relação as classes SP, SP/PE e PE. Isso já era esperado, uma vez que, no mapa auto-organizável de *Kohonen*,

essas classes se apresentaram em uma mesma grande região de neurônios próximos. A classe PI, por outro lado, conseguiu ser facilmente identificada pelas redes treinadas com os dados de ambos os ensaios. Quanto ao desvio padrão extremamente alto da classe SP dos dados do ensaio CP3, provavelmente isso se deve a pequena quantidade de amostras (15 registros) dessa classe. Como foi realizado treinamento com validação cruzada com 5 partições e 60% dos dados para treinamento, 20% para validação e 20% para teste, a classe SP do ensaio CP3 teve apenas 9 amostras para treinamento, 3 para validação e 3 para teste.

Também é interessante notar que as redes conseguiram uma boa generalização. Para as redes treinadas com os dados do ensaio CP3, devido ao balanceamento de classes escolhido, foram utilizados para o treinamento todos os dados das classes SP e SP/PE, no entanto, apenas 35 amostras de PE e 35 de PI foram utilizadas, o que representa menos da metade dos registros dessas classes. Mesmo assim, o percentual de acerto dessas classes para o conjunto de teste, que inclui os dados não utilizados na validação cruzada do treinamento, foi de aproximadamente 90%. Em relação às redes do ensaio CP4, foram utilizados no treinamento todas as amostras da classe PI, mas apenas 93 registros de SP e SP/PE, e 186 registros de PE, o que engloba quase todos os dados de SP/PE, mas exclui aproximadamente 30% de SP e 40% de PE. Ainda assim, o percentual de acerto dessas redes para o conjunto de teste, que inclui os dados excluídos da validação cruzada do treinamento, foi relativamente alto.

É importante saber se as redes seriam capazes de identificar os sinais de emissão acústica eliminados pela limpeza baseada na matriz de similaridade do cosseno. As Tabelas 18 e 19 mostram os resultados obtidos ao aplicar estas amostras retiradas nessa etapa da limpeza dos conjuntos de dados dos ensaios CP3 e CP4 às suas respectivas redes.

Tabela 18 – Desempenhos das Redes Treinadas com os Dados de CP3 para os Dados do Ruído Retirado da Matriz de Similaridade do Cosseno

	Média de Acertos (%)				Desvio-Padrão (%)			
	SP	SP/PE	PE	PI	SP	SP/PE	PE	PI
SP	6,88	0,31	84,69	8,13	4,00	1,40	3,19	2,94
SP/PE	5,16	10,16	62,42	22,26	4,49	3,19	6,13	5,82
PE	58,21	19,82	17,50	4,46	5,06	2,71	6,34	2,56
PI	4,79	18,89	8,16	68,16	2,25	2,57	6,64	9,01
Total	43,47				5,66			

Tabela 19 – Desempenhos das Redes Treinadas com os Dados de CP4 para os Dados do Ruído Retirado da Matriz de Similaridade do Cosseno

	Média de Acertos (%)				Desvio-Padrão (%)			
	SP	SP/PE	PE	PI	SP	SP/PE	PE	PI
SP	16,67	16,69	62,34	4,31	2,62	2,82	3,51	1,15
SP/PE	29,96	3,02	65,16	1,86	2,45	1,35	2,55	0,75
PE	36,65	25,81	32,73	4,81	1,89	2,31	2,92	1,13
PI	0,00	0,00	40,00	60,00	0,00	0,00	50,26	50,26
Total	16,30				1,03			

Observando as duas tabelas anteriores, é possível perceber que o percentual de acerto da rede para estas amostras de ruído é muito baixo. Esse resultado já era esperado, uma vez que, segundo a matriz de similaridade do cosseno, se tratam de registros mais parecidos com registros distantes do tempo em que foram captados do que com registros captados em instantes próximos durante os ensaios de EA, e, logo, registros mais próximos de outras classes do que com as classes as quais, de acordo com o tempo em que foram captados, deveriam pertencer. Por outro lado, as redes conseguiram, com algum êxito identificar os registros pertencentes à classe PI e classificar os dados das outras três classes como pertencentes a uma das três.

Por último, para testar se seria possível identificar os dados gerados em um ensaio através das redes treinadas com os dados de outro ensaio, os dados de CP3 foram aplicados às redes de CP4 treinadas por validação cruzada e vice-versa. Os respectivos resultados podem ser visualizados nas Tabelas 20 e 21. Todos os dados restantes após a limpeza total foram utilizados nestes testes.

Tabela 20 – Desempenhos das Redes Treinadas com os Dados de CP4 para o Conjunto de Dados de CP3

	Média de Acertos (%)				Desvio-Padrão (%)			
	SP	SP/PE	PE	PI	SP	SP/PE	PE	PI
SP	71,67	7,33	21,00	0,00	9,40	5,25	8,45	0,00
SP/PE	7,29	0,29	87,57	4,86	3,98	1,28	10,29	11,69
PE	15,26	16,32	68,42	0,00	6,26	7,18	10,27	0,00
PI	0,68	3,82	24,00	71,50	0,71	1,58	3,49	4,25
Total	61,74				4,46			

Tabela 21 – Desempenhos das Redes Treinadas com os Dados de CP3 para o Conjunto de Dados de CP4

	Média de Acertos (%)				Desvio-Padrão (%)			
	SP	SP/PE	PE	PI	SP	SP/PE	PE	PI
SP	47,33	18,07	26,37	8,22	3,71	2,38	3,62	2,45
SP/PE	8,05	1,05	59,67	31,24	2,34	1,27	20,03	20,28
PE	10,49	11,20	57,66	20,66	4,75	2,12	6,45	7,00
PI	0,48	1,83	0,00	97,69	1,07	2,26	0,00	2,27
Total	51,99				3,35			

Como já foi explicado, as emissões acústicas dependem dos valores dos parâmetros de tempo utilizados, e os parâmetros retirados dessa emissão dependem do *threshold*. Os responsáveis pelos testes hidrostáticos que geraram os dados informaram quais os prováveis valores de parâmetros de tempo utilizados, mas não os valores exatos, de forma que não se tem certeza que ambos os ensaios possuíssem valores iguais para estes

parâmetros. Além disso, como já foi dito, os valores de *threshold* utilizados nos ensaios foram diferentes. As faixas de frequência utilizadas para os parâmetros de potência parcial (PPF) também não foram iguais para os dois ensaios. Assim, era esperado que as redes treinadas com os dados de um ensaio não apresentassem um desempenho muito elevado de classificação para os dados do outro ensaio. Mesmo assim, as redes de CP4 conseguiram classificar razoavelmente bem SP, PE e PI dos dados do ensaio CP3, e conseguiram realizar uma boa separação das classes mais próximas (SP, SP/PE e PE) em relação à PI. As redes de CP3 obtiveram uma alta performance de classificação de PI dos dados de CP4, e conseguiram realizar uma separação razoável de SP, SP/PE e PE relativamente à esta classe.

5.4. ANÁLISE EM CONJUNTO

A seguir, são apresentados os resultados obtidos ao se utilizar a abordagem da análise em conjunto, explicada na seção de metodologia, que leva em consideração os valores de saída da rede para um determinado sinal de emissão acústica em conjunto com os resultados apresentados pela rede para alguns registros captados imediatamente antes do registro em análise.

As Tabelas 22 e 23 mostram os resultados obtidos para as amostras de treino e de teste, respectivamente, do ensaio CP3. Por sua vez, as Tabelas 24 e 25 apresentam os resultados da análise em conjunto para as amostras de treino e de teste, nessa ordem, para os dados do ensaio CP4. Para analisar os dados de cada ensaio foram empregadas as

respectivas redes treinadas com validação cruzada e cujos resultados já foram apresentados anteriormente neste trabalho.

Tabela 22 – Resultado da Análise em Conjunto das Saídas das Redes Treinadas com os Dados de CP3 para os Conjuntos de Treino

	Média de Acertos (%)				Desvio-Padrão (%)			
	SP	SP/PE	PE	PI	SP	SP/PE	PE	PI
SP	100,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
SP/PE	10,71	89,29	0,00	0,00	5,75	5,75	0,00	0,00
PE	0,00	4,05	95,95	0,00	0,00	2,80	2,80	0,00
PI	0,00	0,00	9,52	90,48	0,00	0,00	0,00	0,00
Total	92,92				1,55			

Tabela 23 – Resultado da Análise em Conjunto das Saídas das Redes Treinadas com os Dados de CP3 para os Conjuntos de Teste

	Média de Acertos (%)				Desvio-Padrão (%)			
	SP	SP/PE	PE	PI	SP	SP/PE	PE	PI
SP	96,67	1,67	1,67	0,00	10,26	7,45	7,45	0,00
SP/PE	20,00	80,00	0,00	0,00	16,97	16,97	0,00	0,00
PE	0,07	2,31	97,61	0,00	0,33	0,76	0,89	0,00
PI	0,04	2,10	2,01	95,85	0,20	2,94	0,40	2,93
Total	95,90				1,62			

Tabela 24 – Resultado da Análise em Conjunto das Saídas das Redes Treinadas com os Dados de CP4 para os Conjuntos de Treino

	Média de Acertos (%)				Desvio-Padrão (%)			
	SP	SP/PE	PE	PI	SP	SP/PE	PE	PI
SP	97,86	0,53	1,61	0,00	1,61	1,16	1,65	0,00
SP/PE	1,17	98,03	0,80	0,00	1,21	1,63	1,48	0,00
PE	1,75	2,60	95,65	0,00	2,47	0,82	2,59	0,00
PI	0,00	0,00	4,31	95,69	0,00	0,00	3,46	3,46
Total	96,58				1,48			

Tabela 25 – Resultado da Análise em Conjunto das Saídas das Redes Treinadas com os Dados de CP4 para os Conjuntos de Teste

	Média de Acertos (%)				Desvio-Padrão (%)			
	SP	SP/PE	PE	PI	SP	SP/PE	PE	PI
SP	97,18	0,08	2,74	0,00	2,19	0,37	2,20	0,00
SP/PE	13,80	82,97	3,23	0,00	5,17	7,89	4,91	0,00
PE	0,51	2,27	96,86	0,35	0,99	0,44	1,33	1,07
PI	0,00	0,00	11,46	88,54	0,00	0,00	5,97	5,97
Total	94,77				1,19			

Para a maioria das classes, os resultados apresentados ao analisar conjuntos de saídas das redes foram melhores do que aqueles obtidos analisando as respostas da rede separadamente. As classes que apresentaram melhor desempenho ao realizar a análise individual das amostras tiveram todos os seus registros utilizados na validação cruzada.

É interessante notar, também, que as classes que tiveram muitos dados não utilizados na validação cruzada obtiveram um melhor desempenho para as amostras de teste, que também incluem os dados não utilizados na validação cruzada, do que para as amostras de treino na análise em conjunto. Isso aconteceu para as classes PE e PI do ensaio CP3 e para a classe PE do ensaio CP4.

Também é importante observar quais seriam os resultados da aplicação da análise em conjunto aos dados retirados através da limpeza pela matriz de similaridade do cosseno. Como o objetivo da análise em conjunto é identificar as classes corretas apesar do ruído existente, os dados de ruído foram aplicados às redes juntamente com os dados limpos. As Tabelas 26 e 27, a seguir, mostram esses resultados para os dados dos ensaios CP3 e CP4, respectivamente.

Tabela 26 – Resultado da Análise em Conjunto das Saídas das Redes Treinadas com os Dados de CP3 para os Dados do Ruído Retirado da Matriz de Similaridade do Cosseno Junto com os Dados Limpos

	Média de Acertos (%)				Desvio-Padrão (%)			
	SP	SP/PE	PE	PI	SP	SP/PE	PE	PI
SP	38,55	0,00	61,45	0,00	4,62	0,00	4,62	0,00
SP/PE	0,30	61,52	35,98	2,20	1,05	3,76	4,25	2,22
PE	1,75	1,54	96,71	0,00	1,40	1,26	1,98	0,00
PI	0,15	6,19	1,64	92,02	0,29	3,79	1,32	4,79
Total	85,22				2,38			

Tabela 27 – Resultado da Análise em Conjunto das Saídas das Redes Treinadas com os Dados de CP4 para os Dados do Ruído Retirado da Matriz de Similaridade do Cosseno Junto com os Dados Limpos

	Média de Acertos (%)				Desvio-Padrão (%)			
	SP	SP/PE	PE	PI	SP	SP/PE	PE	PI
SP	23,52	6,21	67,88	2,39	4,32	2,59	5,44	0,46
SP/PE	12,65	13,14	74,13	0,07	2,85	3,02	4,47	0,21
PE	7,80	7,91	81,52	2,77	2,12	2,23	3,63	0,88
PI	0,00	0,00	2,98	97,02	0,00	0,00	2,43	2,43
Total	44,99				1,13			

Mais uma vez, as redes foram capazes de separar os dados em dois grandes grupos: um formado pelas classes SP, SP/PE e PE e outro composto pela classe PI. É interessante notar que, para a rede de CP3, a quantidade de dados de ruídos nas classes SP, SP/PE, PE e PI foi, respectivamente, 16, 31, 28 e 95. Já para o ensaio CP4, a quantidade de dados de ruídos nas classes SP, SP/PE, PE e PI foi, respectivamente, 396, 374, 291 e 1. Considerando que a quantidade de ruído no ensaio CP4, com exceção da classe PI, foi proporcionalmente maior do que no ensaio CP3, é normal que o percentual de acertos para os dados de CP4 tenha sido menor do que para os dados de CP3 na análise em conjunto dos dados de antes da retirada de ruído pela similaridade do cosseno. A classe

PI, cuja quantidade de ruído foi proporcionalmente menor no ensaio CP4 do que no ensaio CP3, obteve um melhor resultado para essa análise para os dados de CP4. Ainda assim, para ambos os ensaios, tanto a classe PE, quanto a classe PI, obtiveram um bom percentual de acertos, levando a crer que são classes mais facilmente identificáveis.

5.5. RELEVÂNCIA DE PARÂMETROS

Por último, foi realizado o estudo de relevância dos parâmetros. Para facilitar a visualização, foram plotados histogramas da relevância dos parâmetros por variável. A Figura 31 mostra estes histogramas para as redes dos ensaios CP3 e CP4. Como a relevância foi definida como a diferença média do percentual de acertos das redes treinadas com todos os parâmetros em relação ao resultado destas redes ao se substituir o valor de uma determinada variável pela média dessa variável para todos os registros do conjunto de dados, os histogramas também apresentam o desvio padrão dessas diferenças de resultado da rede. Os resultados utilizados para comparação são em relação às saídas obtidas pelas redes para todas as amostras de cada conjunto de dados. Os parâmetros presentes nos histogramas são: '1' = Tempo de Subida, '2' = Contagem, '3' = Energia, '4' = Duração, '5' = Amplitude, '6' = A-Freq, '7' = RMS, '8' = ASL, '9' = Contagem até o Pico, '10' = R-Freq, '11' = I-Freq, '12' = Sig-Strength, '13' = Energia Absoluta, '14' = PPF-1, '15' = PPF-2, '16' = PPF-3, '17' = PPF-4, '18' = C-Freq e '19' = P-Freq.

Deve ser lembrado que quanto maior for o valor positivo da diferença percentual de acertos da rede ao se retirar um determinado parâmetro, maior é a contribuição do

mesmo para uma correta identificação de uma ou mais classes. Em contrapartida, quanto maior for o valor negativo dessa diferença, mais este parâmetro dificulta a identificação de uma ou mais classes.

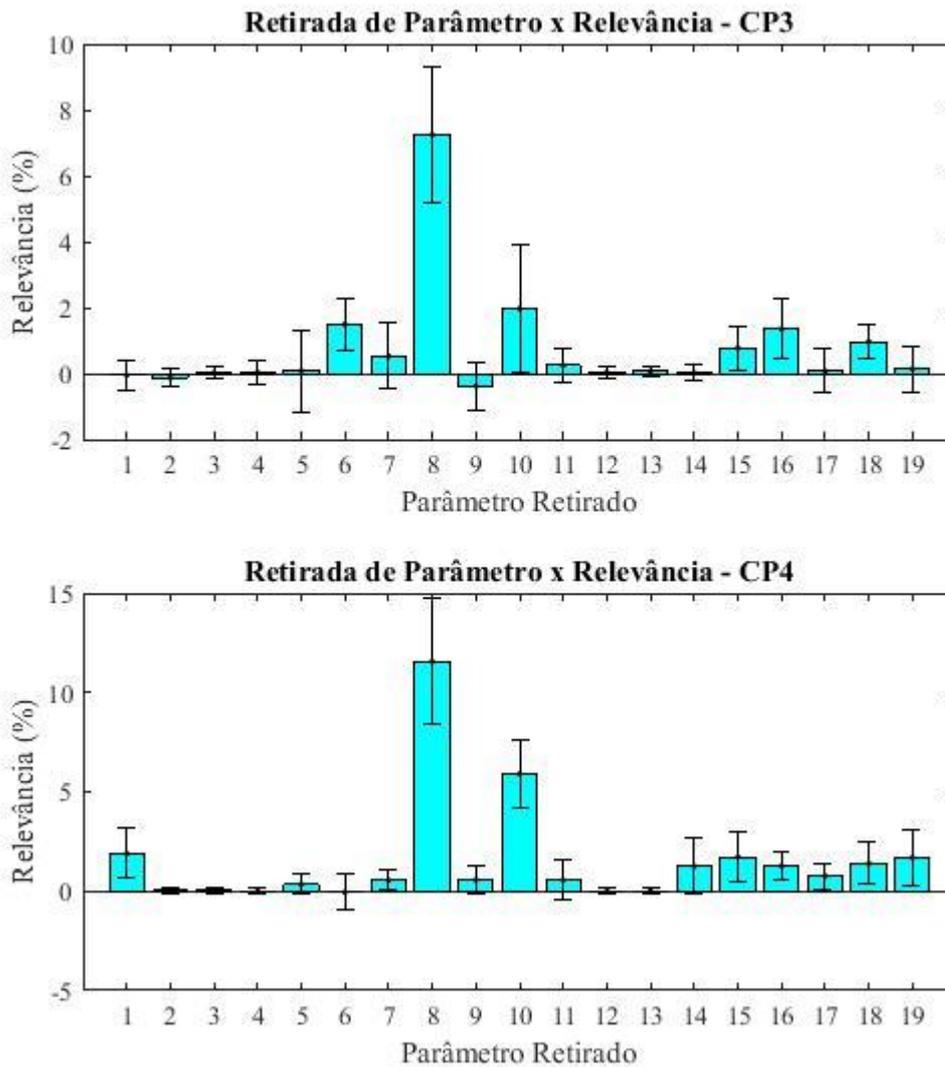


Figura 31 – Relevância dos Parâmetros para as Redes Treinadas.

É possível perceber que alguns parâmetros relevantes para as redes treinadas com os dados de um ensaio não são relevantes para as redes treinadas com os dados do outro. Pôde ser observada uma maior diferença média de relevância dos parâmetros 1, 14, 17 e 19 para as redes de CP4, sendo estes pouco relevantes para as redes de CP3. O parâmetro 6, por outro lado apresenta relevância para as redes de CP3, mas não para as de CP4.

Para quase todos os parâmetros, nos dois ensaios, o valor médio da relevância foi pequeno. E, ao se observar os valores de desvio padrão, poucos parâmetros apresentaram uma relevância significativa, como o parâmetro 8 para as redes de ambos os ensaios, e o parâmetros 10 para as redes de CP4. Em alguns casos, ao se observar o desvio padrão, a relevância pode ter apresentado para os dados de um mesmo ensaio, valores positivos ou negativos, dependendo da rede.

As Tabelas 28 e 29 mostram a relevância de cada parâmetro em relação a cada fase de propagação da trinca para os ensaios CP3 e CP4, respectivamente.

Tabela 28 – Relevância dos Parâmetros por Classe de Propagação – Ensaio CP3.

Parâmetro	Média (%)	DP (%)						
	SP	SP	SP/PE	SP/PE	PE	PE	PI	PI
1	-1,33	2,74	-0,57	1,17	0,63	1,10	-0,25	0,81
2	0,33	2,63	0,14	0,64	0,00	0,00	-0,36	0,43
3	0,00	0,00	0,00	0,00	0,00	0,00	0,04	0,36
4	1,00	3,26	0,00	0,00	0,05	0,24	-0,07	0,51
5	2,00	4,38	3,29	3,50	3,84	2,67	-3,46	1,93
6	6,33	4,58	0,14	1,13	2,89	1,93	0,36	0,88
7	-0,33	2,63	1,00	2,13	1,05	1,74	0,14	2,07
8	11,67	9,14	-0,29	1,58	13,84	5,41	4,18	1,81
9	0,00	2,16	0,00	0,93	0,26	0,67	-0,96	1,34
10	12,00	9,33	6,86	7,26	3,79	4,20	-1,57	1,49
11	1,67	3,67	-0,29	1,58	-0,47	1,11	0,71	0,73
12	0,00	0,00	0,00	0,00	0,00	0,00	0,07	0,32
13	0,00	0,00	0,00	0,00	0,00	0,00	0,14	0,29
14	0,00	0,00	-0,14	0,64	0,05	0,24	0,04	0,49
15	1,00	3,26	1,14	2,69	1,11	1,55	0,43	1,05
16	15,33	6,87	0,00	0,93	-0,42	1,25	1,39	1,47
17	-1,00	3,91	2,57	2,43	1,16	1,80	-1,18	0,81
18	0,33	3,40	0,00	0,93	1,68	1,42	0,79	0,77
19	0,00	3,06	1,14	1,71	1,11	1,39	-0,75	0,88

Tabela 29 – Relevância dos Parâmetros por Classe de Propagação – Ensaio CP4.

Parâmetro	Média (%)	DP (%)						
	SP	SP	SP/PE	SP/PE	PE	PE	PI	PI
1	9,63	3,00	4,62	2,59	-1,80	1,98	-0,32	1,82
2	-0,04	0,56	-0,10	0,43	0,13	0,29	-0,05	0,42
3	-0,22	0,49	-0,19	0,50	0,28	0,22	-0,05	0,24
4	-0,19	0,41	-0,24	0,42	0,16	0,23	0,05	0,24
5	0,78	1,35	0,33	1,21	-0,48	0,86	2,47	2,49
6	-0,04	0,85	0,38	1,46	-0,38	1,88	0,48	0,82
7	-1,44	1,14	-1,00	1,05	2,25	0,83	-0,32	0,71
8	35,48	12,79	-3,38	1,84	-4,61	2,02	46,72	6,68
9	1,74	1,34	0,52	0,84	0,56	0,87	-1,02	1,50
10	-8,48	3,35	3,76	9,22	14,70	5,00	0,38	0,94
11	-1,33	1,26	1,38	2,11	0,85	2,19	1,45	1,75
12	-0,15	0,30	-0,24	0,42	0,15	0,23	0,00	0,00
13	-0,07	0,23	-0,10	0,29	0,10	0,22	0,00	0,00
14	7,37	5,04	4,10	1,31	-2,05	2,35	0,05	0,55
15	-1,52	2,40	9,86	2,97	1,08	1,73	-0,65	1,01
16	7,41	3,28	-0,48	1,59	-1,43	1,38	3,17	2,19
17	8,15	3,08	0,29	3,00	-2,00	1,55	-0,32	0,79
18	0,48	1,72	8,86	4,39	-0,33	1,57	-0,05	0,65
19	7,85	2,58	4,57	5,85	-1,57	1,16	0,22	1,19

Observando as Tabelas 28 e 29, quase todos os parâmetros que influenciaram a correta classificação de alguma das classes, não apresentaram uma influência negativa na classificação de outra classe. Porém, para as redes de CP4, mesmo considerando o desvio padrão, isso ocorreu para os parâmetros 8 e 10.

Foram realizadas algumas tentativas de retiradas de combinações de variáveis, desde retirar todas as variáveis que não causam grande diferença no desempenho das redes ao serem excluídas, até se retirar todas as variáveis que influenciam negativamente em alguma das classes. Em todos os cenários, foram obtidos resultados piores ou iguais a quando são utilizados todos os parâmetros, mas não melhores.

Lembrando que foram escolhidos diferentes valores de *threshold* para os ensaios, que os parâmetros de potência parcial variam de acordo com as faixas de frequências escolhidas na execução do ensaio, e que não foram escolhidos valores iguais para essas faixas de frequência nos dois testes. E considerando que os parâmetros apresentaram relevâncias diferentes para cada conjunto de dados e que os mesmos sofrem variações de acordo com o valor de *threshold*, decidiu-se não retirar nenhuma variável das redes aqui treinadas. Acredita-se que é necessário analisar dados de mais testes, realizados com um maior rigor de padronização, para que se chegue a uma conclusão em relação à relevância de cada parâmetro para a identificação das fases de propagação das trincas.

6. CONCLUSÕES

Para este projeto, foi proposto avaliar se seria possível realizar a identificação das fases de propagação de trincas em dutos rígidos de 40 m através da análise de parâmetros de emissão acústica por redes neurais, como foi previamente realizado por PINTO (2014) em dutos de 1,81 m. Também se propôs identificar automaticamente as fases de propagação de trincas em um conjunto de dados de ensaios hidrostáticos.

Como mencionado nos objetivos do trabalho, na seção de introdução, era esperado serem identificadas três fases de propagação. No entanto, em ambos os ensaios, através da metodologia de identificação automática de classes desenvolvida, foram encontradas 4 classes. A classe PI dos dois ensaios, de acordo com a divisão escolhida, durou apenas alguns segundos. De acordo com especialistas da área de inspeção de dutos, este resultado encontrado para PI está de acordo com o tempo de duração de PI usualmente identificado por eles.

Apesar de PINTO (2014) ter identificado três classes de propagação de trincas em seu trabalho, o autor demonstrou que a classe de PI é uma região em que os registros são menos semelhantes entre si do que os registros das outras duas classes. O pesquisador mostra, ainda, que as outras duas classes se encontram em uma grande região de neurônios próximos no mapa auto-organizável de *Kohonen*. No trabalho aqui desenvolvido, também foi identificado que a classe de PI pertence a uma região de neurônios mais distantes no mapa, e que as outras classes fazem parte de uma região de neurônios próximos.

Quanto ao desempenho das redes neurais supervisionadas, as mesmas apresentaram um bom desempenho de classificação para o corte escolhido para as classes. A considerável confusão das redes entre as classes SP, SP/PE e PE indica que se tratam de classes com características muito semelhantes. A classe de PI, por outro lado, foi mais facilmente identificada pelas redes, mostrando que se trata de uma região com características mais diferentes.

Também é interessante notar que os desempenhos das redes melhor dimensionadas para cada função testada para o treinamento foram bastante semelhantes. Isso ajuda a confirmar que as redes treinadas com os conjuntos de dados utilizados nesse trabalho conseguem atingir uma boa generalização.

Quanto a análise em conjunto, foi demonstrado que avaliar conjuntamente um grupo de registros próximos no tempo ajuda a melhorar o percentual de acertos da rede. Assim, esta é uma boa opção para fazer com que as redes alcancem o resultado esperado, mesmo quando sinais de ruído estiverem presentes.

Os resultados obtidos até o momento, no trabalho aqui realizado e nas pesquisas de PINTO (2011, 2014), mostram que é possível utilizar sinais de emissão acústica analisados por redes neurais artificiais para identificar sinais de propagação de trincas. No entanto, muitas pesquisas ainda precisam ser realizadas para que este método possa ser utilizado na prática, entre elas, as sugestões para trabalhos futuros, mencionadas a seguir.

7. TRABALHOS FUTUROS

De acordo com os especialistas da área de inspeção de dutos, apesar de se dividir as fases de propagação de uma trinca ao longo do tempo de forma rígida, como se uma classe acontecesse após a outra, na verdade, durante uma fase de propagação, as fases precedentes a ela também ocorrem, visto que partes diferentes da trinca se propagam em diferentes fases. Essa ideia leva a hipótese de que os sinais retirados na limpeza através da similaridade do cosseno não se tratem de ruídos, mas sim de sinais de fases de propagação que acontecem fora de ordem no tempo. Assim, seria interessante, como trabalho futuro, realizar um estudo no qual se considerasse que após o início de uma nova fase de propagação, uma fase anterior possa estar ocorrendo. Isso poderia ser realizado através da metodologia empregada por GODIN *et al.* (2005) e CRIVELLI *et al.* (2014), onde são treinados mapas auto-organizáveis de *Kohonen*, cujos neurônios são clusterizados através do algoritmo de *k-means*, para que sejam encontradas as classes de cada registro.

Outra proposta de trabalho futuro é que fossem realizados mais ensaios, com diversos sensores espalhados ao longo dos dutos, para se testar até que distância da trinca os sensores podem estar para que seus dados ainda possam ser utilizados para se identificar as fases de propagação de trincas. Esse era um dos objetivos iniciais do trabalho, que não pôde ser executado devido ao mal funcionamento dos sensores 1, 3 e 4.

Também são necessários mais testes sobre a possibilidade de redes treinadas com dados de um ensaio ou de um sensor conseguirem identificar corretamente os dados

provenientes de outro sensor ou de outro ensaio. Para isso é necessário que todos os parâmetros de tempo, o valor de *threshold* utilizado para captar os eventos de EA e os valores das faixas de frequência definidas para os parâmetros de potência parcial sejam os mesmos. Como os valores dessas variáveis não foram os mesmos nos ensaios CP3 e CP4, o teste de intercambialidade das redes não pôde ser realizado de forma confiável.

REFERÊNCIAS

- BECKER, S., “Unsupervised Learning Procedures for Neural Networks”, **The international Journal of Neural Systems** v. 1-2, pp. 17-33, 1991.
- BIBLIA. Português. **A Bíblia Sagrada**. Tradução de João Ferreira de Almeida. Rio de Janeiro: Imprensa Bíblica Brasileira, 1977. 559 p.
- BOUSSETTA, H., BEYAOUI, M., LAKSIMI, A., et al., “Study of the filament wound glass/polyester composite damage behavior by acoustic emission data unsupervised learning”, **Applied Acoustics** v. 127, pp. 175-183, Dez. 2017.
- CLARKE, T; JACQUES, R., **Relatório Técnico Final**. LAMEF – UFRGS, 2016.
- CRIVELLI, D., GUAGLIANO, M., MONICI, A., “Development of an artificial neural network processing technique for the analysis of damage evolution in pultruded composites with acoustic emission”, **Composites Part B: Engineering** v. 56, pp. 948-959, 2014.
- DAI, Y., HUANG, D., XU, J., “Optimization Of Characteristic Parameters Of Pipeline Crack Identification Based On BP Neural Network”, **Advanced Materials Research** v. 926-930, pp. 3442-3446, 2014.
- Da SILVA, I.N., SPATTI, D.H., FLAUZINO, R.A., **Redes Neurais Artificiais para engenharia e ciências aplicadas: curso prático** São Paulo, Artliber Editora Ltda, 2010.
- Da SILVA, R.R., CALÔBA, L.P., SIQUEIRA, M.H.S., et al., “Pattern recognition of weld defects detected by radiographic test”, **NDT & E International** v. 37, n. 6, pp. 461-70, Set. 2004.
- DA SILVA, R.R., SOARES, S.D., CALÔBA, L.P., et al., “Detection of the propagation of defects in pressurised pipes by means of the acoustic emission technique using artificial neural networks”, **Insight: Non-Destructive Testing and Condition Monitoring** v. 48, n. 1, pp. 45-51, Jan. 2006.
- GAJA, H., LIOU, F., “Defects monitoring of laser metal deposition using acoustic emission sensor”, **International Journal of Advanced Manufacturing Technology** v. 90, n. 1-4, pp. 561-574, Abr. 2017.

- GAJA, H., LIOU, F., “Defect classification of laser metal deposition using logistic regression and artificial neural networks for pattern recognition”, **International Journal of Advanced Manufacturing Technology** v. 94, n. 1-4, pp. 315-326, Jan. 2018.
- GODIN, N., HUGUET, S., GAERTNER, R., et al., “Clustering of acoustic emission signals collected during tensile tests on unidirectional glass/polyester composite using supervised and unsupervised classifiers”, **NDT & E International** v. 37, n. 4, pp. 253-264, Jun. 2004.
- GODIN, N., HUGUET, S., GAERTNER, R., et al., “Integration of the Kohonen's self-organising map and k-means algorithm for the segmentation of the AE data collected during tensile tests on cross-ply composites”, **NDT & E International** v. 38, n. 4, pp. 299–309, Jun. 2005.
- HAN, J., KAMBER, M., PEI, J., **Data Mining Concepts and Techniques**. 3 ed. Waltham, Morgan Kaufmann Publishers, 2012.
- HAYKIN, S., **Redes Neurais: Princípios e Prática** 2 ed. Porto Alegre, Bookman, 2001.
- HELLIER, C.J., **Handbook of Nondestructive Evaluation** USA, McGraw-Hill Companies, Inc, 2003.
- JACQUES, R.C., 2009, **Avaliação de parâmetros de emissão acústica para monitoramento de risers flexíveis**, Tese de Dr.Ing., UFRGS, Porto Alegre, RS, Brasil.
- KIM, J.-T., SAKONG, J., WOO, S.-C., et al., “Determination of the damage mechanisms in armor structural materials via self-organizing map analysis”, **Journal of Mechanical Science and Technology** v. 32, n. 1, pp. 129-138, Jan. 2018.
- KRAL, Z., HORN, W., STECK, J., “Crack Propagation Analysis Using Acoustic Emission Sensors for Structural Health Monitoring Systems”, **The Scientific World Journal** v. 2013, ID. 823603, 13 páginas, 2013.
- MARCHETTE, D.J., SOLKA, J.L., “Using data images for outlier detection”, **Computational Statistics & Data Analysis** v. 43, n. 4, pp. 541-552, Ago. 2003.
- MAREC, A., THOMAS, J.H., EL GUERJOUA, R., et al., “Investigation of damage mechanisms of composite materials: Multivariable analysis based on temporal and wavelet features extracted from acoustic emission signals”, In: **International Symposium on Nondestructive Testing in Civil Engineering**, Nantes, França, Jun. 2009
- MIX, P.E., **Introduction To Nondestructive Testing: A Training Guide**. 2 ed. New Jersey, John & Sons, Inc, Hoboken, 2005.

PHYSICAL ACOUSTICS CORPORATION, **DiSP with AEwin USER'S MANUAL**.
Rev. 4 Princeton Junction, NJ, 2011.

PINTO, C.F.C., 2011, **Monitoração de defeitos em dutos rígidos por emissão acústica e redes neurais**. Dissertação de M.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.

PINTO, C.F.C., SILVA, R.R., CALÔBA, L.P., et al., “Uso de redes neurais artificiais na detecção de propagação de defeitos em dutos rígidos”, **Revista Matéria** v. 17, n. 3, pp. 1084-1097, 2012.

PINTO, C.F.C., 2014, **Monitoração de defeitos em dutos rígidos por análise dos parâmetros de emissão acústica utilizando redes neurais**. Tese de D.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.

PINTO, C.F.C., SILVA, R.R., CALÔBA, L.P., et al., “Probability of defect. propagation in pipelines (POP curves)”, **Insight: Non-Destructive Testing and Condition Monitoring** v. 56, n. 4, pp. 204-210, Abr. 2014.

SEIXAS, J.M., CALÔBA, L.P., DELPINO, I., “Relevance Criteria for Variance Selection in Classifier Designs”. In: **International Conference on Engineering Applications of Neural Networks**, pp.451-454, 1996.

YANG, L., KANG, H.S., ZHOU, Y.C., et al., “Intelligent Discrimination of Failure Modes in Thermal Barrier Coatings: Wavelet Transform and Neural Network Analysis of Acoustic Emission Signals”, **Experimental Mechanics** v. 55, n. 2, pp. 321-330, 2015.

YUKI, H., HOMMA, K., “Estimation of acoustic emission source waveform of fracture using a neural network”, **NDT & E International** v. 29, n. 1, pp. 21–25, Fev. 1996.

ZHANG, X., WANG, K., WANG, Y., et al., “An improved method of rail health monitoring based on CNN and multiple acoustic emission events”, In: **IEEE Instrumentation and Measurement Technology Conference**, Politecnico di Torino, Torino, Itália, Jul. 2017.