



MONITORAÇÃO DE DEFEITOS EM DUTOS RÍGIDOS POR ANÁLISE DOS  
PARÂMETROS DE EMISSÃO ACÚSTICA UTILIZANDO REDES NEURAIAS

Carlos Fernando Carlim Pinto

Tese de Doutorado 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 Doutor em  
Engenharia Elétrica.

Orientadores: Luiz Pereira Calôba

Romeu Ricardo da Silva

Rio de Janeiro

Dezembro de 2014

MONITORAÇÃO DE DEFEITOS EM DUTOS RÍGIDOS POR ANÁLISE DOS  
PARÂMETROS DE EMISSÃO ACÚSTICA UTILIZANDO REDES NEURAIAS

Carlos Fernando Carlim Pinto

TESE 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 DOUTOR EM  
CIÊNCIAS EM ENGENHARIA ELÉTRICA.

Examinada por:

---

Prof. Luiz Pereira Calôba, Dr.Ing.

---

Dr. Romeu Ricardo da Silva, D.Sc.

---

Profa. Beatriz de Souza Leite Pires de lima D.Sc.

---

Dr. Sergio Damasceno SOARES, D.Sc.

---

Dr. Marcio Humberto Silva Siqueira, D.Sc.

---

Profa. Marley Maria Bernardes R. Vellasco, Ph.D.

---

Prof. Jose Manoel Seixa, D.Sc.

RIO DE JANEIRO, RJ – BRASIL

DEZEMBRO DE 2014

Pinto, Carlos Fernando Carlim

Monitoração de Defeitos em Dutos Rígidos por Análise dos Parâmetros de Emissão Acústica Utilizando Redes Neurais/Carlos Fernando Carlim Pinto. – Rio de Janeiro: UFRJ/COPPE, 2014.

XXII, 170 p.: il.: 29,7cm.

Orientadores: Luiz Pereira Calôba

Romeu Ricardo da Silva.

Tese (doutorado) – UFRJ/ COPPE/ Programa de Engenharia Elétrica, 2014.

Referências Bibliográficas: p. 117 - 122.

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

# Dedicatória

*Aos meus pais, que investiram muito para minha formação. Sem seu apoio nunca teria conseguido.*

*A minha esposa Roberta, por todo seu amor, carinho e compreensão durante esta jornada.*

# Agradecimentos

...

Ao meu orientador, Luiz Pereira Calôba, o qual foi fundamental para a realização desta jornada. Muito obrigado professor, palavras são poucas para descrever a gratidão e apressado que tenho pelo senhor.

Ao meu segundo orientador, Romeu Ricardo da Silva, o qual passei a considerar como um irmão mais velho, sempre me apoiando e cobrando nas horas certas.

Agradeço ao Programa de Engenharia Elétrica, à COPPE, à UFRJ e a todos os professores, funcionários e alunos que tiveram papel importante na minha formação.

Aos meus amigos do LPS e SMT que sempre me apoiaram e ajudaram nas horas em que mais precisei.

A Daniele da secretaria do PEE, que sempre me ajudou e resolveu de maneira muito eficiente os meus problemas burocráticos.

Agradeço à PETROBRAS por ter fornecido todos os dados necessários para a realização deste trabalho.

Agradeço ao amigo Sergio Damasceno da PETROBRAS, por seus ensinamentos em Emissão Acústica.

Agradeço ao CNPq pela bolsa concedidas para a realização do doutorado. Agradeço a todos os integrantes da banca examinadora por aceitarem o convite de participação.

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

MONITORAÇÃO DE DEFEITOS EM DUTOS RÍGIDOS POR ANÁLISE DOS  
PARÂMETROS DE EMISSÃO ACÚSTICA UTILIZANDO REDES NEURAIAS

Carlos Fernando Carlim Pinto

Dezembro/2014

Orientadores: Luiz Pereira Calôba

Romeu Ricardo da Silva

Programa: Engenharia Elétrica

O monitoramento de dutos de transporte de petróleo e derivados em tempo real se tornou cada vez mais importante, principalmente quando se destina à segurança operacional. Os Testes de emissão acústica (EA) são aplicados para a inspeção de vários tipos de equipamentos. Esta tese apresenta a proposta de estudo sobre a utilização da emissão acústica para detectar propagação de defeitos em tubos rígidos pressurizados. Os sinais resultantes EA foram classificados como: Sem Propagação (SP), Propagação Estável (PE) e Propagação Instável (PI) e utilizados como dados na criação de classificadores não-lineares. O desempenho do classificador atingiu cerca de 100%, provando a eficiência do método nas condições testadas neste estudo. A partir dos classificadores criados, são apresentadas as metodologias utilizadas para a construção da curva de Possibilidade de Propagação (PoP) que permitirá predizer quando a propagação de uma trinca se tornará uma propagação instável.

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

MONITORING OF DEFECTS OF RIGID PIPES BY ANALYZING OF FEATURES  
ACOUSTIC EMISSION USING NEURAL NETWORKS

Carlos Fernando Carlim Pinto

December/2014

Advisors: Luiz Pereira Calôba

Romeu Ricardo da Silva

Department: Electrical Engineering

The real-time pipeline transportation of petroleum products monitoring has become increasingly important, especially when intended for operational security. Acoustic emission tests (AE) are applied to the inspection of various kinds of equipment. This thesis presents a proposal for a study on the use of acoustic emission to detect the propagation of defects in pressurized rigid pipes. The resulting signals were classified as: No Propagation (NP), Stable Propagation (SP) and Unstable Propagation (UP) and used as data in the creation of non-linear classifiers. Classifier performance reached about 100%, proving the efficiency of the method under the conditions tested in this study. From classifiers built are presented the methodologies used for the construction of the curve Possibility of Propagation (PoP) which will make it possible predict when the spread of crack will become an unstable propagation.

# Sumário

1	Introdução .....	1
2	Revisão Teórica .....	6
2.1	Emissão Acústica .....	6
2.1.1	Princípios e Teoria .....	6
2.1.2	Propagação do Sinal .....	7
2.1.3	Tipos de Sinais .....	8
2.1.4	Processamento dos Sinais .....	9
2.1.5	Parâmetros de EA .....	11
2.2	Redes Neurais Artificiais .....	13
2.2.1	Aprendizado Supervisionado .....	13
2.2.2	Aprendizado Não Supervisionado .....	14
2.2.3	Mapas Auto-Organizacionais .....	15
3	Revisão Bibliográfica .....	19
3.1	Monitoramento em Dutos de Transporte de Gás, Petróleo e Derivados .....	19
3.1.1	Inspeção Humana .....	19
3.1.2	Ensaio Ultrassônico .....	20
3.1.3	Monitoramento de Emissões Químicas .....	22
3.1.4	Fluxo Magnético .....	23
3.1.5	Supervisório de Controle de Aquisição de Dados (SCADA) .....	23

3.1.6	Métodos com EA .....	26
3.2	Reconhecimento de Padrões aplicados à EA .....	28
3.3	Conclusões .....	29
4	Metodologia.....	31
4.1	Classificador Neural.....	31
4.1.1	Acurácia dos Classificadores .....	32
4.1.2	Definição das Classes .....	33
4.1.3	Aquisição dos dados de entrada do Classificador .....	35
4.1.4	Critério de Relevância .....	36
4.2	Curva de Possibilidade de Propagação (PoP) .....	37
4.3	Análise de Agrupamentos .....	47
5	Discussão e Resultados.....	49
5.1	Classificador Neural.....	50
5.1.1	Ensaio 1 .....	50
5.1.2	Ensaio 2 .....	68
5.1.3	Ensaio 3 .....	80
5.2	Curva PoP .....	83
5.3	Análise de Agrupamentos dos Sinais de EA.....	96
5.3.1	Primeiro Passo .....	96
5.3.2	Segundo Passo .....	99

5.3.3	Terceiro Passo.....	109
6	Conclusões.....	114
7	Trabalhos Futuros .....	116
8	Referências Bibliográficas.....	117
	Apêndice.....	123

# Índice de Ilustrações

Figura 1 – Tipos de incidentes causadores de derramamento de petróleo e derivados. Fonte: PHMSA <i>Accident Hazardous Liquid</i> , 2010 – 2015. ....	2
Figura 2 – Local de ocorrência de vazamentos de petróleo e derivados. Fonte: PHMSA <i>Accident Hazardous Liquid</i> , 2010 – 2015. ....	2
Figura 3 – Detecção de vazamentos de petróleo e derivados. Fonte: PHMSA <i>Accident Hazardous Liquid</i> , 2010 – 2015. ....	3
Figura 4 - Características da emissão acústica (SOARES, 2008a).....	8
Figura 5 - À esquerda, um sinal transiente e à direita um sinal contínuo de EA (MIX, 2005).....	9
Figura 6 - Determinação do tempo de chegada (MIX, 2005).....	10
Figura 7 - Parâmetros de um sinal transiente (MIX, 2005).....	11
Figura 8 – Diagrama de blocos do aprendizado supervisionado (HAYKIN, 1999).....	13
Figura 9 - Algoritmo <i>K-means</i> .....	15
Figura 10 - Grade de neurônios de duas dimensões, com quatro entradas e nove neurônios, formando um mapa 3x3.....	16
Figura 11 – Algoritmo de formação do SOM.....	17
Figura 12 – Classificação e detecção de vazamento. O gráfico superior esquerdo mostras as probabilidades a prior e preditiva nos três tipos de vazamentos (0: sem vazamento; 1: vazamento comum; 2: vazamento por sabotagem). Os três cenários correspondem a três	

diferentes conjuntos de dados medidos. Os gráficos restantes mostram regiões de alta densidade para a distribuição da localização do vazamento para cada um dos três cenários diferentes (ROUGIER, 2005). .....	26
Figura 13 – Curva de pressão vs. tempo - linha tracejada. Curva de propagação da trinca vs tempo - linha contínua.....	35
Figura 14- Curva PoP teórica - A linha contínua cinza representa a possibilidade de SP, a linha preta contínua a possibilidade de PE e a linha de tracejada a possibilidade PI. ....	38
Figura 15 - A curva com a linha contínua é a densidade estimada e as linhas tracejadas são as funções do Kernel para cada ponto indicado (DRLEFT, 2010). .....	41
Figura 16 – Cura de Densidade de probabilidade teórica - A linha contínua representa a densidade de probabilidade da “classe” e a linha tracejada a densidade da “não classe”. Dados hipotéticos. ....	43
Figura 17 - Curva de probabilidade posteriori para a classe, gerada a partir da densidade de probabilidade. ....	44
Figura 18 – Gráfico da probabilidade em relação ao tempo da classe SP.....	44
Figura 19 - Curvas de Possibilidade da classe SP. Linha preta contínua – Curva de Possibilidade para o tempo até 4500s. A linha cinza contínua - Curva de Possibilidade para o tempo até 5000s. Linha preta tracejada - Curva de Possibilidade para o tempo até 5500s. Linha cinza tracejada - Curva de Possibilidade para o tempo até 13000s .....	46
Figura 20 – Exemplo Curva PoP para todas as classes. ....	46
Figura 21 – Ensaio 1 - Curva de Pressão vs. Tempo de Ensaio – linha tracejada. Curva de Crescimento da trinca vs. Tempo de Ensaio – linha contínua. ....	51

Figura 22 – Ensaio 1 - Distribuição dos valores de $Z_{SP}$ para a classe SP em relação aos conjuntos sorteados para classificação .....	56
Figura 23 – Ensaio 1 - Distribuição dos valores de $Z_{PE}$ para a classe PE em relação aos conjuntos.....	57
Figura 24 – Ensaio 1 - Distribuição dos valores de $Z_3$ para a classe PI em relação aos conjuntos sorteados para a classificação. ....	57
Figura 25 – Dados das classes SP e PE Ensaio 1 - Distribuição dos valores de $Z_1$ para a classe SP em relação aos conjuntos sorteados para classificação. ....	59
Figura 26 - Dados das classes SP e PE Ensaio 1 - Distribuição dos valores de $Z_2$ para a classe PE em relação aos conjuntos sorteados para classificação. ....	59
Figura 27 - Divisão dos novos conjuntos de treinamento e teste do Ensaio 1 para a classe SP e PE. (a) curva de Pressão vs. Tempo e Crescimento da Trinca vs. Tempo. (b) detalhe do conjunto de SP; (c) detalhe do conjunto de PE. ....	61
Figura 28 – Ensaio 1 - Distribuição dos valores de $Z_1$ para a classe SP em relação aos novos conjuntos sorteados para classificação. (a) Conjunto de treino; (b) Conjunto de teste 1; (c) Conjunto de teste 2.....	62
Figura 29 - Ensaio 1 - Distribuição dos valores de $Z_2$ para a classe PE em relação aos novos conjuntos sorteados para classificação. (a) Conjunto de treino; (b) Conjunto de teste 1; (c) Conjunto de teste 2.....	63
Figura 30 – Ensaio 1 - Separação dos dados de treinamento para Rede A de acordo com o novo critério proposto.....	64

Figura 31 - Ensaio 1 - Separação dos dados de treinamento para Rede B de acordo com o novo critério proposto.....	65
Figura 32 – Ensaio 1 - Distribuição dos valores de $Z_{sp}$ para a classe SP em relação aos intervalos definidos. (a) Rede A; (b) Rede B. ....	67
Figura 33 – Ensaio 1 - Distribuição dos valores de $Z_{PE}$ para a classe PE em relação aos intervalos definidos. (a) Rede A; (b) Rede B. ....	67
Figura 34 – Ensaio 1 - Distribuição dos valores de $Z_{PI}$ para a classe PI em relação aos intervalos definidos. (a) Rede A; (b) Rede B. ....	68
Figura 35 - Ensaio 2 - Curva de Pressão vs. Tempo de Ensaio – linha tracejada. Curva de Crescimento da trinca vs. Tempo de Ensaio – linha contínua. Separação ao longo do tempo das classes SP, PE e PI. ....	69
Figura 36 - Ensaio 2 - Curva de Pressão vs. Tempo de Ensaio – linha tracejada. Curva de Crescimento da trinca vs. Tempo de Ensaio – linha contínua. Separação ao longo do tempo das classes SP e P. ....	71
Figura 37 - Gráfico da relevância de cada parâmetro para cada uma das três classes ...	76
Figura 38 - Em cinza o histograma das relevâncias para as três classes juntas. As estrelas indicam a relevância de cada parâmetro para as três classes juntas. ....	77
Figura 39 - Separação de conjuntos pela relevância. À direita o percentual de acerto na classificação de cada conjunto.....	78
Figura 40 – Ensaio 3 – Curva de Crescimento da trinca vs. tempo.....	81
Figura 41 – Curvas de Possibilidade da classe SP para o Ensaio 3. Os pontos representam a probabilidade para cada valor de Z. A linha tracejada preta a curva estimada até 4500	

segundos, a linha contínua cinza a curva até 5000s, a linha tracejada cinza a curva até 6000s, a linha contínua preta a curva até 7000s e a linha pontilhada cinza a curva estimada com todos os sinais do Ensaio 3. ....	84
Figura 42 - Evolução do coeficiente “a” da equação de aproximação da curva de possibilidade da classe SP. ....	85
Figura 43 - Evolução do coeficiente "b" da equação de aproximação da curva de possibilidade da classe SP. ....	85
Figura 44- Curvas de Possibilidade da classe PE para o Ensaio 3. Os pontos representam a probabilidade para cada valor de Z. A linha contínua preta representa a curva estimada até 5000 segundos, a linha contínua cinza a curva até 6000s, a linha tracejada cinza a curva até 7000s, a linha tracejada preta a curva até 9000s e a linha pontilhada cinza a curva estimada com todos os sinais do Ensaio 3. ....	86
Figura 45 - Evolução do coeficiente “a” da equação de aproximação da curva de possibilidade da classe PE. ....	87
Figura 46 - Evolução do coeficiente “b” da equação de aproximação da curva de possibilidade da classe PE. ....	87
Figura 47 - Evolução do coeficiente “c” da equação de aproximação da curva de possibilidade da classe PE. ....	88
Figura 48 - Evolução do coeficiente “d” da equação de aproximação da curva de possibilidade da classe PE. ....	88
Figura 49 – Curvas de Possibilidade da classe PI. Os pontos representam a probabilidade para cada valor de Z. A linha tracejada cinza representa a curva estimada até 6000	

segundos, a linha contínua cinza a curva até 7000s, a linha tracejada preta a curva até 7500s, a linha contínua preta a curva até 8000s e a linha pontilhada cinza a curva estimada com todos os sinais do Ensaio 3. ....	89
Figura 50 - Evolução do coeficiente “a” da equação de aproximação da curva de possibilidade da classe PI. ....	90
Figura 51 - Evolução do coeficiente “b” da equação de aproximação da curva de possibilidade da classe PI. ....	90
Figura 52 - Curva PoP do Ensaio 3. ....	91
Figura 53 - Curva PoP do Ensaio 3– Curva estimada até 6.000 segundos. ....	92
Figura 54 - Curva PoP do Ensaio 3 – Curva estimada com os dados até 8.000 segundos. ....	92
Figura 55 - Curva PoP –Ensaio 2 – separação das classes. ....	94
Figura 56 – Curva PoP do Ensaio 3 estimada até 7500 segundos. ....	95
Figura 57 - Mapa de distâncias do Ensaio 3. ....	97
Figura 58 - Mapa das ativações dos neurônios. (a) ativação da classe SP. (b) ativação para classe PE. (c) ativação para classe PI. ....	98
Figura 59 - Fluxograma da formação do novo conjunto de treinamento formado com os dados do Ensaio 3 da rede neural de múltiplas camadas. ....	100
Figura 60 – Algoritmo <i>K-means</i> aplicado ao Grupo 1. ....	102

Figura 61 – Coeficiente de Silhueta dos grupos formados com os dados do Conjunto 1. (a) Silhueta para $K=2$ ; (b) Silhueta para $K=3$ ; (c) Silhueta para $K=4$ ; (d) Silhueta para $K=5$ .....	104
Figura 62 – Curva da Silhueta Média dos Agrupamentos formados. No eixo vertical o valor da Silhueta e no eixo horizontal os valores de $K$ . .....	105
Figura 63 – Algoritmo <i>K-means</i> aplicado ao grupo d.....	106
Figura 64 - Fluxograma de formação do Conjunto 2, a partir dos dados do Ensaio 3. ....	108
Figura 65 - Mapa das distâncias dos dados do Conjunto 2. ....	110
Figura 66 – Conjunto 2 - Mapa das ativações dos neurônios. (a) ativação da classe SP. (b) ativação para classe PE. (c) ativação para classe PI.....	110
Figura 67 - gráfico de classes em relação ao tempo de ensaio. (a) dados excluídos do Ensaio 3. (b) Conjunto 2.....	112

# Índice de Tabelas

Tabela 1 - Parâmetros de EA extraídos dos ensaios. (MIX, 2005, SOARES, 2008a). ..	12
Tabela 2- Definições da rede neural. ....	39
Tabela 3 – Equações de Z para as respectivas classes. ....	43
Tabela 4 – Modelo de aproximação da Possibilidade de cada classe. ....	45
Tabela 5 – Ensaio 1 - Índice de acerto em função da variação do número de neurônios na camada intermediária da rede neural treinada. ....	52
Tabela 6 – Ensaio 1 - Índices de acerto em função da variação do número de neurônios na camada intermediária da rede, com taxa de aprendizado ( $\alpha$ ) máximo igual a 0,2. ....	52
Tabela 7 – Ensaio 1 - Estimação da acurácia de classificação para os 10 pares de conjuntos sorteados .....	53
Tabela 8 – Ensaio 1 - tabela confusão dos conjuntos de treino e teste com duplicação de dados. ....	55
Tabela 9 - Definição da separação entre as classes para o treinamento da rede A. ....	65
Tabela 10 - Definição da separação entre as classes para o treinamento da rede B .....	65
Tabela 11 - Tabela confusão para dados de treinamento da rede A .....	66
Tabela 12 - Tabela confusão para dados de treinamento da rede B .....	66
Tabela 13 - Índice de acerto em função da variação do número de neurônios na camada intermediária da rede treinada para classificar três classes. ....	70

Tabela 14 – Ensaio 2 – Resultado da média de acerto para os 10 conjuntos de treino e teste (duas classes).....	71
Tabela 15 – Ensaio 2 - Resultados do desvio padrão da média de acerto para os 10 conjuntos de treino e teste (duas classes). STD – Desvio padrão da média geral de acerto. ....	72
Tabela 16 – Ensaio 2 - Tabela de Confusão média para os 10 conjuntos de treinamento e teste (três classes sem reclassificação). NC – não classificado .....	73
Tabela 17 - Tabela de Confusão do desvio padrão para os 10 conjuntos de treinamento e teste (três classes sem reclassificação). NC – não classificado. STD – Desvio padrão da média geral de acerto.....	74
Tabela 18 - Tabela de Confusão da média para os 10 conjuntos de treinamento e teste (três classes com reclassificação). ....	75
Tabela 19 - Tabela de Confusão do desvio padrão para os 10 conjuntos de treinamento e teste (três classes com reclassificação). STD – Desvio padrão da média geral de acerto. ....	75
Tabela 20 – Ensaio 2 – Estudo da relevância dos parâmetros de entrada. Tabela confusão da rede treinada com todos os 19 parâmetros de entrada. ....	79
Tabela 21 – Ensaio 2 – Estudo da relevância dos parâmetros de entrada. Tabela confusão da rede treinada com os 7 parâmetros mais relevantes (C-Frq, ASL, AMP, I-Frq,Freq-PP1, Freq-PP2, Freq-PP3). ....	79
Tabela 22 - Ensaio 3 - Tabela de Confusão média para os 10 conjuntos de treinamento e teste (três classes sem reclassificação). NC – não classificado .....	81

Tabela 23 - Equações de regressão tangente hiperbólica. ....	83
Tabela 24 - Equações de regressão tangente hiperbólica de Ensaio 2.....	93
Tabela 25 - Tabela de erros de classificação percentual. ....	95
Tabela 26 - Parâmetros de construção do SOM. Os valores foram determinados empiricamente. ....	96
Tabela 27 - Parâmetros de treinamento algoritmo <i>K-means</i> . ....	99
Tabela 28 - Tabela Confusão.....	99
Tabela 29 – Resultados da acurácia média para 10 conjuntos de treino e teste formados com os dados de Conjunto 1. NC – não classificado.....	101
Tabela 30 - Resultado da acurácia média para 10 conjuntos de treino e teste com os dados do Ensaio 3. NC – não classificado. ....	101
Tabela 31 - Tabela confusão para K=2.....	102
Tabela 32 - Tabela confusão para K=3.....	102
Tabela 33 - Tabela confusão para K=4.....	103
Tabela 34 - Tabela confusão para K=5.....	103
Tabela 35 - Tabela confusão para K=2.....	106
Tabela 36 - Tabela confusão para K=3.....	106
Tabela 37 - Tabela confusão para K=4.....	107
Tabela 38 – Tabela confusão para K=5. ....	107
Tabela 39 – Tabela confusão do fluxograma apresentado na figura 60. Em destaque os dados formadores do Conjunto 2.....	108

Tabela 40 - Resultados da acurácia média para 10 conjuntos de treino e teste formados com os dados de Conjunto 2. NC – não classificado.....	109
Tabela 41 – Tabela confusão dos dados de Ensaio 3 aplicados ao classificador treinado com os dados do Conjunto 2. NC –não classificado .....	111
Tabela 42 - Tabela confusão dos dados do Ensaio 2 com a transição da classe PE de 6000 para 5500 segundos .....	112

# Acrônimos

LPS – Laboratório de Processamento de Sinais

NC – Não classificado

PE – Propagação Estável

PHNSA – *Pipeline and Hazardous Materials Safety Administration*

PI – Propagação Instável

PIG – *Pipeline Inspection Gauge*

PZT – *Lead Zirconate Titanate* (formula química  $\text{Pb}[\text{Zr}_x\text{Ti}_{1-x}]\text{O}_3$  ( $0 \leq x \leq 1$ ))

SP – Sem Propagação

TMEC - Tecnologia de Materiais, Equipamentos e Corrosão.

ToFD – *Time of Flight of Diffraction*

# 1 Introdução

Em medicina, um exame não-invasivo é definido como procedimento que não rompe a pele ou penetra fisicamente no corpo e é de grande importância no diagnóstico de um paciente. Dentre os diversos tipos de exames, destacam-se o ultrassom, a tomografia computadorizada e a ressonância magnética. Análogo à medicina, na indústria existem os ensaios não-destrutivos (ENDs), só que aplicados a materiais e equipamentos. Estes ensaios constituem uma das principais ferramentas do controle da integridade material dos equipamentos, contribuindo para reduzir os custos de manutenção e garantindo a confiabilidade operacional dos mesmos.

Muitos dos acidentes industriais, em especial na indústria de Petróleo e Gás, devem-se à falha de materiais dos equipamentos, seja por projetos errados, condições adversas operacionais ou deficiências de manutenção. De acordo com a PHNSA – *Pipeline and Hazardous Materials Safety Administration*, instituição diretamente ligada ao departamento de transporte dos Estados Unidos, os acidentes com dutos de petróleo e derivados causam impactos ao meio-ambiente, afetam a saúde da população e geram altos custos de operação, o custo estimado dos últimos 20 anos está próximo de 7 bilhões de dólares. A maior parte dos acidentes é provocada por vazamentos, conforme mostra o gráfico da figura 1.

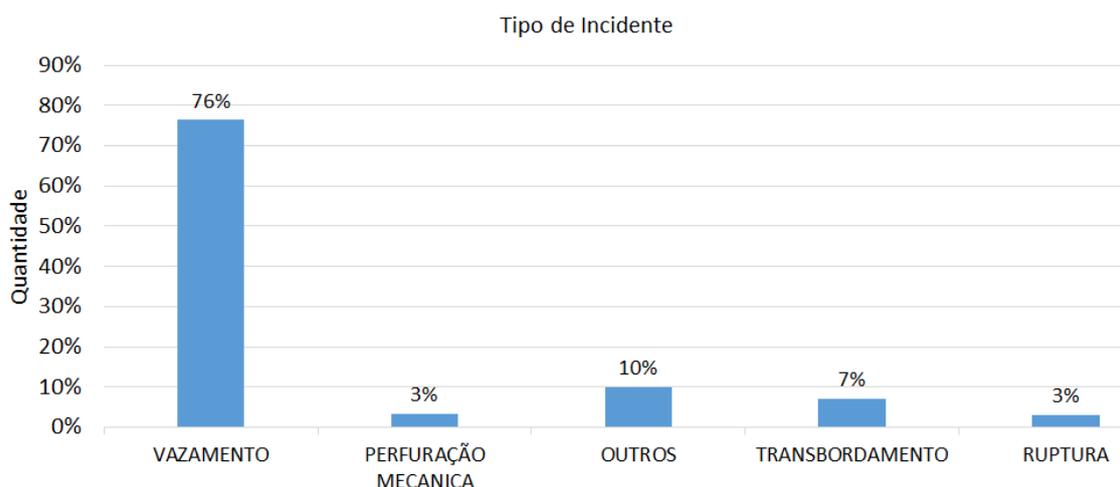


Figura 1 – Tipos de incidentes causadores de derramamento de petróleo e derivados. Fonte: PHMSA *Accident Hazardous Liquid*, 2010 – 2015.

As maiores incidências de vazamentos ocorrem no corpo do duto, conforme mostra figura 2, este fato comprova a necessidade do monitoramento eficiente e constante dos dutos. Contudo, apenas 10% dos vazamentos de petróleo e derivados ocorridos entre 2010 e 2015 nos Estados Unidos foram detectados por sistemas computacionais, a maior parte foi detectado pelo operador local após o agravamento do acidente, figura 3.

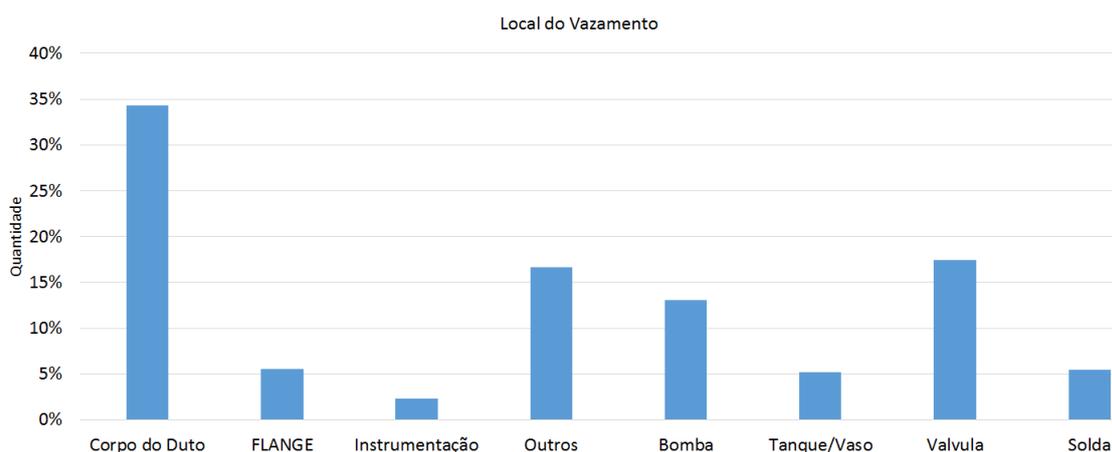


Figura 2 – Local de ocorrência de vazamentos de petróleo e derivados. Fonte: PHMSA *Accident Hazardous Liquid*, 2010 – 2015.

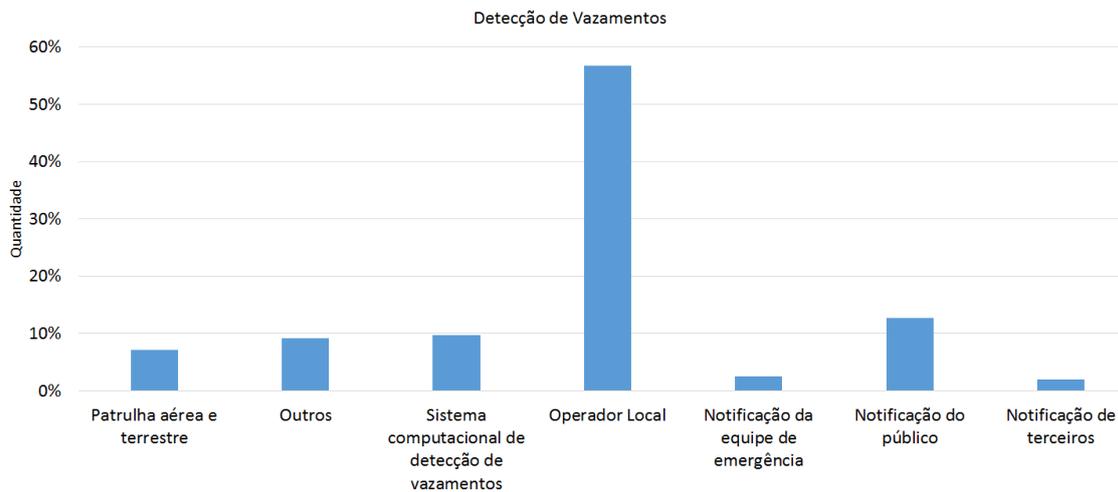


Figura 3 – Detecção de vazamentos de petróleo e derivados. Fonte: PHMSA *Accident Hazardous Liquid*, 2010 – 2015.

De acordo com SOARES (2008), o método de inspeção por Emissão Acústica (EA) é o mais indicado para monitoração em tempo real de estruturas. O método é baseado na detecção de sinais acústicos que são emitidos durante a propagação de discontinuidades e deformações plásticas acentuadas. Contudo, este método não é capaz de fornecer as dimensões dos defeitos/discontinuidades, uma vez que só fornece indicações de discontinuidades ativas durante o carregamento das estruturas sendo, entretanto, capaz de determinar a localização através de métodos de triangulação.

Os ensaios de EA têm extensa gama de aplicações na indústria petroquímica, soldagem, engenharia civil, indústria eletrônica, indústria aeroespacial, engenharia biomédica e monitoração de processos (SOARES, 2008).

Os ensaios de EA são realizados associados a ensaios de pressão e são utilizados para localizar e monitorar fontes de emissão, isto é, em que estágio encontra-se a propagação de deformações no equipamento (AMN, 2014). Os resultados destes ensaios determinam, por exemplo, se um duto de transporte de petróleo e derivados que apresente

uma trinca pode operar ou não com segurança. Uma desvantagem desta técnica é a dependência constante da análise das EA por um especialista.

A implementação de técnicas computacionais de determinação da presença ou crescimento de defeitos em equipamentos extrai a subjetividade das tomadas de decisão em inspeções meramente baseadas em um inspetor.

As técnicas de reconhecimento de padrões e modelagem de sinais associadas a ensaios não destrutivos vêm se mostrando ferramentas poderosas no desenvolvimento de sistemas automáticos ou semi-automáticos de inspeção de equipamentos (DA SILVA *et al.*, 2006, 2002, PINTO, 2011, 2014).

Motivado pela necessidade de tornar a análise dos sinais de EA automática e pela potencialidade de se implementar classificadores não lineares pelas técnicas de rede neurais, o presente trabalho tem como objetivo principal propor uma metodologia que determine automaticamente o estágio de crescimento de uma trinca/defeito em um duto rígido, desta forma indicando o momento em que o transporte de fluido através do duto deverá ser interrompido para manutenção do equipamento, antes que haja o seu rompimento de forma catastrófica, causando acidentes com possíveis perdas humanas e/ou ambientais, além de lucros cessantes para as empresas.

Neste trabalho, a metodologia utilizada propõe a criação de curvas de Possibilidade de Propagação (PoP) de defeitos através dos parâmetros extraídos dos sinais de EA empregados para monitorar testes hidrostáticos em dutos rígidos, determinando um índice de discriminação do crescimento de defeitos em três classes de sinais: Sem Propagação (SP), Propagação Estável (PE) e Propagação Instável (PI).

Ressalta-se que os sinais utilizados neste trabalho são provenientes de ensaios realizados em um projeto de P&D entre a PETROBRAS/CENPES/TMEC e o Laboratório de Metalurgia Física da UFRGS (LAMEF), e estão também inseridos no projeto intitulado Desenvolvimento e Avaliação de Técnicas de Reconhecimento de Padrões para Detectar a Propagação de Defeitos em Dutos Rígidos Inspeccionados por Emissão Acústica desenvolvido entre a PETROBRAS/CENPES/TMEC e a UFRJ/COPPE/LPS.

## **2 Revisão Teórica**

### **2.1 Emissão Acústica**

#### **2.1.1 Princípios e Teoria**

Em 1950, Joseph Kaiser publicou, em sua tese de doutorado, o primeiro estudo abrangente sobre o tema EA, onde descobriu que materiais emitem pulsos acústicos quando colocados sob esforços mecânicos. Uma vez que o corpo de prova tenha sido carregado e a emissão acústica tenha cessado, nenhuma nova emissão ocorrerá até que o nível de carregamento anterior tenha sido ultrapassado. Estas descobertas ficaram conhecidas como Efeito Kaiser e estes princípios são usados até os dias de hoje na teoria de emissão acústica.

A EA é o único método de ensaio não destrutivo (END) em que o material inspecionado gera o próprio sinal ao apresentar falha (MIX, 2005). Como já mencionado, este método é baseado no fato do material sólido emitir sinais de ultrassom durante esforço térmico ou mecânico nos pontos onde ocorrerem as deformações, permitindo identificar e mostrar a falha no momento em que ela é criada. Por este motivo, falhas não podem ser retestadas por EA: nestes casos, aplicam-se os métodos ultrassônicos, os quais detectam e caracterizam a falha após ela ser criada (SOARES, 2008).

O ensaio de EA é caracterizado por ser um método para detecção e monitoração da resposta de um material à variação da carga aplicada e geralmente requer que uma

tensão maior que a máxima tensão atingida durante a operação seja aplicada, especialmente no caso de equipamentos construídos com materiais metálicos (DA SILVA *et al.*, 2006]. A monitoração pode ser feita a partir de fontes remotas, em alguns casos à distância de vários metros, e realizada em tempo real do desenvolvimento das descontinuidades, detectando e localizando o crescimento de dano. Por ser não intrusivo, é aplicável para todas as estruturas, enterradas ou não, moldadas, revestidas ou não, prevenindo possíveis falhas repentinas no equipamento de pressão (SOARES, 2008a).

Um exemplo de fonte de EA é a corrosão de metais em fundos de tanques de armazenamento de óleo, onde a emissão acústica da falha se propaga através do líquido até a parede do tanque, onde pode ser detectada. Com o vazamento, a EA é produzida, por exemplo, pelo próprio fluxo turbulento do líquido ou pelas partículas que retornam do suporte do tanque. Neste caso, o sinal de falha de emissão acústica ocorre principalmente em altas pressões. As baixas diferenças de pressões causam principalmente fluxo laminar que emite sinais de EA contínuos com baixa amplitude e pouca distância de propagação, sendo considerado ruído (SOARES,2008a).

## **2.1.2 Propagação do Sinal**

Análogo ao epicentro de um terremoto, mas com dimensões microscópicas, um evento de EA é resultado do deslocamento pontual muito rápido do material. Este deslocamento é a fonte de uma onda elástica, a qual se propaga em todas as direções.

As ondas são detectadas por transdutores geralmente piezoelétricos, que convertem os movimentos da superfície do material em sinais elétricos. Estes sinais são

processados para indicar e localizar as fontes de emissão acústica (SOARES, 2008a). A

Figura 4 detalha o princípio da EA.

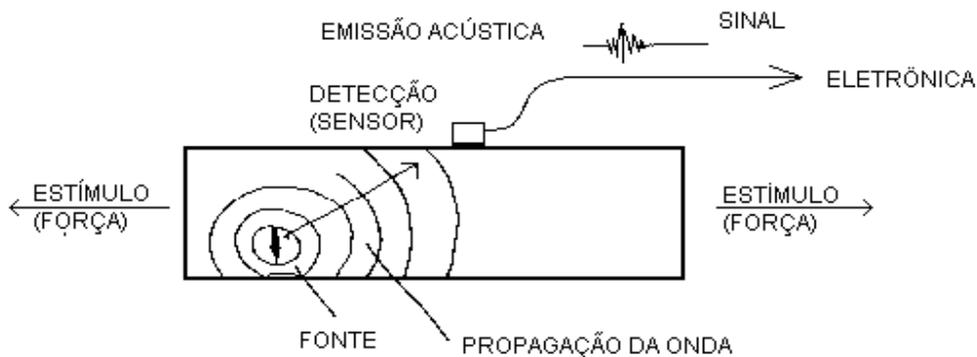


Figura 4 - Características da emissão acústica (SOARES, 2008a).

O cálculo da localização da fonte emissora de EA pode ser realizado pela diferença de tempo de chegada das diferentes ondas em diferentes sensores, pois dependendo da posição da fonte emissora, a onda atinge o sensor com certo atraso. Atualmente o cálculo de localização pode ser feito em tempo real, ou seja, durante a inspeção, e o resultado pode ser mostrado imediatamente (SOARES, 2008a).

Existem três fatores fundamentais para a determinação do local da fratura, são eles: atenuação do sinal, que define a distância necessária entre os sensores para a detecção confiável; velocidade de propagação, parâmetro fundamental para a determinação precisa da fonte emissora de EA; e tipos de ondas acústicas, os quais determinam o contorno da onda no entorno do sensor (SOARES, 2008b).

## 2.1.3 Tipos de Sinais

Existem dois tipos de emissão acústica: Emissão de Fratura e Emissão Contínua.

(a) Emissão de fratura: também conhecida como emissão transiente, é caracterizada por eventos discretos que podem ser separados um do outro, isto é, os pontos iniciais e finais diferem claramente do ruído de fundo (MIX, 2005).

(b) Emissão contínua: caracterizada por eventos que não podem ser separados um do outro, isto é, não há um ponto final para o sinal, pode-se apenas visualizar a amplitude e a variação de frequência (MIX, 2005).

A Figura 5 ilustra os dois tipos de emissão, a esquerda um sinal transiente e a direita um sinal contínuo. Neste exemplo, os transientes detectados em ensaios de EA em grandes vasos de pressão são sinais de fratura provenientes do crescimento de uma trinca no vaso, e os sinais contínuos são normalmente provenientes de ruídos indesejáveis (MIX, 2005).

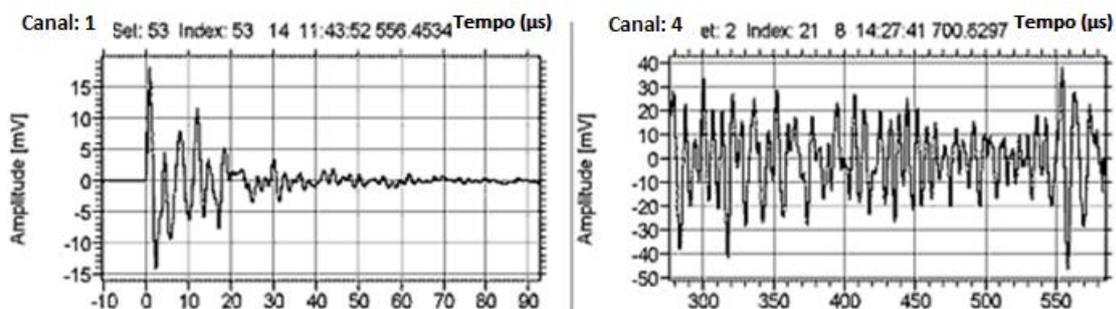


Figura 5 - À esquerda, um sinal transiente e à direita um sinal contínuo de EA (MIX, 2005).

## 2.1.4 Processamento dos Sinais

Os sistemas de processamento de sinais de EA são responsáveis pela conversão do sinal detectado em um conjunto de dados e pela eliminação do ruído de fundo.

Inicialmente, são ajustados limites de detecção, um positivo e um negativo: se o sinal exceder um destes limites, significa um sinal de deformação. O tempo em que o sinal cruza pela primeira vez um dos limites, é conhecido como Tempo de Chegada. A Figura 6 apresenta um exemplo de forma de onda com os limites positivo e negativo, assim como o tempo de chegada.

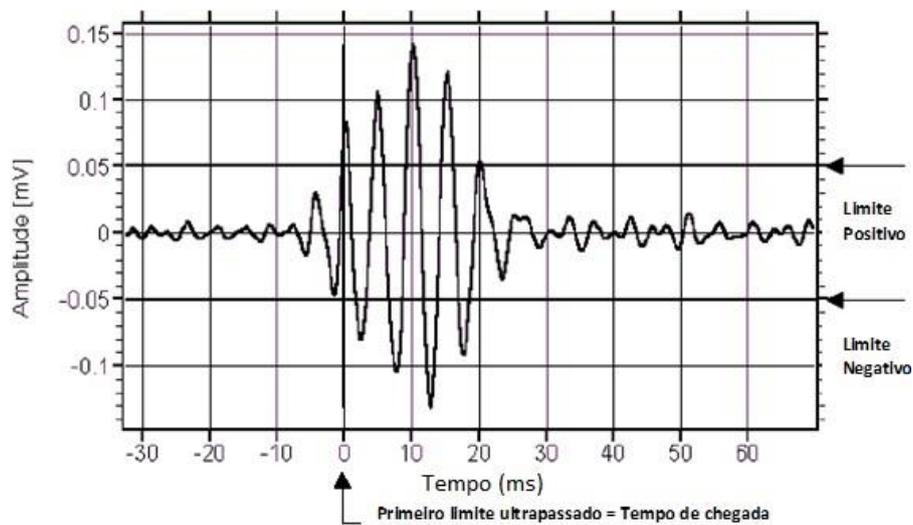


Figura 6 - Determinação do tempo de chegada (MIX, 2005).

No processamento, o sinal de EA é amostrado a cada 100  $\mu$ s. No gráfico da Figura 3, a cada 10 ms há 100 amostras, conseqüentemente no intervalo de tempo de 100 ms uma onda contém mais de 1000 amostras, demonstrando a necessidade de grande quantidade de memória e poder de processamento do sistema.

## 2.1.5 Parâmetros de EA

Os sistemas de EA permitem a captação de diversos parâmetros durante um ensaio, contudo os mais usados são: amplitude máxima, tempo de subida, duração do sinal, energia e valor RMS (Média aritmética da raiz quadrada, em inglês, *Root Mean Square*) (Figura 7)(MIX, 2005).

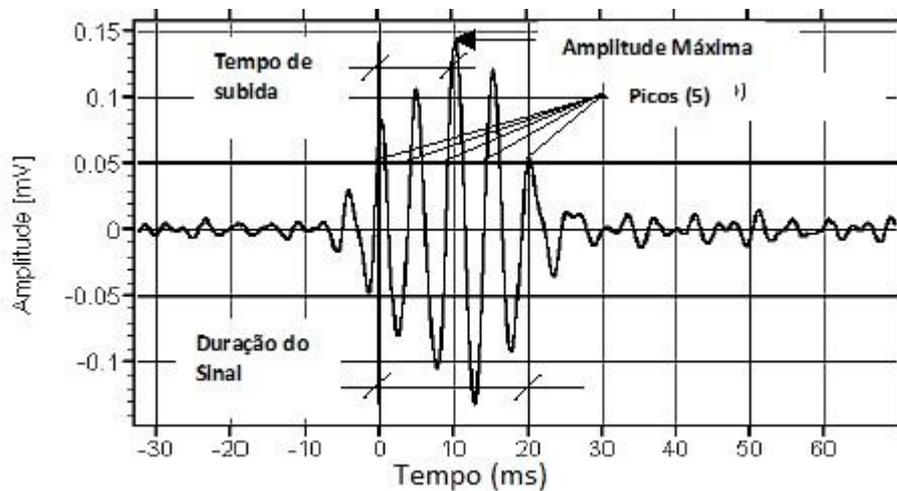


Figura 7 - Parâmetros de um sinal transiente (MIX, 2005).

A Amplitude é o pico máximo alcançado pela onda e é um dos atributos mais importantes para determinar o estágio de propagação do sinal, pois geralmente o sinal de trinca se caracteriza por valores médios para altos de amplitude e tem duração aproximada de 10 ms. Então sinais com menos de três pontos de cruzamento e duração menor do que 3 ms podem ser considerados como ruído e devem ser descartados.

A Tabela 1 apresenta de forma sucinta descrições para cada parâmetro extraídos nos ensaios de EA que serviram de entrada para a rede neural treinada.

Tabela 1 - Parâmetros de EA extraídos dos ensaios. (MIX, 2005, SOARES, 2008a).

Parâmetro	Descrição
Tempo de Subida	Tempo do primeiro pico a ultrapassar o limiar de referência até o pico de amplitude máxima.
Contagem	Número de vezes em que o sinal ultrapassa o limiar.
Energia	Integral do valor absoluto, ou módulo, de cada pico da onda. Como se trata de um sinal temporalmente discreto, somam-se os valores das amostras da forma de onda retificada. Cabe salientar que a amplitude aqui se refere a uma medida de tensão/voltagem e não decibel.
Duração	Intervalo de tempo entre a primeira e a última ultrapassagem do limite pela EA.
Amplitude (AMP)	Amplitude máxima do sinal, em dB.
A-Freq	Frequência Média: a definição é contagem sobre duração, [contagem/duração].
RMS	Raiz quadrada da integral dos valores de tensão ao quadrado dividida pelo intervalo de tempo dado pela diferença de tempo entre os limites superior e inferior de integração.
ASL	Nível médio do sinal, em dB.
PCNTS	Número de picos até a amplitude máxima ser alcançada, sempre levando em consideração o limiar de referência.
R-Freq	Frequência de reverberação: definida por: [contagem – contagem ao pico] / [duração - tempo de subida].
I-Freq	Frequência de Iniciação (definida por: contagem ao pico / tempo de subida)
<i>Sig-Strength</i>	Intensidade ou potência do sinal: praticamente a definição de energia, porém com coeficiente mais simples de $\text{sen}(\pi/4)$ .
Energia Absoluta	Quantidade real de energia sendo a unidade base pico Joule, definido pela soma das amplitudes das amostras ao quadrado dividido pela impedância de 10 kOhm. É importante lembrar que este parâmetro é normalizado.
Freq-PP1	Primeira potência parcial.
Freq-PP2	Segunda potência parcial.
Freq-PP3	Terceira potência parcial.
Freq-PP4	Quarta potência parcial.
C-Freq	Centróide de frequência: não necessariamente a frequência central, correspondente ao centro do espectro, mas uma frequência que leva em consideração “pesos” devido à magnitude e espalhamento.
P-Freq	Frequência pico: componente de frequência de maior magnitude no espectro.

## 2.2 Redes Neurais Artificiais

### 2.2.1 Aprendizado Supervisionado

No aprendizado supervisionado, um “professor” fornece categorias ou classes para cada padrão em um conjunto de treinamento (DUDA, 2010). O “professor” tem o conhecimento do ambiente a ser modelado e este conhecimento é representado pelos exemplos de entrada e saída do conjunto de treinamento (HAYKIN, 1999). A figura 8 apresenta o diagrama de blocos deste tipo de aprendizado.

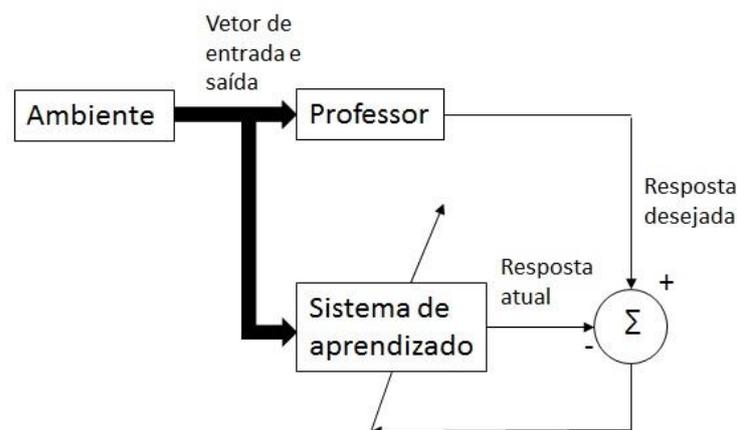


Figura 8 – Diagrama de blocos do aprendizado supervisionado (HAYKIN, 1999).

O “professor” e o sistema de aprendizado são ambos expostos ao conjunto de treinamento (vetor de entrada e saídas), o qual contém a resposta desejada para determinada entrada. Desta forma, os parâmetros da rede neural são ajustados em virtude do vetor de entrada e do sinal de erro, este é definido como a diferença entre a resposta desejada e atual apresentada pela rede. Os ajustes de parâmetros ocorrem iterativamente fazendo com que o “professor” encontre os ajustes ótimos para os parâmetros da rede

neural. A técnica descrita é conhecida como aprendizado por correção de erro. (HAYKIN, 1999).

## **2.2.2 Aprendizado Não Supervisionado**

No aprendizado não supervisionado, não existe a figura do “professor” durante o processo de treinamento, isto é, não existem exemplos de entrada com saídas conhecidas a serem aprendidos pela rede neural (HAYKIN, 1999). De acordo com DUDA (2001), existem pelo menos cinco razões básicas para realizar procedimentos não supervisionados. Primeiro, coletar e categorizar um grande conjunto de amostras pode ser altamente custoso. Um classificador pode ser modelado a partir de um pequeno conjunto de amostras categorizadas e então ajustado para rodar sem supervisão um grande conjunto de amostras sem categorias, desta forma economizando tempo e custo computacional. Segundo, treinar um conjunto grande de amostras não categorizadas e então aplicar aprendizado supervisionado nos agrupamentos formados. Terceiro, em muitas aplicações as características dos padrões podem mudar vagarosamente com o tempo. Se estas mudanças puderem ser rastreadas por um classificador não supervisionado, pode-se alcançar melhora na performance. Quarto, se pode utilizar métodos não supervisionados para encontrar atributos que são uteis para a categorização. Quinto, em dados completamente desconhecidos pode-se ter um ganho em conhecimento a respeito da natureza e estrutura dos dados. A descoberta de subclasses distintas ou similaridades entre os padrões pode indicar que direção deve ser tomada no desenvolvimento do classificador.

### 2.2.2.1 Método K-means

O algoritmo do *K-means* é um método utilizado para encontrar grupos e os centros de grupos a partir de um conjunto de dados sem classificação prévia. O *K* se refere ao número de centros no qual se deseja que os dados sejam agrupados (HASTIE, 2008).

De acordo com RAJARAMAN *et al.*(2011), o valor de *K* pode ser determinado por tentativa e erro e o objetivo principal do algoritmo está em atribuir iterativamente cada ponto ao grupo mais próximo, onde “próximo” significa próximo ao centro do agrupamento.

O Diagrama da figura 9 ilustra os passos do algoritmo. Dada a inicialização aleatória dos centros, os agrupamentos são formados e para cada um é calculado a distância média dos elementos ao centro, então esta distância é definida como novo centro. A convergência acontece quando não ocorre mais mudanças dos centros.

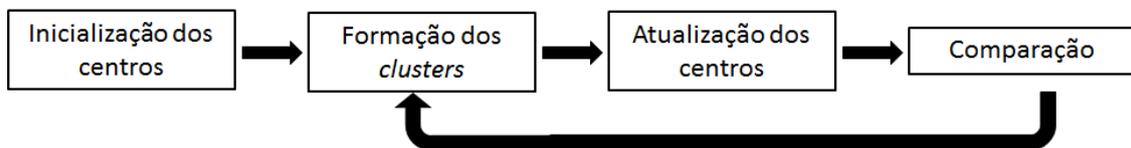


Figura 9 - Algoritmo *K-means*.

## 2.2.3 Mapas Auto-Organizacionais

De acordo com HASTIE *et al.* (2008), este método pode ser visto com uma versão mais genérica do algoritmo de *K-means*, na qual as entradas são “encorajadas” a estarem em espaços de uma ou duas dimensões do espaço de atributos, isto é, a alta dimensionalidade das observações pode ser mapeada em um sistema de duas dimensões.

DUDA *et al.* (2001) diz que o objetivo é representar todos os pontos do espaço de entrada em um espaço alvo, de forma que as relações de distância e proximidade sejam preservadas tanto quanto possível. O Mapa Auto-Organizável, em inglês *Self-Organizing Map* (SOM), é um método particularmente útil quando existe um mapeamento não linear inerente ao próprio problema.

O principal objetivo do SOM é transformar um padrão de entrada de dimensão arbitrária em um mapa discreto de uma ou duas dimensões, e realizar esta transformação de forma topologicamente adaptativa (HASTIE, 2008).

Conclui-se que um SOM pode ser interpretado como uma rede neural *feedforward* (HAYKIN, 1999) de uma única camada, onde cada neurônio está conectado a todos os nós do vetor de entrada. Geralmente os neurônios estão arranjados em linhas e colunas de modo a formar uma grade, como mostra a figura 10.

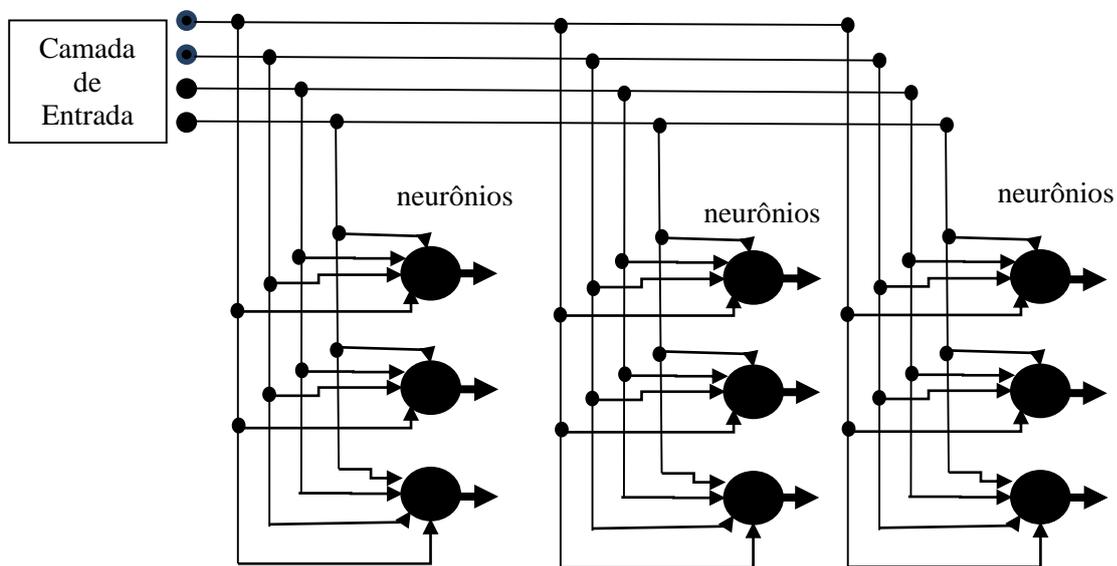


Figura 10 - Grade de neurônios de duas dimensões, com quatro entradas e nove neurônios, formando um mapa 3x3.

O algoritmo responsável pela formação do SOM pode ser descrito de acordo com o diagrama representado na figura 11.

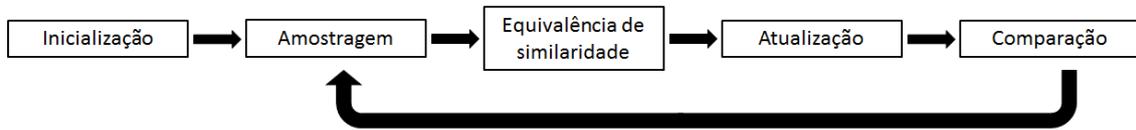


Figura 11 – Algoritmo de formação do SOM.

O primeiro passo é realizar a inicialização dos pesos sinápticos da rede. Estes podem ser atribuídos a partir de um gerador randômico de pequenos valores numéricos. A única restrição é que o vetor de pesos  $w_j(0)$  seja diferente para cada  $j = 1, 2, \dots, k$ , onde  $k$  é o número de neurônios da rede.

A amostragem é realizada aleatoriamente a partir do espaço de entradas formando o vetor  $x$ , o qual representa um padrão de ativação a ser aplicado à grade.

A equivalência de similaridade é calculada utilizando o critério da mínima distância Euclidiana e desta forma é determinado o neurônio vencedor  $i(x)$  a cada passo  $n$ . A equação 1 determina a melhor equivalência [HAYKIN, 1999].

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

Após a determinação do neurônio vencedor, é realizada a atualização dos pesos sinápticos de acordo com a equação 2 (HAYKIN, 1999).

$$w_j(n + 1) = w_j(n) + \eta(n)h_{j,i(x)}(n) (x(n) - w_j(n)) \quad (2)$$

Onde,  $\eta(n)$  é a taxa de aprendizagem e  $h_{j,i(x)}(n)$  é a função de vizinhança que determina o montante de atualização a ser aplicada aos vizinhos mais próximos do neurônio vencedor  $i(x)$  em função da distância entre estes neurônios. A taxa de aprendizagem  $\eta(n)$  é decrescida com o tempo  $n$  e a função de vizinhança  $h_{j,i(x)}(n)$  é usualmente uma Gaussiana cujo desvio padrão decai com o tempo  $n$ . Em nosso caso utilizamos a formulação e parâmetros apresentados em HAYKIN (1999).

$$\eta(n) = \eta_0 \exp\left(-\frac{n}{\tau_\alpha}\right) \quad \eta_0 = .1 \quad \tau_\alpha \cong 500 \quad (3)$$

$$h_{j,i(x)}(n) = \exp\left(-\frac{m_{j,i(x)}^2}{2\sigma^2(n)}\right) \quad m_{j,i(x)}^2 = |N_j - N_{vencedor}|^2 \quad \sigma = \sigma(n) = \sigma_0 \exp\left(-\frac{n}{\tau_h}\right) \quad (4)$$

$$\sigma_0 \approx \frac{\text{max\_dim\_grade}}{5} = 0.2\sqrt{P^2 + Q^2} \quad \text{para\_mapa\_bidimensional} \quad \tau_h = \frac{1000}{\ln \sigma_0}$$

O último passo é comparar o mapa atual com o anterior, caso seja observada diferença entre eles, o algoritmo é repetido a partir do passo 2.

Com o mapa pronto, importantes agrupamentos entre as amostras podem ser observados, conforme será descrito no capítulo 5.

## **3 Revisão Bibliográfica**

Neste capítulo, será apresentada uma revisão bibliográfica dividida em três partes:

1. Monitoramento em dutos de transporte de gás, petróleo e derivados.
2. Reconhecimento de padrões em EA.
3. Conclusões

### **3.1 Monitoramento em Dutos de Transporte de Gás, Petróleo e Derivados**

#### **3.1.1 Inspeção Humana**

A inspeção humana é realizada por inspetores treinados para identificar, monitorar e localizar vazamentos ao longo de dutos. De acordo com MIRANDA (2003), um inspetor bem treinado é capaz de identificar o odor de gases em mistura, escutar sons emitidos por vazamentos e visualizar solos descolorados ou contaminação na água.

Os sons emitidos por uma falha em uma conexão, por uma trinca ou por um ponto de corrosão, no duto, geralmente indicam o vazamento de gás. Uma das vantagens deste método é que não tem custo envolvido, pois faz parte da rotina de inspeção do operador. Contudo, o método é ineficiente na detecção de pequenos vazamentos (MANDAL, 2014).

No monitoramento pelo odor, gás odorante é intencionalmente dispersado no ar, abaixo da concentração de explosão, desta forma ao passar por um solo contaminado ou através de algum gás diferente, o mesmo é filtrado e seu odor modificado, indicando contaminação. Contudo o odor não é um método totalmente confiável para indicar a presença ou ausência de vazamento de gases (MANDAL, 2014).

### 3.1.2 Ensaio Ultrassônico

A inspeção ultrassônica pode ser aplicada como um END para a análise das condições estruturais de um duto (MIX, 2005). Os transdutores ultrassônicos são cristais piezelétricos que funcionam como emissores e receptores de ondas sonoras. As ondas sonoras são transmitidas no material a ser testado e se uma descontinuidade é encontrada, parte da energia ultrassônica é refletida de volta para o transdutor. Então, este transforma a onda sonora em pulsos elétricos e através da amplitude do sinal são extraídas características da falha. A localização da falha é determinada pelo intervalo de tempo entre a emissão e a recepção da onda refletida, este tempo é denominado como o tempo de voo (em inglês, *time of flight*) da onda através do material (MIX, 2005).

Recentemente, o uso de ondas de *Lamb* em END tem se mostrado crescente (AGRAWAL, 2008) Ondas de *Lamb* são ondas ultrassônicas guiadas capazes de se propagar por longas distâncias em placas e estruturas laminadas, como tanques de armazenamento e vasos pressurizados (MIX, 2005). JIN e EYDGAHI (2008) em seu trabalho utiliza Ondas de *Lamb* para identificar falhas através de sensores piezelétricos feitos de titanato zirconato de chumbo (em inglês, *Lead zirconium titanate* – PZT). Os sensores funcionam simultaneamente como receptor e emissor, gerando e emitindo ondas

guiadas através do duto. Desta forma, uma rede de PZT atuadores/sensores permite o monitoramento automático e em tempo real do duto.

ToFD (em inglês, *Time of Flight of Diffrction*) é uma técnica baseada no tempo de voo de ecos de ondas ultrassônicas difratadas nas pontas de descontinuidades, as quais estão diretamente relacionadas com a verdadeira posição (SILK, 1997). Esta técnica utiliza dois transdutores, um emissor e um receptor, e quando o ultrassom é emitido, os limites do defeito (uma trinca por exemplo) funcionam como fontes de ondas difratadas. A partir do sinal recebido pode ser gerada uma imagem bidimensional do defeito (ERHARD e EWERT, 1999).

ZAHRAN e Al-NUAMY (2004), utilizou parâmetros extraídos de imagens geradas pela técnica de ToFD para desenvolver um sistema de inteligência artificial que permita classificar automaticamente defeitos em soldas de dutos. Utilizando análise estatística e lógica *fuzzy*, os defeitos são classificados em quatro classes: falha planar, falha volumétrica, falha pontual e falha *thread-like*. Nos poucos resultados apresentados, a técnica obteve boa acurácia na classificação automática dos defeitos, indicando o funcionamento satisfatório do sistema.

### 3.1.3 Monitoramento de Emissões Químicas

O monitoramento de emissões químicas ao longo do duto de transporte de gás, petróleo e derivados, pode ser realizado por amostragem de gás na vizinhança do duto ou monitoramento do solo.

SPERL (1991) descreve um sistema de detecção direta de vazamentos, que ao contrário dos demais, detecta o gás ou líquido que está vazando e não a perda de pressão ou volume causados pela perda de produto. Um tubo sensor, com alta permeabilidade para gases e vapores líquidos e impermeável para a água, é instalado em paralelo ao longo do duto. E se existir vapor externo ao tubo, este entrará no tubo por difusão gerada pela diferença de gradiente de concentração. O autor afirma que, o sistema é capaz de monitorar o duto vinte e quatro horas por dia e é extremamente preciso. De acordo LIU *et al.* (2005), as desvantagens desta técnica são que o tempo de resposta a detecção do vazamento é muito longo e o custo de monitorar um duto longo é muito alto.

LOWRY *et al.* (2000) patenteou um método de monitoramento de dutos enterrados. Sua invenção envolve monitoramento do solo e injeção de um gás com um marcador químico no duto a ser monitorado. Este gás, não nocivo e altamente volátil, irá sair do duto na ocasião de um vazamento e ao longo da superfície acima do duto são instalados sensores responsáveis pela detecção do gás. A desvantagem do método é que o mesmo não funciona para dutos expostos a atmosfera.

### **3.1.4 Fluxo Magnético**

O monitoramento de dutos por fluxo magnético é um método aplicado periodicamente para inspeção utilizando um equipamento chamado de PIG (*Pipeline Inspection Gauge*).

Os PIGs são inseridos no duto e se deslocam ao longo de sua extensão impulsionados pela pressão do bombeio do fluido, seja ele gás ou óleo (MIRANDA, 2003). Quando lançado, o PIG emite um fluxo magnético no duto e anomalias como, pontos de corrosão e falhas mecânicas, são detectadas e armazenadas, ao alcançar o fim do seu percurso, as informações são recolhidas e processadas (MANDAL, 2014).

Este método pode localizar falhas com precisão de 0,1% do local real, e detectar pontos de 5 a 10% da espessura da parede do duto (Liu *et al.*, 2005). As vantagens deste sistema é que ele pode inspecionar um longo duto de uma só vez e não requer nenhum tipo de escavação. As desvantagens são que o duto tem que ser retirado de operação e requer estações de lançamento e recuperação do PIG (MANDAL, 2014).

### **3.1.5 Supervisório de Controle de Aquisição de Dados (SCADA)**

O SCADA é um sistema de computadorizado responsável por monitorar, processar e transmitir dados, como vazão, pressão, temperatura e outros, para o responsável pela operação do duto de transporte. A partir dos dados coletados modelos

matemáticos podem ser criados para indicar a presença e a localização de defeitos nos dutos.

O balanço de massa ou volume é uma técnica baseada no princípio de conservação da massa. O volume ou a massa podem ser computados usando as leituras de algumas variáveis do processo, como: vazão, pressão e temperatura (LIU, 2008). Para detectar pequenos vazamentos, este método necessita de um longo tempo de monitoramento, outra desvantagem deste método é que ele não é capaz de localizar o vazamento e é suscetível a falsos alarmes (MANDAL, 2014).

COLOMBO *et al.*, (2009) descreve a potencialidade dos métodos de detecção de vazamentos utilizando transientes de onda de pressão. Ele afirma que qualquer mudança na estrutura física no duto, como junção, expansão, bloqueio ou vazamento, gera uma onda que reflete na chegada de um sinal transiente, alterando a resposta do sistema de vazão e pressão.

Pressão negativa é um método popular de detecção e localização de vazamentos em dutos de óleo e gás. O aparecimento repentino de um vazamento leva ao súbito caimento da pressão, no local do da falha, o que gera uma onda de pressão negativa que se propaga na velocidade do som em ambas as direções do duto (MANDAL, 2014). JOODE e HOFFMAN (2011) desenvolveu um sistema de detecção da pressão negativa gerada no aparecimento de um vazamento ou pela instabilidade de pressão gerada no local do vazamento. O autor afirma que seu sistema mostrou sensibilidade melhor do que 1% do fluxo nominal em todos os testes e que é capaz de detectar vazamentos tão pequenos que são medidos em litros.

Métodos estatísticos são uma forma simples de detectar vazamentos em dutos de óleo e gás sem a necessidade do desenvolvimento de um modelo matemático. A análise estatística é conduzida por parâmetros já monitorados pelo sistema, como a pressão e vazão em múltiplos locais ao longo do duto (MANDAL, 2014).

ROUGIER (2005) descreve uma abordagem probabilística usando balanço de massa para identificar, localizar e medir o tamanho de vazamentos. Os vazamentos são classificados em três tipos: tipo 0, sem vazamento; tipo 1, vazamento comum; e tipo 2, vazamento causado por sabotagem. Um dos problemas que surgem da abordagem estatística para localização e medição do vazamento está em como apresentar os dados. De acordo com o autor, a melhor forma de apresentação é graficamente, a figura 12 apresenta um exemplo de representação da classificação dos vazamentos e da localização para três cenários diferentes.

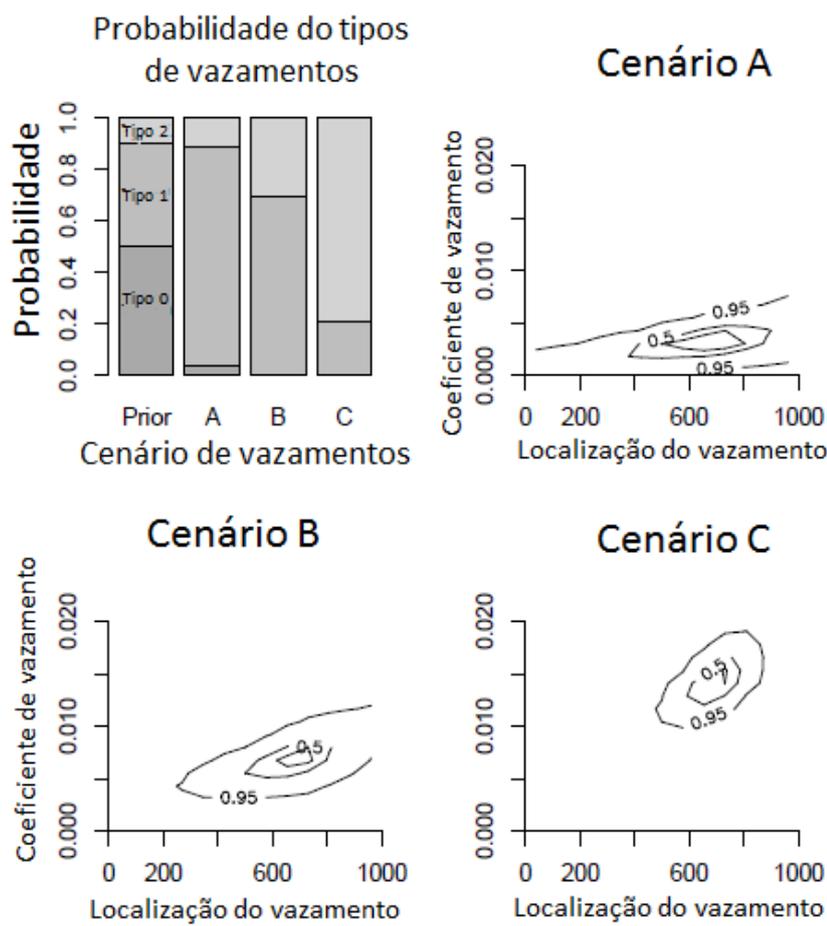


Figura 12 – Classificação e detecção de vazamento. O gráfico superior esquerdo mostra as probabilidades a prior e preditiva nos três tipos de vazamentos (0: sem vazamento; 1: vazamento comum; 2: vazamento por sabotagem). Os três cenários correspondem a três diferentes conjuntos de dados medidos. Os gráficos restantes mostram regiões de alta densidade para a distribuição da localização do vazamento para cada um dos três cenários diferentes (ROUGIER, 2005).

### 3.1.6 Métodos com EA

Os sistemas baseados em EA permitem a detecção e localização de defeitos em dutos através da própria onda sonora gerada pela descontinuidade.

SOARES (2008a), propõe uma metodologia que relaciona a EA com as dimensões das descontinuidades e consequente determinação da criticidade da mesma. Para atingir

tal objetivo o autor utilizou corpos de prova confeccionados a partir de segmentos de dutos e nestes foram inseridas descontinuidades com o objetivo de simular um defeito. Os corpos de prova foram submetidos a ensaios hidrostáticos para a captação de EA, a propagação e as dimensões da trinca foram determinadas utilizando o método de ToFD. Os sinais de EA e os sinais de ultrassom foram relacionados utilizando o parâmetro de mecânica da fratura  $K_I$  (fator de intensidade de tensão). Como resultado o autor obteve índices de correlação de 0,9 entre os valores de  $K_I$  estimados com os sinais de EA e os valores encontrados com os sinais de ultrassom. Em função dos resultados, determinou que é possível definir a criticidade de uma trinca em um duto rígido utilizando EA.

DA SILVA et al. (2006) apresenta um estudo pioneiro, até a data de sua publicação, em que utiliza parâmetros de EA geradas a partir de uma trinca inserida em um duto pressurizado, para treinar redes neurais artificiais capazes de determinar a propagação do defeito inserido no duto. Para isto, utilizou corpos de prova confeccionados de seções de duto e os mesmos foram submetidos a ensaios hidrostáticos para a aquisição dos parâmetros de EA (SOARES, 2008a, 2008b). O autor definiu duas classes para a propagação da trinca, Sem Propagação (SP) e Propagação (P). Em seu trabalho, o desempenho do classificador treinado alcança 92% de acertos na classificação dos sinais. Concluindo que é possível realizar a classificação de uma trinca nas duas classes propostas.

## 3.2 Reconhecimento de Padrões aplicados à EA

Uma das principais linhas de pesquisa e desenvolvimento hoje na área de END é a utilização de ferramentas de reconhecimento de padrões para semi-automatização ou automatização de processos de detecção e classificação de defeitos em equipamentos.

YUKI *et al.* (1996) demonstra que as redes neurais artificiais podem ser treinadas utilizando formas de ondas de EA simuladas por sensor piezoeletrico de cerâmica, e que a rede treinada pode ser utilizada para classificar formas de onda de EA reais geradas a partir do teste de tensão de em corpos de provas de grafite com entalhe *Chevron*.

KRAL *et al.* (2013) propõe um sistema de monitoramento em tempo real da estrutura de aeronaves utilizando EA e redes neurais artificiais. Em seu trabalho, ele propõe classificar a magnitude e localizar as diferentes fontes de emissão acústica na estrutura. Seus resultados demonstraram que é possível estimar o tamanho e classificar o crescimento de uma fratura em plástico ou elástico, contudo a localização da deformação ainda é incerta e não pode ser determinada.

GODIN *et al.*, (2004) propõe que EA pode ser utilizada para discriminar diferentes tipos de defeitos encontrados em corpos de prova de resina pura e fibra de vidro/poliéster unidirecional submetidos ao teste de tensão. Utilizando técnicas de reconhecimento de padrões não supervisionado e supervisionado, as diferentes fontes de emissão acústicas são separadas em diversas classes que refletem a estrutura interna dos corpos de prova.

GODIN *et al.* (2005) afirma que a EA é uma técnica muito útil para a determinação de defeito local em materiais. Ele combina duas técnicas de análise de agrupamentos, Mapas auto-organizacionais (SOM) e *k-means*, e determina que os sinais de EA gerados em testes de tensão em corpos de prova de compostos de vidro/epóxi podem ser separados em três agrupamentos distintos.

EMAMIAN *et al.* (2003) conta que um dos grandes problemas do monitoramento em tempo real de estruturas utilizando EA é separar os eventos acústicos de ruídos proveniente de vibração, interferências magnéticas entre outros. Um sistema de monitoramento automático deve ser capaz de separar o ruído da EA emitida pela propagação de uma falha. O autor propõe um procedimento em dois passos capaz de realizar tal separação, primeiro os ruídos são separados dos eventos de interesse usando uma combinação de análise de covariância e análise de componentes principais. Na segunda etapa é aplicado correlação cruzada associada a mapas auto organizacionais separando os dados restantes em dois grupos, o de ruído e o de eventos de EA.

### **3.3 Conclusões**

A presente revisão bibliográfica apresentou as diferentes metodologias de monitoramento e inspeção de dutos apontando as vantagens e as desvantagens de cada uma delas. Um ponto comum a praticamente todas as metodologias apresentadas é que por mais eficientes que sejam, atualmente são empregadas para a detecção de vazamentos, isto é, são medidas empregadas na identificação do incidente após este ter ocorrido. Quando a metodologia é capaz de identificar falhas antes de ocorrer o vazamento, é necessário que o duto seja retirado de operação para que a inspeção seja realizada.

Quando comparada com as metodologias apresentadas, a metodologia proposta nesta tese será um grande avanço para o setor de petróleo e gás, a mesma será capaz de prever, em tempo real, quando um defeito estará se propagando num duto pressurizado em ensaio hidrostático, sendo possível a interrupção desta propagação instável, que levaria à falha catastrófica do equipamento.

## 4 Metodologia

Neste capítulo descrevem-se as metodologias empregadas na tese, dividindo-se as seções em:

- Classificador Neural;
- Curva PoP;
- Análise de Agrupamentos.

### 4.1 Classificador Neural

A discriminação entre as classes foi feita por classificadores de padrões não lineares usando redes neurais artificiais *feedforward* treinadas pelo algoritmo de retropropagação de erro, *backpropagation* (HAYKIN, 1999). Foram utilizadas redes com duas camadas de neurônios: uma camada intermediária e uma de saída.

Por se tratar de uma rede de classificação de padrões, o número de neurônios da camada de saída corresponde ao número de classes definidas, com um neurônio de saída por classes definida.

Com a finalidade de se encontrar a melhor configuração de rede para o treinamento e teste (generalização), treinaram-se diversas redes sempre com o mesmo conjunto de treino e teste sorteado aleatoriamente na proporção 80%/20%, utilizando três neurônios na camada de saída (três classes de sinais), tangente hiperbólica como função de ativação e treinamento em batelada. Variou-se o número de neurônios na camada intermediária de 1 até 10, testando vários tipos de parâmetros de treinamento: taxa de

aprendizagem ( $\alpha$ ) fixo e sem momento;  $\alpha$  fixo e com momento;  $\alpha$  variável e sem momento; e  $\alpha$  variável e com momento.

Os testes foram realizados com taxa de aprendizagem de 0,1 e momento de 0,9, e depois com 0,5 e 0,9, respectivamente. A quantidade “ótima” de neurônios foi determinada pela análise de tabelas de índice de acerto nos conjuntos de treinamento e teste em função da variação do número de neurônios na camada intermediária. No Capítulo 5, são apresentadas estas tabelas e são definidos o número de neurônios da camada intermediária e os parâmetros da rede “ótima”.

Nesta tese, foram utilizados dois tipos de classificação, **Sem Reclassificação** – admitindo como classificação certa apenas quando o neurônio da classe é o único positivo, e **Com Reclassificação** – admitindo como classificação certa se a saída do neurônio for a maior entre as saídas das classes.

## 4.1.1 Acurácia dos Classificadores

O desempenho de um classificador pode ser medido pela acurácia, a qual expressa o grau de sucesso de classificar corretamente uma amostra. De acordo com DIAMANTIDIS (2000), três métodos têm sido aplicados para estimar a acurácia de um classificador:

1. Avaliação com amostragem aleatória.
2. Validação-cruzada
3. *Bootstrap*

Todas as técnicas baseiam-se em amostragem aleatória, diferindo apenas na implementação da estimação da acurácia do classificador.

No método de avaliação com amostragem aleatória, o conjunto original de dados (com  $n$  amostras) é dividido aleatoriamente em dois conjuntos: um conjunto de treino contendo  $p \times n$  amostras, e outro de teste com  $(1-p) \times n$  amostras. Este processo é repetido uma quantidade específica de vezes e calculado o valor médio dos resultados.

Neste trabalho, a acurácia dos classificadores foi calculada pela avaliação com amostragem aleatória, devido à grande quantidade de entradas disponíveis não se justifica o uso dos outros métodos, usualmente empregados para espaços amostrais deficientes (HAYKIN, 1999). Para cada classificador, foram sorteados aleatoriamente 10 conjuntos de treino e teste, cada um se dividindo em uma proporção de aproximadamente 80% para treino e 20% para teste.

## **4.1.2 Definição das Classes**

As classes são definidas em função do estágio de evolução da trinca identificado a partir da curva de pressão de ensaio hidrostático e da curva de crescimento da trinca, os sinais foram separados em duas e em três classes. As curvas de cada ensaio são apresentadas no Capítulo 5.

Para duas classes definiu-se:

1. Sem Propagação (SP) – Enquanto a profundidade da trinca se mantém constante.
2. Propagação (P) – A partir do primeiro sinal de crescimento da trinca até o rompimento do corpo de prova.

E para três classes:

1. Sem Propagação (SP) – Enquanto a profundidade da trinca se mantém constante.
2. Propagação Estável ou Elástica (PE) – Crescimento lento da trinca por um longo intervalo de tempo. O crescimento da deformação é interrompido quando a pressão se mantém constante.
3. Propagação Instável ou Plástica (PI) – Crescimento acentuado da trinca por um curto intervalo de tempo até o rompimento. O crescimento da deformação continua mesmo em pressão constante ou decrescente.

Após a determinação dos intervalos de cada classe os sinais foram sincronizados com o tempo de pressurização e do crescimento da trinca.

A figura 13 apresenta um exemplo de um gráfico contendo as curvas de pressão do ensaio hidrostático e crescimento da trinca.

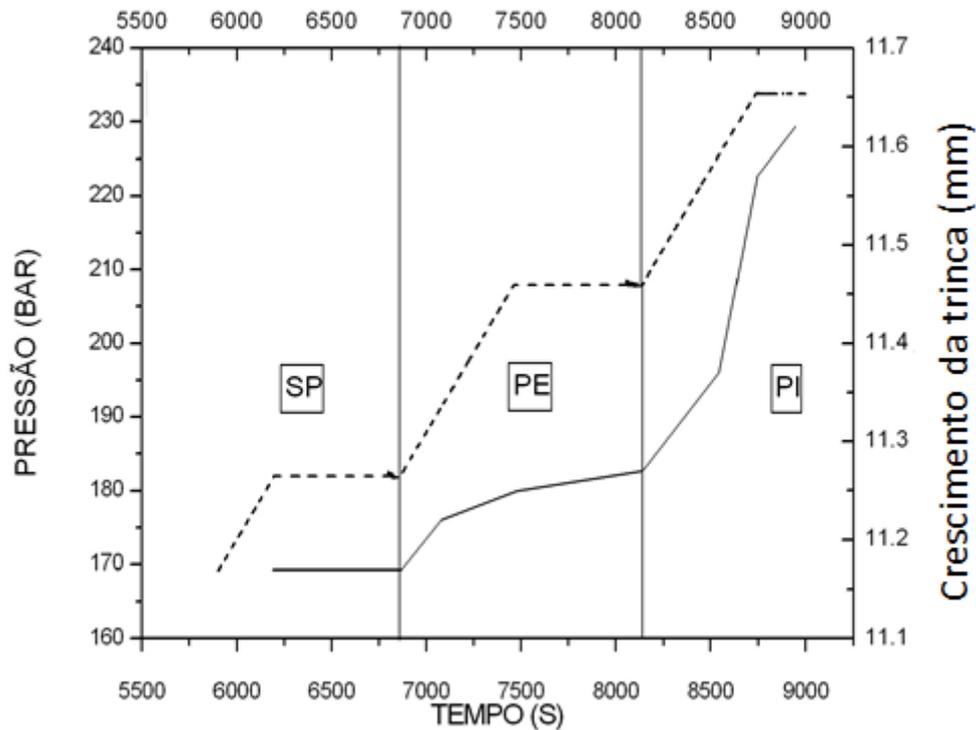


Figura 13 – Curva de pressão vs. tempo - linha tracejada. Curva de propagação da trinca vs tempo - linha contínua.

### 4.1.3 Aquisição dos dados de entrada do Classificador

Os sinais de EA utilizados neste trabalho se referem à realização de três ensaios de um projeto intitulado “Inspeção de Dutos Rígidos” entre a Petrobras/Cenpes e a UFRGS/Laboratório de Metalurgia Física, onde descontinuidades são inseridas no duto e monitoradas e medidas por sistema de inspeção ultrassônica com a técnica *time of flight diffraction* (ToFD). A técnica ToFD está baseada na difração do feixe ultrassônico

causada pelas extremidades superiores e inferiores de um da descontinuidade inserida no duto (SOARES, 2008a).

No primeiro ensaio (denominado Ensaio 1) foram adquiridos os seguintes parâmetros de emissão acústica: *Rise* (Tempo de subida), *Count* (Contagem), *Energy* (Energia), *Duration* (Duração), AMP (Amplitude), A-Freq, RMS, ASL, PCNTS, R-Freq, I-Freq, SIG-Strength e ABS-Energy. No segundo e terceiro ensaios, denominados Ensaio 2 e Ensaio 3 respectivamente, além dos parâmetros do Ensaio 1, também foram coletados: Freq-PP1, Freq-PP2, Freq-PP3, Freq-PP4, C-Freq e P-Freq.

## 4.1.4 Critério de Relevância

Nesta tese, utilizou-se este método para avaliar a importância dos atributos de entrada acrescentados no Ensaio 2 e Ensaio 3 em relação ao Ensaio 1.

Este critério mede a relevância de cada atributo de entrada do classificador, isto é, mede quanto este influencia na performance da rede neural. O método consiste em procurar mudanças significativas na resposta da rede, ao substituir os valores da variável avaliada pelo valor médio (SEIXAS, 1996).

A relevância  $R(X_i)$  da componente  $X_i$  do vetor  $X$  pode ser calculada pela equação 5:

$$R(X_i) = \frac{\sum_{j=1}^P \|y(x_j) - y(x_{ji})\|^2}{P} \quad (5)$$

$R(X_i)$ : relevância da componente  $x_i$  dos vetores de entrada  $x$  ;

$P$  : número de padrões (treinamento ou teste);

$y(x_j)$ : vetor de saída da rede neural para cada padrão  $x_j$  de entrada apresentado;

$x_{ji}$  : vetor de entrada  $x_j$  , em que a  $i$ -ésima componente foi substituída pelo seu valor médio tomado sobre todos os vetores de entrada;

$y(x_{ji})$  : vetor de saída da rede para a entrada  $x_{ji}$  .

## 4.2 Curva de Possibilidade de Propagação (PoP)

Nesta seção, é proposta a metodologia de construção da curva PoP, a qual cada instante de tempo determina três valores de possibilidade da EA a ser classificada como uma das classes definidas na seção 4.1.2.

Nestas curvas, a possibilidade é definida como um índice com valores entre 0 e 1. Quando a possibilidade é igual a 1, significa certeza do sinal pertencer a determinada classe e quando a possibilidade é igual a 0, significa certeza do sinal não pertencer a classe.

Para explicar a metodologia, pode-se analisar a figura 14, imagina-se que um ensaio de EA para monitoramento da propagação de uma trinca em um equipamento pressurizado teve duração de 150s, e que de 0 a 50 segundos os sinais são definidos como SP, de 50 a 100 segundos como PE e de 100 a 150s como PI. Observando o gráfico da

figura 9, de 0 até 50 segundos a possibilidade do sinal ser SP é igual a um e as demais igual a zero, entre 50 e 100 a possibilidade de PE é igual a 1 e as demais igual a zero, a partir de 100 segundos até o final do ensaio a possibilidade de PI é igual a 1 e as demais igual a zero. Destaca-se, contudo, que isso aconteceria para uma situação ideal de classificação dos sinais, isto é, com acerto de 100% para os sinais de cada classe nas regiões de definição.

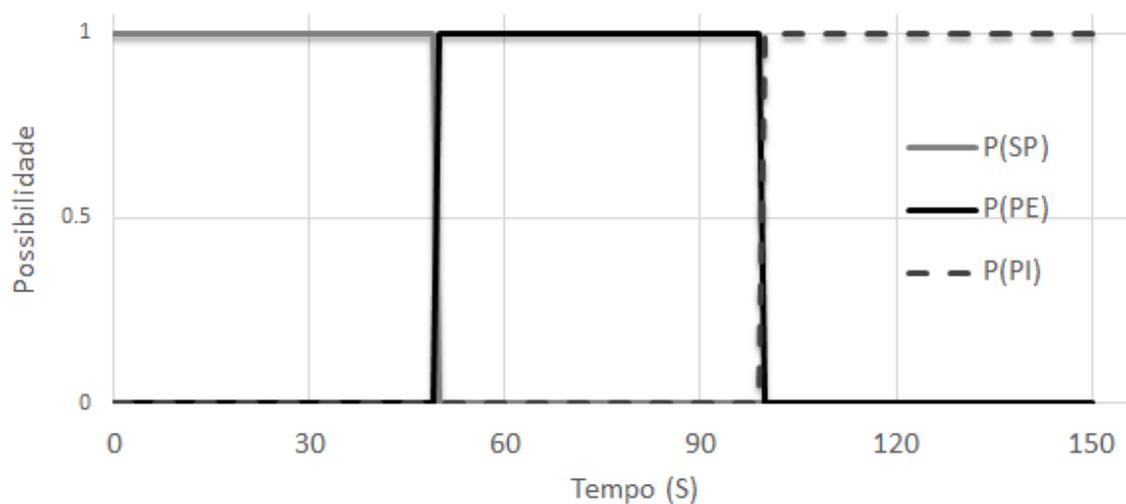


Figura 14- Curva PoP teórica - A linha contínua cinza representa a possibilidade de SP, a linha preta contínua a possibilidade de PE e a linha de tracejada a possibilidade PI.

Foi escolhido o tempo de ensaio como referência, porque, uma vez que exista a trinca e o sinal de EA seja emitido, a tendência é que a propagação ocorra até que haja o rompimento do duto, a menos que a pressão seja aliviada até a classe PE (ANM, 2014, SOARES, 2008a). Isto é, em um tempo  $t_{n+1}$ , o tamanho da trinca será maior ou igual ao tamanho em  $t_n$ , nunca será menor.

Esta nova abordagem pode ser caracterizada como um problema de reconhecimento de padrões estatístico, onde o desafio está em estimar funções de densidade no espaço de n-dimensões e dividir o espaço em classes (FUKUNAGA,1990).

Neste novo contexto, dentre os diversos classificadores, os de Bayes são considerados os melhores, pois minimizam a probabilidade de erros na classificação. Na primeira etapa da classificação, é estimada a função densidade de probabilidade não paramétrica, devido à distribuição dos dados ser completamente desconhecida (FUKUNAGA, 1990). Na segunda e última etapa, é realizada a classificação utilizando o teorema de Bayes (HASTIE, 2008).

De acordo com a rede neural usada para treinar o classificador, as classes foram determinadas a partir do valor do vetor de saída Y. A tabela 2 apresenta os valores das saídas definidos para cada classe, em notação maximamente esparsa.

Tabela 2- Definições da rede neural.

Classe	Vetor de saída Y
SP	$[1 \ -1 \ -1]^T$
PE	$[-1 \ 1 \ -1]^T$
PI	$[-1 \ -1 \ 1]^T$

De acordo com SPECHT (1990), a similaridade entre as redes neurais *feed-forward* e classificadores de padrão não paramétricos é notável. O autor afirma que esta semelhança pode ser observada nas redes neurais probabilísticas, onde a função de ativação tangente hiperbólica é substituída por uma função exponencial, a mesma utilizada no Kernel Gaussiano. Apesar de não estarmos desenvolvendo um Rede Neural

Probabilística, se conclui que, para a estimação da distribuição de probabilidade, é necessário que seja retirada a função de ativação de cada neurônio da camada de saída, de acordo com a equação 6.

$$U_n = \tanh^{-1}(Y_n) \quad (6)$$

tal que  $n$  é o neurônio e  $Y$  a saída do neurônio.

Após eliminar a função de ativação, o próximo passo é estimar as densidades de probabilidade. As funções de probabilidade não paramétricas são extremamente difíceis de serem estimadas com precisão, quando comparadas com as paramétricas (FUKUNAGA, 1990, HASTIE, 2008). Contudo, o objetivo não é a precisão da função estimada, e sim usar as curvas para modelar o classificador.

Dentre os diversos métodos de estimação não paramétrica, destaca-se o de Parzen que ao ser ajustado com uma função Kernel gaussiano  $K(\cdot)$ , tal que  $\int K(X)dX = 1$  (FUKUNAGA, 1990, HASTIE, 2008), pode ser interpretado como uma soma ponderada do valor da função  $K(\cdot)$  em cada valor de  $X$ , como exemplificado na figura 15.

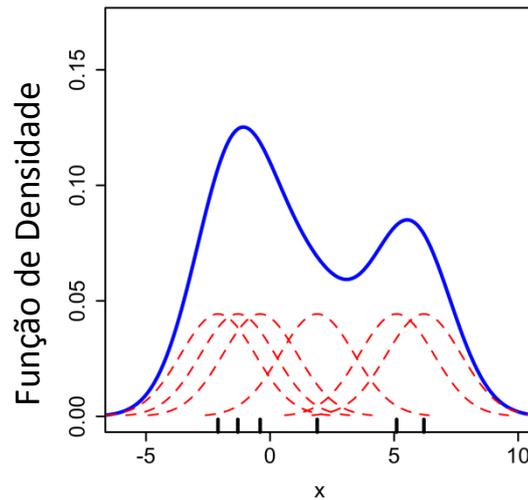


Figura 15 - A curva com a linha contínua é a densidade estimada e as linhas tracejadas são as funções do Kernel para cada ponto indicado (DRLEFT, 2010).

Após estimar as funções densidades de probabilidade, pode-se realizar a classificação, usando o teorema de Bayes, o qual determinará a probabilidade a posteriori segundo a equação 7 (HASTIE, 2008). Isto é, dada uma entrada X a probabilidade de esta pertencer à classe é calculada.

$$\widehat{Pr}(G = j|X = x_0) = \frac{\hat{\pi}_j \hat{f}_j(x_0)}{\sum_{k=1}^J \hat{\pi}_k \hat{f}_k(x_0)} \quad (7)$$

$\hat{f}(X)$  – função não paramétrica de densidade estimada.

$\hat{\pi}$  - probabilidade a priori da classe.

$J$  – quantidade de classes.

Ajustando a equação 7 para o cálculo de cada classe, SP, PE e PI se têm a equação 8.

$$\widehat{Pr}(G = Classe|X = x_0) = \frac{\hat{\pi}_{Classe}\hat{f}_{Classe}(x_0)}{\hat{\pi}_{Classe}\hat{f}_{Classe}(x_0) + \hat{\pi}_{n\tilde{a}oClasse}\hat{f}_{n\tilde{a}oClasse}(x_0)} \quad (8)$$

Com o objetivo de evitar qualquer influência no resultado final gerada por um possível desbalanceamento entre os conjuntos classe e não classe, a probabilidade a priori dada uma entrada  $x$  qualquer será  $\hat{\pi}_{Classe} = 0,5$  e  $\hat{\pi}_{n\tilde{a}oClasse} = 0,5$ ; Desta forma a probabilidade a posteriori será apenas resultado das funções densidades de probabilidade estimadas.

De acordo com a equação 8, a probabilidade a posteriori depende das densidades estimadas com os elementos da classe e da não classe. Então se faz necessário a definição de uma nova variável,  $Z$ , descrita na equação 9.

$$Z = U_l - \max(U_m, U_n) \quad (9)$$

tal que  $l, m, n$  são os neurônios de saída da camada se e somente se  $l \neq m \neq n$ .

Utilizando o classificador neural desenvolvido na seção 4.1, para os elementos pertencentes à classe, os valores de  $Z$  serão maiores que zero (verdadeiros positivos), quando classificados corretamente, e menores que zero quando classificados errados (falsos negativos). Para os elementos que não pertencem à classe, os valores de  $Z$  serão menores que zero quando classificados corretamente (verdadeiros negativos) e maiores que zero quando classificados como a classe (falsos positivos). A tabela 3 apresenta a equação utilizada em cada classe, uma abordagem semelhante é apresentada em DA SILVA (2003).

Tabela 3 – Equações de Z para as respectivas classes.

Classe	Conjunto de elementos da classe	Soma de dois conjuntos que não pertencem a classe
SP	$Z_{SP} = U_1 - \max(U_2, U_3)$	$Z_{\text{não}SP} = U_1 - \max(U_2, U_3)$
PE	$Z_{PE} = U_2 - \max(U_1, U_3)$	$Z_{\text{não}PE} = U_2 - \max(U_1, U_3)$
PI	$Z_{PI} = U_3 - \max(U_2, U_1)$	$Z_{\text{não}PI} = U_3 - \max(U_2, U_1)$

De acordo com HASTIE (2008), quando duas curvas de densidade de probabilidade seguem a forma apresentada na figura 16, geradas a partir de dados hipotéticos, o gráfico da probabilidade posteriori calculada com a equação 8 terá a forma suave apresentada na figura 17.

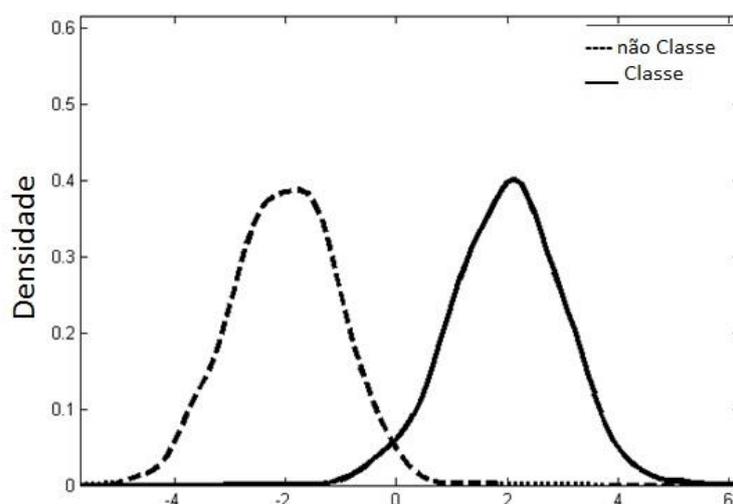


Figura 16 – Cura de Densidade de probabilidade teórica - A linha contínua representa a densidade de probabilidade da “classe” e a linha tracejada a densidade da “não classe”. Dados hipotéticos.

Com as probabilidades a posteriori encontradas, é realizada a regressão utilizando tangente hiperbólicas. E a partir deste ponto, a probabilidade da classe pode ser escrita em função do tempo e de Z, de acordo com a equação 10.

$$P_{\text{Class}}(t) = a \times \tanh(b \times Z_n(t) - c) + d \quad (10)$$

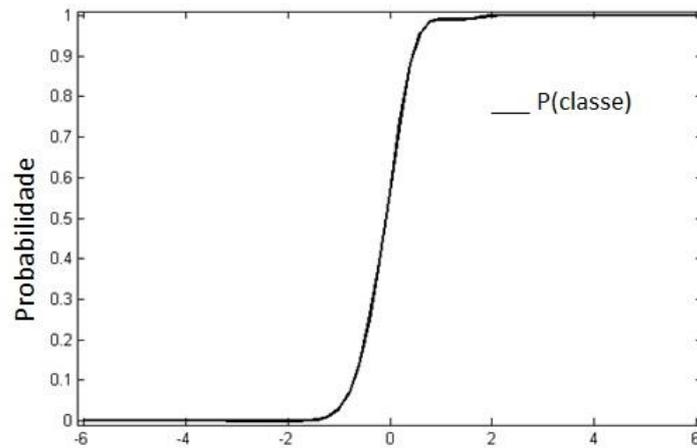


Figura 17 - Curva de probabilidade posterior para a classe, gerada a partir da densidade de probabilidade.

A figura 18 apresenta um gráfico da probabilidade calculada a partir da equação 10. Neste exemplo, cada ponto representa a probabilidade do sinal de EA para a classe SP.

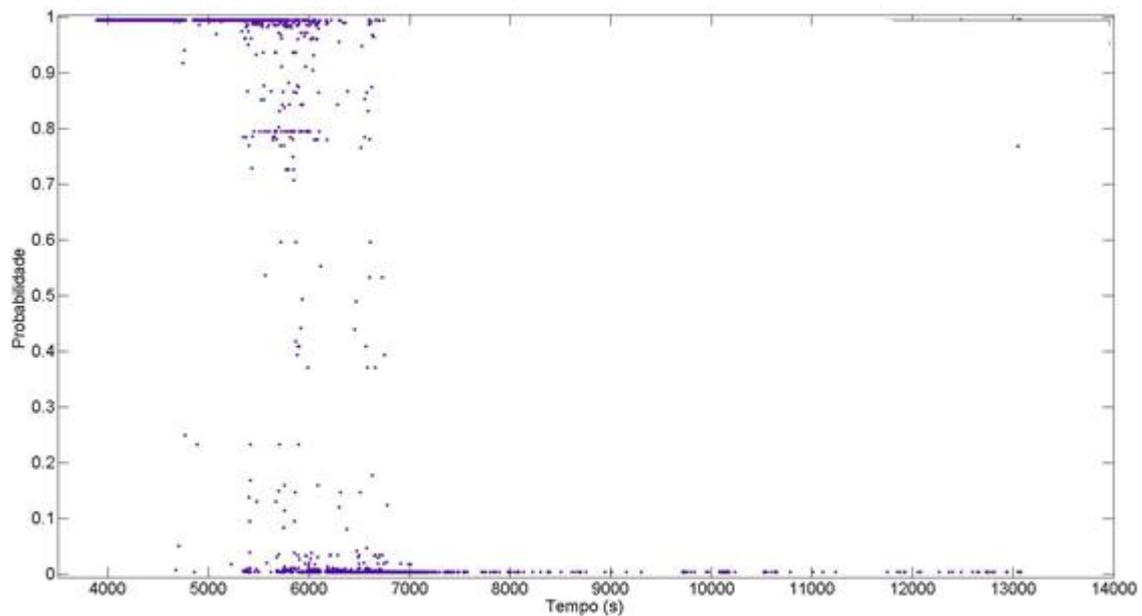


Figura 18 – Gráfico da probabilidade em relação ao tempo da classe SP

A curva de Possibilidade será gerada a partir da aproximação de cada ponto do gráfico para uma função tangente hiperbólica, conforme as equações 11, 12 e 13 da tabela 4, de acordo com o algoritmo minimização do erro médio quadrático, descrito a seguir.

Tabela 4 – Modelo de aproximação da Possibilidade de cada classe.

PoP	Modelo	
SP	$PoP_{SP}(t) = \frac{\tanh(-at + b) + 1}{2}$	(11)
PE	$PoP_{PE}(t) = \frac{\tanh(at + b) + 1}{2} - \frac{\tanh(-ct + d) + 1}{2}$	(12)
PI	$PoP_{PI}(t) = \frac{\tanh(-at + b) + 1}{2}$	(13)

#### **Início do Algoritmo Curva PoP**

- 1 – Inicialização dos coeficientes próximo de zero
- 2 – Gerar curva para os atuais coeficientes
- 3 – Aplicar o algoritmo *Trust-region* (NOCEDAL, 2006) para encontrar os coeficientes “ótimos” da curva
- 4 – Retornar ao passo 2 se não ocorreu a convergência

#### **Fim do Algoritmo**

A figura 19 apresenta exemplos da curva de aproximação encontrada para diferentes intervalos de tempo.

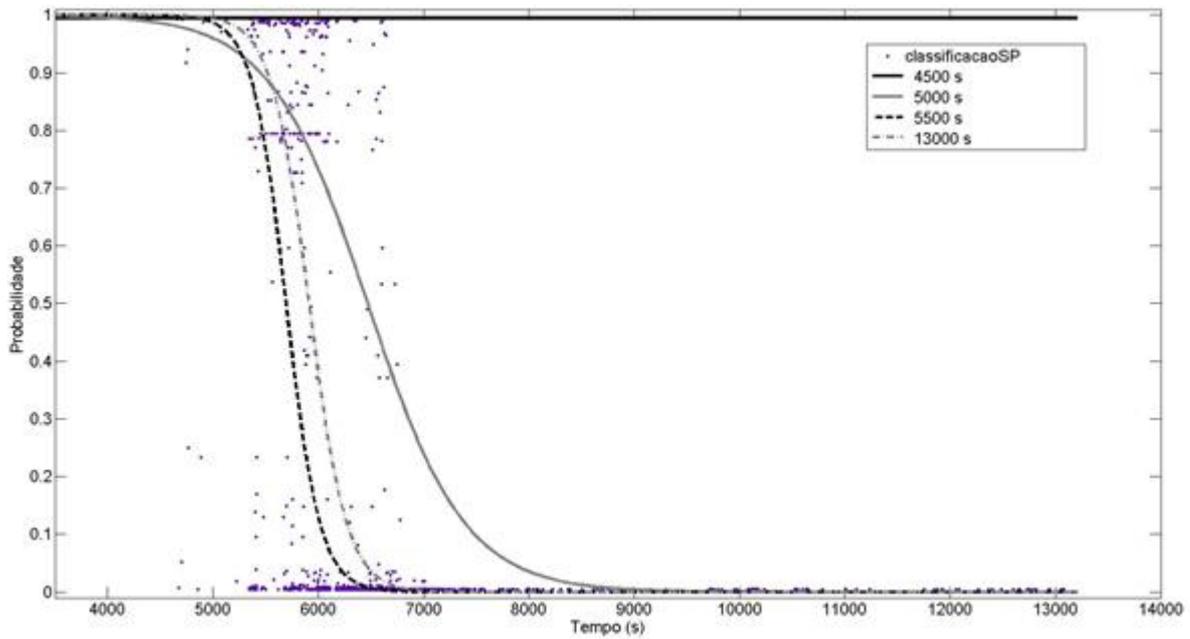


Figura 19 - Curvas de Possibilidade da classe SP. Linha preta contínua – Curva de Possibilidade para o tempo até 4500s. A linha cinza contínua - Curva de Possibilidade para o tempo até 5000s. Linha preta tracejada - Curva de Possibilidade para o tempo até 5500s. Linha cinza tracejada - Curva de Possibilidade para o tempo até 13000s

A curva PoP será formada com as curvas de possibilidades geradas para cada classe, de acordo com a figura 20.

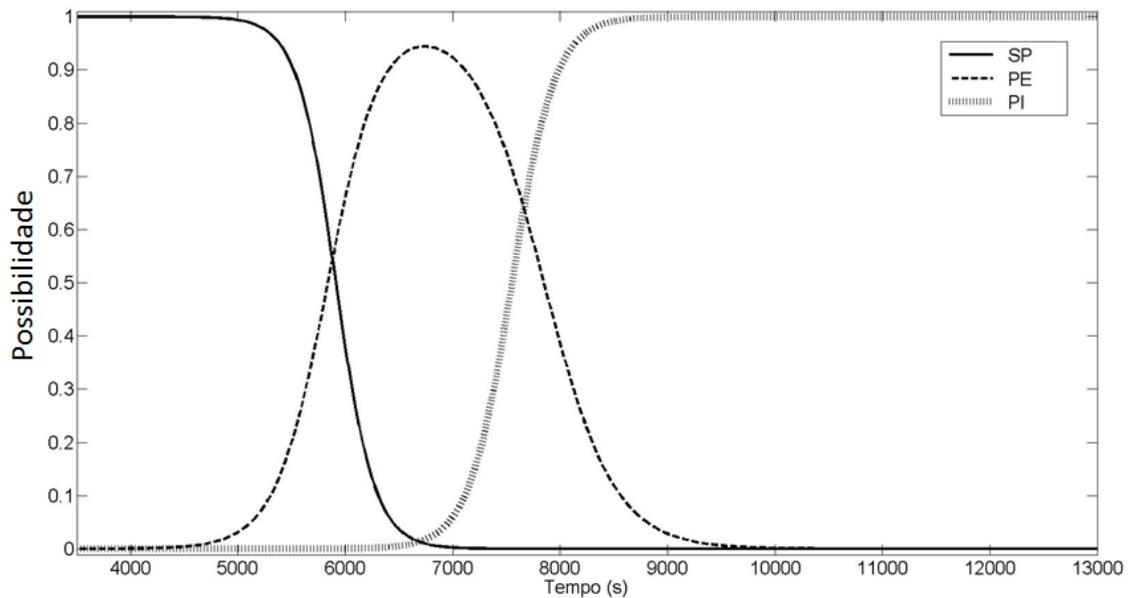


Figura 20 – Exemplo Curva PoP para todas as classes.

## 4.3 Análise de Agrupamentos

De acordo com HASTIE (2008), a análise de agrupamento está relacionada ao agrupamento ou separação de uma coleção de objetos em subconjuntos, agrupamentos, de forma que os elementos pertencentes a um mesmo grupo estejam mais relacionados entre si do que com os pertencentes a outro grupo.

RAJARAMAN (2011) afirma que a análise de agrupamento é o processo de examinar um conjunto de “pontos”, e agrupá-los em grupos de acordo com alguma medida de distância. O objetivo é que pontos em um mesmo grupo sejam próximos uns dos outros e pontos em diferentes grupos sejam distantes.

HAYKIN (1999) descreve o aprendizado não supervisionado como um procedimento sem um “professor ou crítico” externo observando o processo de aprendizagem de um classificador. Em DUDA *et al.* (2001), quando as amostras de treinamento de um classificador são previamente categorizadas, diz-se que este é um processo supervisionado. Quando as amostras não são previamente categorizadas a aprendizagem do classificador é chamada de não supervisionada.

DUDA *et al.* (2001) relaciona a análise de agrupamento ao treinamento de um classificador. De acordo com ele um conjunto grande de dados sem conhecimento prévio de classes pode ser agrupado em grupos, utilizando um método de aprendizado não supervisionado, e a partir dos grupos formados aplicar uma das técnicas de treinamento supervisionado para o classificador.

Nesta seção são realizadas as análises dos agrupamentos formados com os dados de EA do Ensaio 3 e a partir dos agrupamentos formados propõe-se determinar em que classe cada sinal de EA melhor se encaixa no conjunto de treinamento do classificador desenvolvido na seção 4.1. E desta forma estudar as regiões de transição entre as classes, avaliando se as classes definidas, previamente, na seção 4.1.2 estão corretas.

Esta análise, também, permitirá a observação do arranjo espacial dos dados de EA e os resultados servirão como base para o futuro desenvolvimento de uma metodologia de pré-processamento dos sinais de EA, automatizando a análise da curva de crescimento da trinca.

A análise é realizada em três passos, inicialmente é projetada uma rede do tipo SOM e visualizado se existem regiões de separação entre os dados, caso a afirmação seja positiva, é aplicado o algoritmo de *K-means* para a formação dos agrupamentos e com base no pré-conhecimento da classe a que o sinal de EA pertence, é gerada uma tabela de confusão de Classe vs. Agrupamento.

A partir da análise destas tabelas possíveis elementos que não pertencem à suposta classe são eliminados e um novo conjunto de dados é gerado sem a presença de tais elementos. Nesta etapa o algoritmo *K-means* é executado iterativamente em agrupamentos com elementos de classes diferentes até que o resultado não se altere.

No último passo, um novo classificador supervisionado é treinado e sua acurácia é comparada com os resultados obtidos dos dados originais.

## 5 Discussão e Resultados

Neste capítulo, serão apresentadas as discussões e as análises dos resultados obtidos para o estabelecimento das conclusões desta tese envolvendo reconhecimento de padrões e EA.

Na seção 5.1, são apresentados resultados obtidos pelo classificador neural, os resultados são apresentados por Ensaio, sendo desenvolvido um classificador por ensaio. Também é realizado, um estudo da relevância dos parâmetros de entrada da rede neural treinada e a influência na acurácia do classificador causada pelos novos parâmetros acrescentados aos Ensaio 2 e ao Ensaio 3.

Na seção 5.2, são apresentadas as análises dos resultados obtidos ao longo do desenvolvimento da curva PoP utilizando os dados do Ensaio 3. Ao final a metodologia de criação da curva é aplicada ao Ensaio 2 e realizada a comparação entre as duas curvas PoP geradas.

Na seção 5.3, são apresentados os resultados obtidos pela análise de agrupamento dos sinais de EA e realizada a comparação da acurácia do classificador treinado com todos os dados do Ensaio 3, com o classificador treinado com alguns dados selecionadas deste mesmo ensaio.

## **5.1 Classificador Neural**

### **5.1.1 Ensaio 1**

De acordo com o descrito na Seção 4.1.2, neste ensaio foram coletados os seguintes parâmetros: Tempo de subida, Contagem, Energia, Duração, AMP, A-Freq, RMS, ASL, PCNTS, R-Freq, I-Freq, SIG-Strength e Energia Absoluta. Vale destacar que durante o teste hidrostático não houve rompimento do duto, fato que influencia nas características dos sinais de EA emitidos.

#### **5.1.1.1 Definição dos parâmetros de treinamento**

De acordo com a figura 21, o conjunto de sinais foi separado em 3 classes: 2929 sinais da classe SP, 1517 sinais da classe PE 2986 da classe PI. Foi realizado o estudo para encontrar a rede “ótima”, conforme descrito no Capítulo 4.

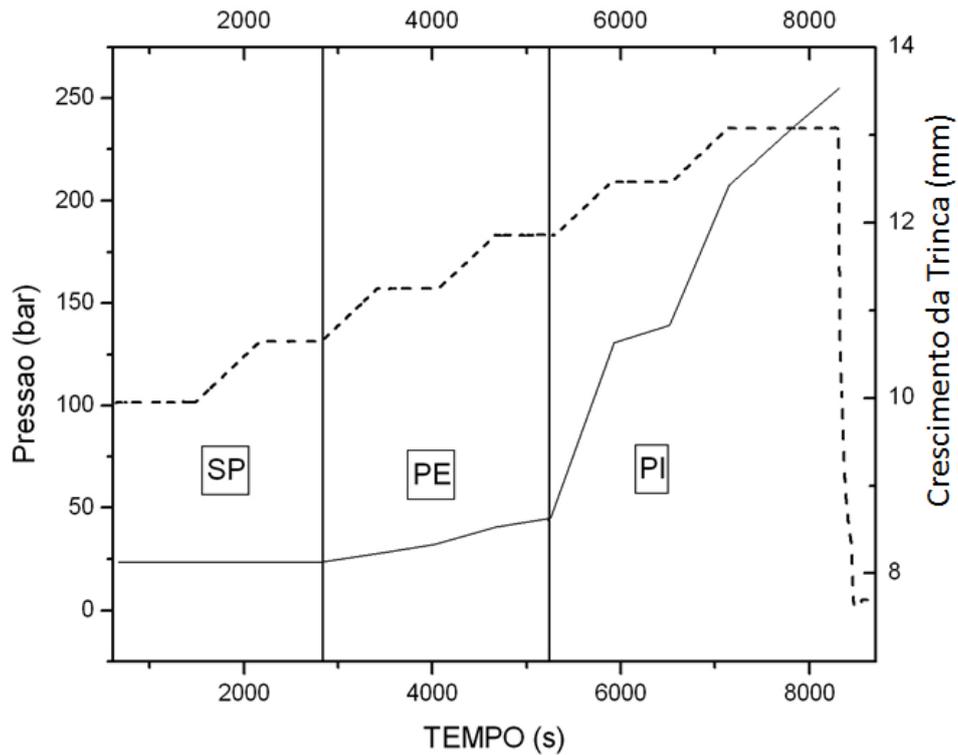


Figura 21 – Ensaio 1 - Curva de Pressão vs. Tempo de Ensaio – linha tracejada. Curva de Crescimento da trinca vs. Tempo de Ensaio – linha contínua.

A Tabela 5 mostra os índices de acerto em relação ao número de neurônios utilizados para treinamento. Contudo, foram observados resultados inesperados, no caso do treinamento sem momento e com taxa de aprendizado variável, a taxa de acerto com quatro neurônios foi maior que o dobro da taxa de acerto do treinamento com cinco neurônios, indicando incoerência no treinamento, provavelmente a captura por um mínimo local de difícil acesso, devido à taxa de aprendizagem alcançar valores muito elevados.

Tabela 5 – Ensaio 1 - Índice de acerto em função da variação do número de neurônios na camada intermediária da rede neural treinada.

Neurônios camada Intermediária	Sem momento		Com momento		Sem momento e alfa variável		Com momento e alfa variável	
	Treino	Teste	Treino	Teste	Treino	Teste	Treino	Teste
1	0,0	0,0	0,43727	0,47106	14,867	16,353	12,159	11,844
2	18,214	18,371	20,249	21,198	18,584	17,429	18,803	18,371
3	34,359	35,599	19,189	17,766	18,634	19,112	18,87	17,295
<b>4</b>	<b>30,979</b>	<b>31,629</b>	<b>27,666</b>	<b>27,12</b>	<b>56,475</b>	<b>56,662</b>	<b>29,835</b>	<b>31,561</b>
<b>5</b>	<b>25,597</b>	<b>26,11</b>	<b>23,041</b>	<b>22,611</b>	<b>19,324</b>	<b>18,506</b>	<b>38,11</b>	<b>37,416</b>
6	36,983	37,887	36,916	39,3	56,576	57,537	37,084	37,954
7	34,174	35,061	35,94	34,522	55,97	57,201	23,562	22,342
8	34,494	34,791	34,157	33,782	55,954	55,249	36,495	37,281
9	35,621	36,07	35,738	35,397	54,205	53,163	39,775	37,887
10	35,318	35,33	37,723	37,079	52,321	52,153	40,531	38,223

Buscando evitar a captura por um mínimo local durante o treinamento, limitou-se a taxa de aprendizado em no máximo 0,2. A partir daí os resultados apresentados foram como o esperado. Como pode ser observado na Tabela 6, a taxa de acerto aumenta de acordo com o aumento do número de neurônios.

Tabela 6 – Ensaio 1 - Índices de acerto em função da variação do número de neurônios na camada intermediária da rede, com taxa de aprendizado ( $\alpha$ ) máximo igual a 0,2.

Neurônios camada Intermediária	Sem momento		Com momento		Sem momento e alfa variável		Com momento e alfa variável	
	Treino	Teste	Treino	Teste	Treino	Teste	Treino	Teste
1	15,76	16,22	39,37	39,57	14,56	13,73	8,61	7,40
2	18,95	17,63	30,05	29,21	34,93	35,26	0,12	0,13
3	19,88	19,65	33,10	30,69	18,28	18,10	18,38	18,84
4	22,00	21,60	19,21	18,04	18,90	18,30	29,20	28,20
<b>5</b>	<b>32,27</b>	<b>32,97</b>	<b>40,33</b>	<b>39,57</b>	<b>35,47</b>	<b>36,07</b>	<b>35,54</b>	<b>36,31</b>
<b>6</b>	<b>28,37</b>	<b>26,99</b>	<b>33,47</b>	<b>34,66</b>	<b>39,64</b>	<b>37,28</b>	<b>35,52</b>	<b>36,95</b>
7	36,76	36,34	34,86	34,19	31,25	32,50	37,45	38,49
8	31,65	31,70	31,42	31,56	36,51	35,80	37,66	37,08
9	36,51	37,15	37,49	35,46	35,65	37,42	33,54	36,00
10	35,82	35,06	36,26	36,27	39,17	37,08	36,68	34,93

Foi definida como rede "ótima" uma rede com 6 neurônios, treinada sem momento,  $\alpha$  variável com valor inicial igual a 0,05, fator de incremento de 1,05, fator de decréscimo de 0,9 e alfa máximo de 0,2 (parâmetros ajustados no programa MATLAB).

### **Classificação sem Duplicação de Dados da classe PE**

Definido os melhores parâmetros a serem utilizados no treinamento da rede, partiu-se para os testes da avaliação da acurácia do classificador. A Tabela 7 apresenta os resultados obtidos de classificação para 10 conjuntos sorteados aleatoriamente na proporção de 80% para treino e 20% para teste.

Tabela 7 – Ensaio 1 - Estimação da acurácia de classificação para os 10 pares de conjuntos sorteados

<b>Conjunto</b>	<b>Treino</b>	<b>Teste</b>
1	57,94	56,33
2	57,60	56,12
3	55,90	54,78
4	57,62	58,08
5	57,82	57,81
6	57,74	56,86
7	57,45	57,54
8	57,52	57,13
9	57,67	56,73
10	57,67	57,47
<b>Media</b>	<b>57,49</b>	<b>56,88</b>

Estes primeiros resultados demonstram que é possível realizar a separação das três classes, pois o pior caso esperado seria uma classificação com taxa de acerto de 33%, isto é, cada entrada ser classificada aleatoriamente. Contudo, os valores de acerto alcançados ainda são baixos para a rede ser utilizada como um classificador. Desta forma, foi necessária a aplicação de técnicas adicionais de pré-processamento e pós-processamento, descritas nas próximas seções.

### **Classificação com Duplicação de Dados da classe PE**

No conjunto de sinais deste ensaio, a classe PE contém 1517 dados, número equivalente a cerca de metade das classes SP e PI. Para equilibrar o número de dados das três classes, visando o não favorecimento das classes mais populosas no treinamento da rede, o número de dados de PE foi duplicado para 3034 dados.

Com o novo conjunto formado, dividiram-se por meio de sorteio aleatório os conjuntos de treino e teste na proporção de 80/20, respectivamente. Neste caso, apenas um conjunto de treino e um de teste foram sorteados, pois neste e nos demais testes a seguir o objetivo é avaliar o desempenho das técnicas empregadas no aumento da taxa de acerto, caso algumas das técnicas empregadas nas próximas seções apresente aumento significativo da taxa de acerto será realizado o teste de acurácia.

Com os mesmos parâmetros de configuração ótima de treinamento já definidos, recorreu-se ao uso de um conjunto de validação com 20% de sinais escolhidos aleatoriamente do conjunto de treino para controle de super treinamento (*overtraining*). Com o treinamento ajustado para 6000 épocas, o mesmo foi interrompido em 3820 pela validação. Para a classificação foi utilizado o critério de reclassificação.

A Tabela 8, referente aos sinais de treinamento, mostra que as classes SP e PI têm índices similares de acerto. A classe PE tem o maior índice de acerto de classificação, 64,57%. O fato mais importante que se pode observar é que as classes SP e PE têm os maiores índices de confusão, o que pode ser esperado em função da pouca discriminação destes eventos em EA. SP e PE têm pouca confusão com PI, embora PI tenha razoável

confusão com SP e, principalmente, PE, o que na prática é um resultado indesejável, pois seriam casos de falsos negativos.

Quanto ao conjunto de testes, também apresentados na Tabela 8, estes comprovam a generalização do classificador devido aos valores similares de acerto em relação ao conjunto de treinamento.

Tabela 8 – Ensaio 1 - tabela confusão dos conjuntos de treino e teste com duplicação de dados.

	Conjuntos de treinamento				Conjuntos de teste		
	SP	PE	PI		SP	PE	PI
SP	46%	52%	2%	SP	47%	51%	2%
PE	35%	64,5%	0,5%	PE	35%	63%	2%
PI	20%	32%	48%	PI	21%	34%	45%
ACERTOS	53%				50%		

Não foi observada evolução no desempenho do classificador, quando comparados os resultados obtidos com a rede treinada sem duplicação dos dados com a rede treinada com duplicação dos mesmos. Portanto os resultados apresentados nas próximas seções, são obtidos com redes neurais treinadas com os dados originais extraídos dos ensaios de EA, sem realização de duplicação de dados para equalizar a quantidade entre as classes.

### 5.1.1.2 Histogramas de classificação com três classes

Os histogramas a seguir apresentam a distribuição das saídas dos neurônios da rede visando à avaliação da probabilidade de um dado sinal pertencer a uma classe. Estes histogramas foram obtidos com os valores calculados a partir da Equação 9, página 46. Valores acima de zero são sinais classificados corretamente e valores inferiores a zero são sinais classificados erroneamente. Quanto mais próximo de zero, mais difícil é a classificação do sinal. As Figuras 22-a e 22-b mostram os histogramas obtidos para os

valores de  $Z_{SP}$  (diferença entre o U da classe SP e o U da classe mais próxima) para os conjuntos de treinamento e teste, respectivamente. Analogamente, foram elaborados os gráficos das Figuras 23 e 24 para as classes PE e PI, respectivamente.

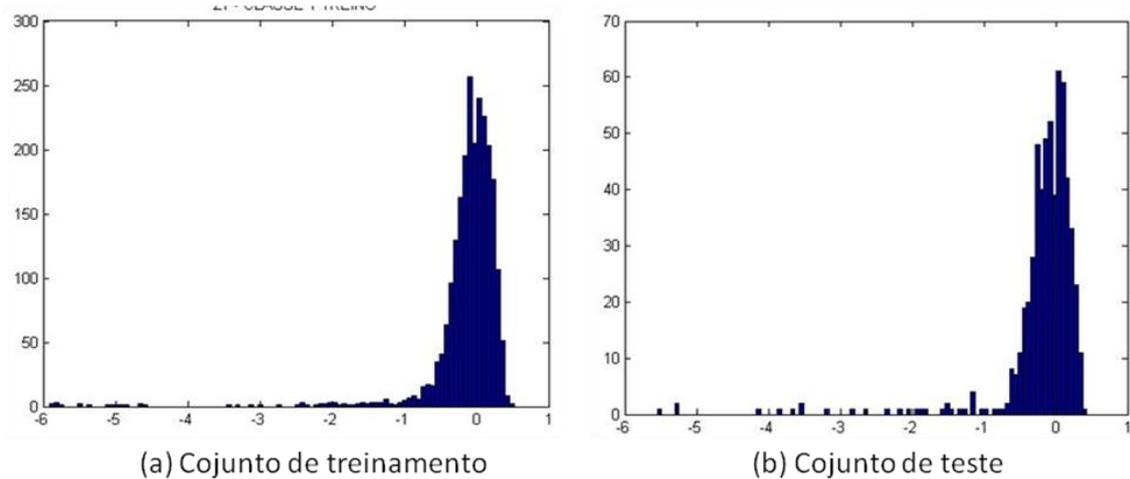


Figura 22 – Ensaio 1 - Distribuição dos valores de  $Z_{SP}$  para a classe SP em relação aos conjuntos sorteados para classificação

Pela figura 22, fica evidenciado que os valores calculados de  $Z$  estão próximos de zero, mostrando que a discriminação da SP de PE é complexa, ratificando os resultados apresentados de classificação para sinais de treinamento e teste.

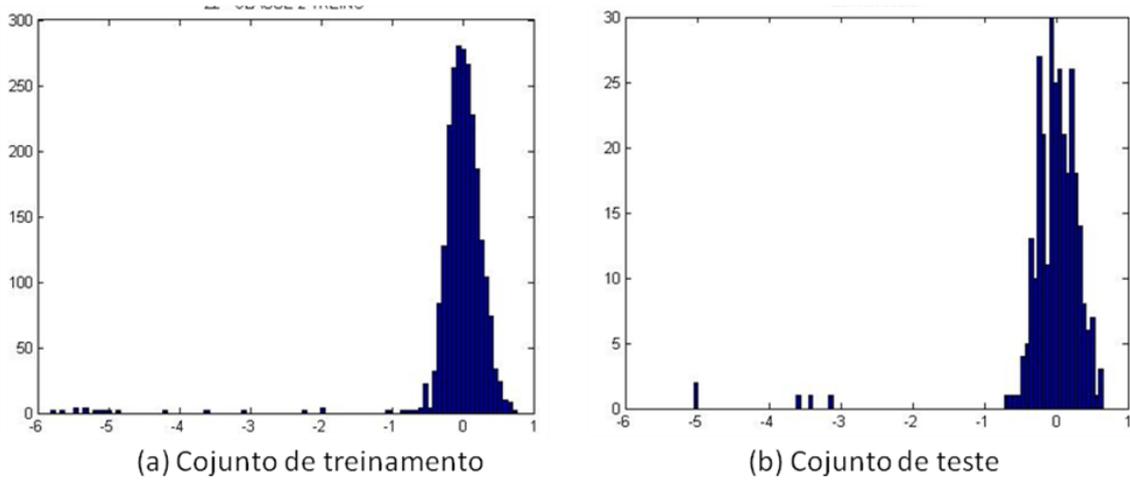


Figura 23 – Ensaio 1 - Distribuição dos valores de  $Z_{PE}$  para a classe PE em relação aos conjuntos

Assim como para classe SP, os gráficos apresentados na Figura 23 atestam que a separação da classe PE das demais classes é complexa, visto que os valores de  $Z$  também se encontram próximos de zero.

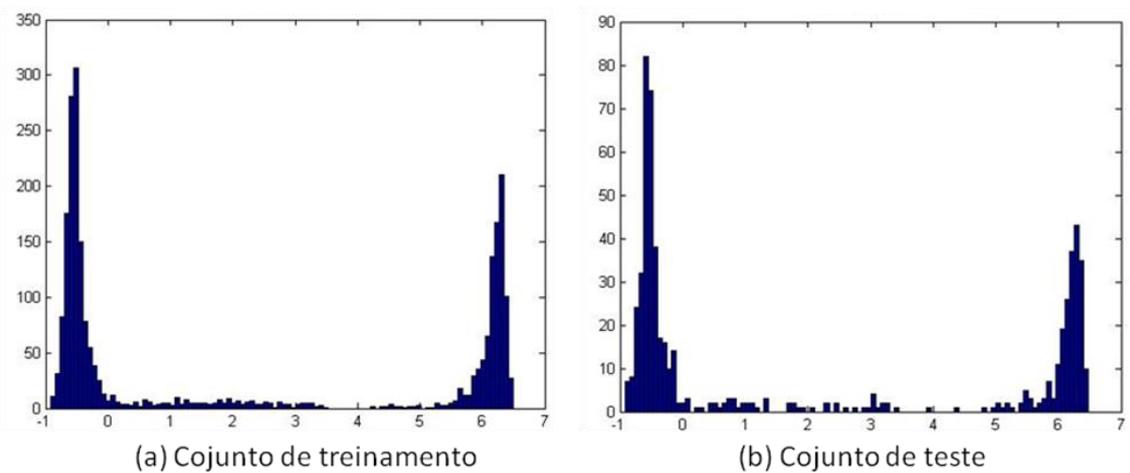


Figura 24 – Ensaio 1 - Distribuição dos valores de  $Z_3$  para a classe PI em relação aos conjuntos sorteados para a classificação.

Em relação à classe PI, os gráficos de Z apresentados na Figura 23 mostram que a discriminação dessa classe apresenta maior probabilidade de acerto, coerente com os valores de classificação apresentados na Tabela 8, pois muitos valores de Z estão posicionados acima de zero (pico em torno de 6).

### **5.1.1.3 Classificação com Duas Classes**

A partir dos resultados apresentados na seção 5.1.1.2 ficou evidente que a dificuldade está em classificar os sinais SP e PE. Com o objetivo de melhorar esta classificação, treinou-se uma rede utilizando como entrada os sinais das classes SP e PE, apenas. Foi utilizado o mesmo conjunto de parâmetros de configuração ótima e os mesmos conjuntos de treinamento e teste da seção 5.1.1.2, excluindo-se a classe PI. O treinamento foi ajustado para as mesmas 6000 épocas, entretanto, não foi utilizado nenhum critério de parada.

Para este treinamento não são apresentadas tabelas de confusão, pois o objetivo deste treinamento foi observar a dispersão das saídas do classificador e através disto analisar a dificuldade do classificador em discriminar as classes SP e PE.

A Figura 25 mostra os histogramas obtidos para os valores de  $Z_1$  (diferença entre o U da classe SP e o U da classe PE) para os conjuntos de treinamento e teste. Analogamente, foram elaborados os gráficos da figura 26 para a classe PE.

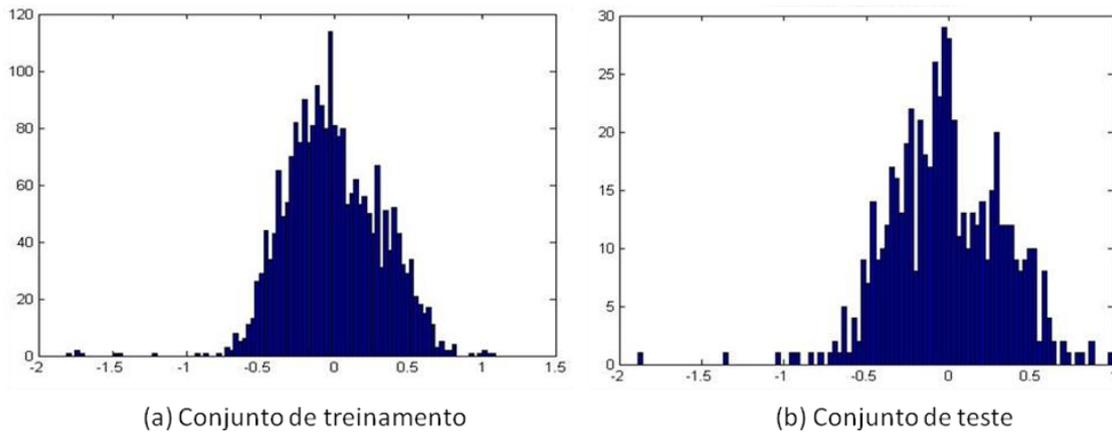


Figura 25 – Dados das classes SP e PE Ensaio 1 - Distribuição dos valores de  $Z_1$  para a classe SP em relação aos conjuntos sorteados para classificação.

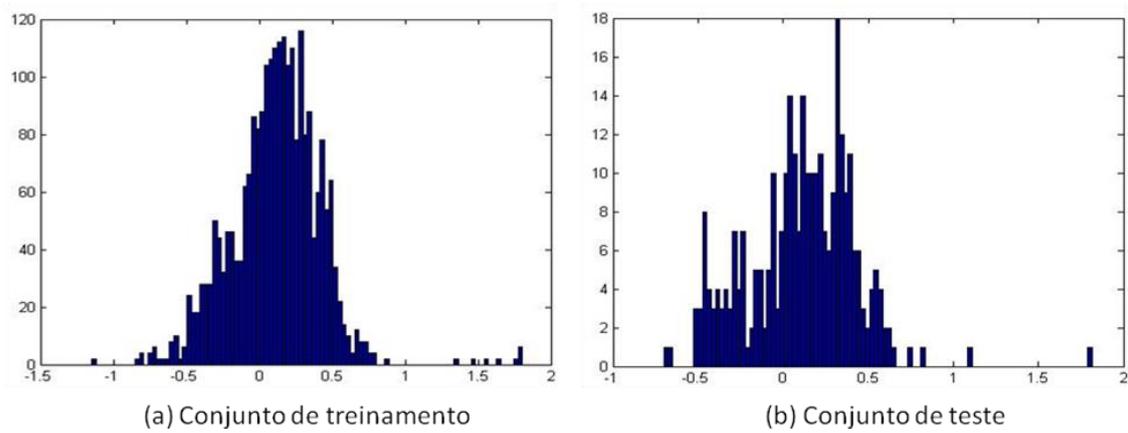


Figura 26 - Dados das classes SP e PE Ensaio 1 - Distribuição dos valores de  $Z_2$  para a classe PE em relação aos conjuntos sorteados para classificação.

As Figuras 25 e 26 demonstram que a rede ainda não é capaz de discriminar com clareza as duas classes, com a classificação correta de aproximadamente metade dos dados

Os histogramas demonstram uma grande região de confusão, isto é, uma grande concentração de dados em torno de zero, indicando que as duas classes podem estar

misturadas. Buscando uma melhor separação entre as classes, treinou-se uma nova rede utilizando os mesmos parâmetros ótimos já definidos, porém, com entradas diferentes.

O conjunto de treinamento foi formado com os cem primeiros elementos da classe SP e os centos e cinquenta últimos da classe PE (destes foram desprezados os cinquenta últimos sinais). Desta forma, esperou-se obter sinais que com certeza fossem da classe SP ou PE, já que foram selecionados sinais de entradas bem distantes. O conjunto de treinamento ficou com um total de 200 dados. A Figura 27-a mostra o gráfico de Pressão vs. Tempo e Crescimento da Trinca vs. tempo, destacados o conjunto de SP e o conjunto de PE. As Figuras 27-b e 27-c mostram o conjunto de SP e de PE, respectivamente.

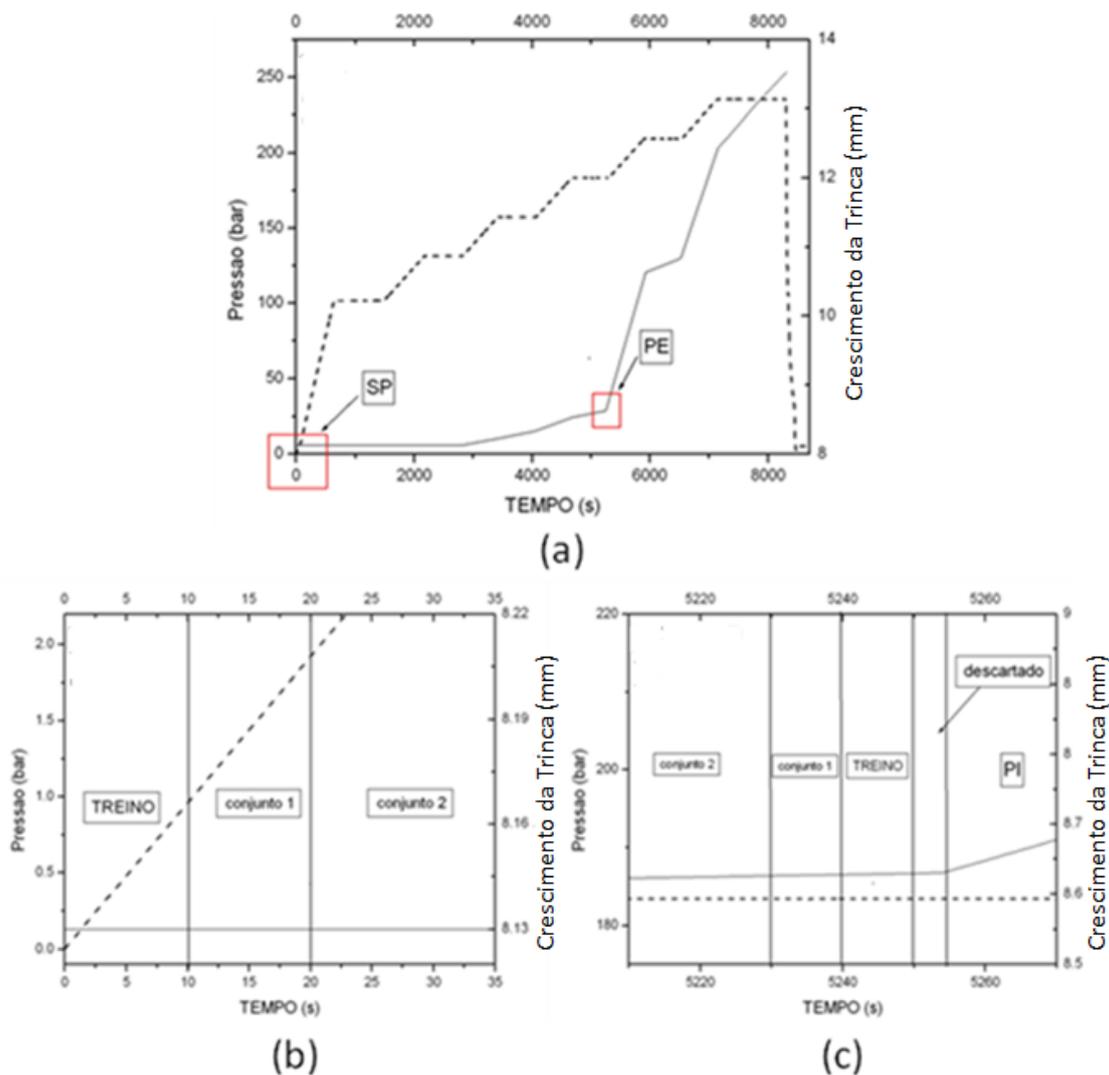


Figura 27 - Divisão dos novos conjuntos de treinamento e teste do Ensaio 1 para a classe SP e PE. (a) curva de Pressão vs. Tempo e Crescimento da Trinca vs. Tempo. (b) detalhe do conjunto de SP; (c) detalhe do conjunto de PE.

Para os testes desta nova rede, foram utilizados dois conjuntos diferentes de sinais. O conjunto 1 – Figura 27-b – contendo um total de duzentos elementos, cem da classe SP e cem da classe PE. Os sinais escolhidos da classe SP foram os cem elementos sequenciais após os elementos extraídos para treinamento. Os sinais da classe PE – Figura 27-c – foram formados separando os duzentos e cinquenta últimos sinais, desprezando-se os centos e cinquenta últimos (destes, 100 compuseram o conjunto de treinamento). No

conjunto 2, foram retirados os duzentos primeiros elementos da classe SP, pois estes foram utilizados no treinamento e no teste 1, e os sinais restantes foram usados para o segundo teste. Em relação à classe PE, procedeu-se da mesma forma, foram retirados os 250 últimos elementos da classe PE, pois estes já foram utilizados no treinamento e no teste 1. Os sinais que sobraram foram utilizados para o segundo teste.

As figuras 28 e 29 apresentam a distribuição para os valores de  $Z_1$  e  $Z_2$  encontrados, respectivamente.

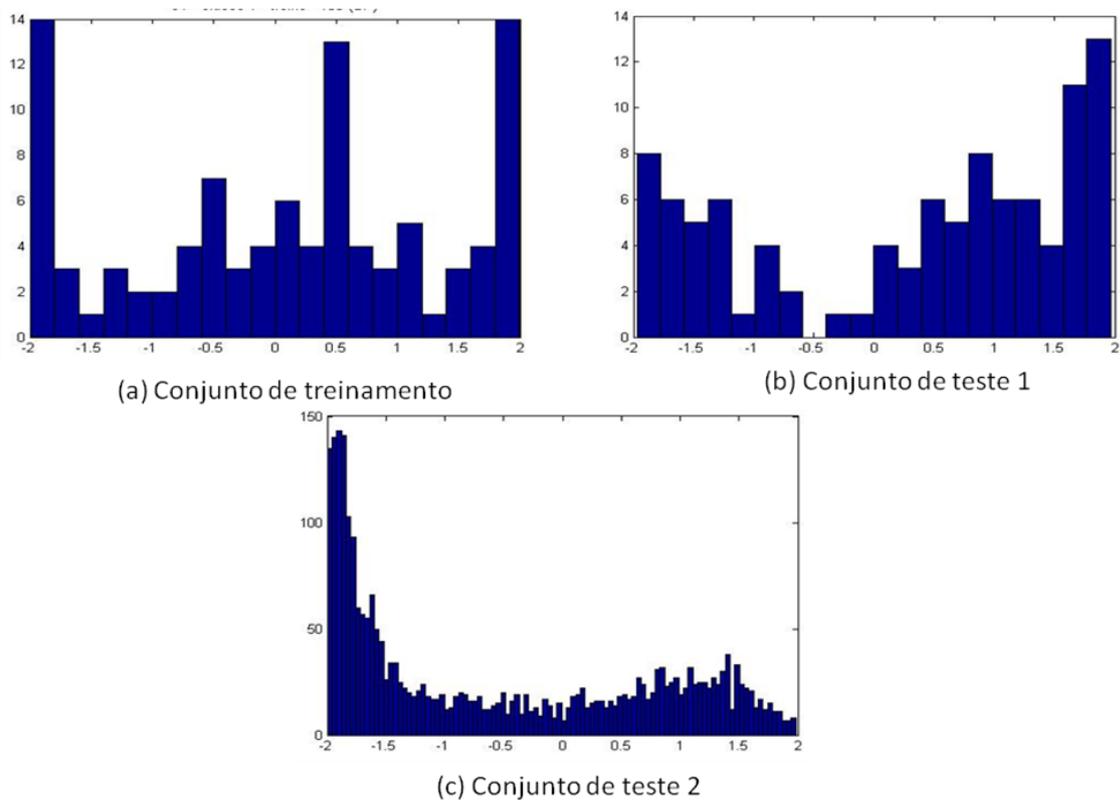


Figura 28 – Ensaio 1 - Distribuição dos valores de  $Z_1$  para a classe SP em relação aos novos conjuntos sorteados para classificação. (a) Conjunto de treino; (b) Conjunto de teste 1; (c) Conjunto de teste 2.

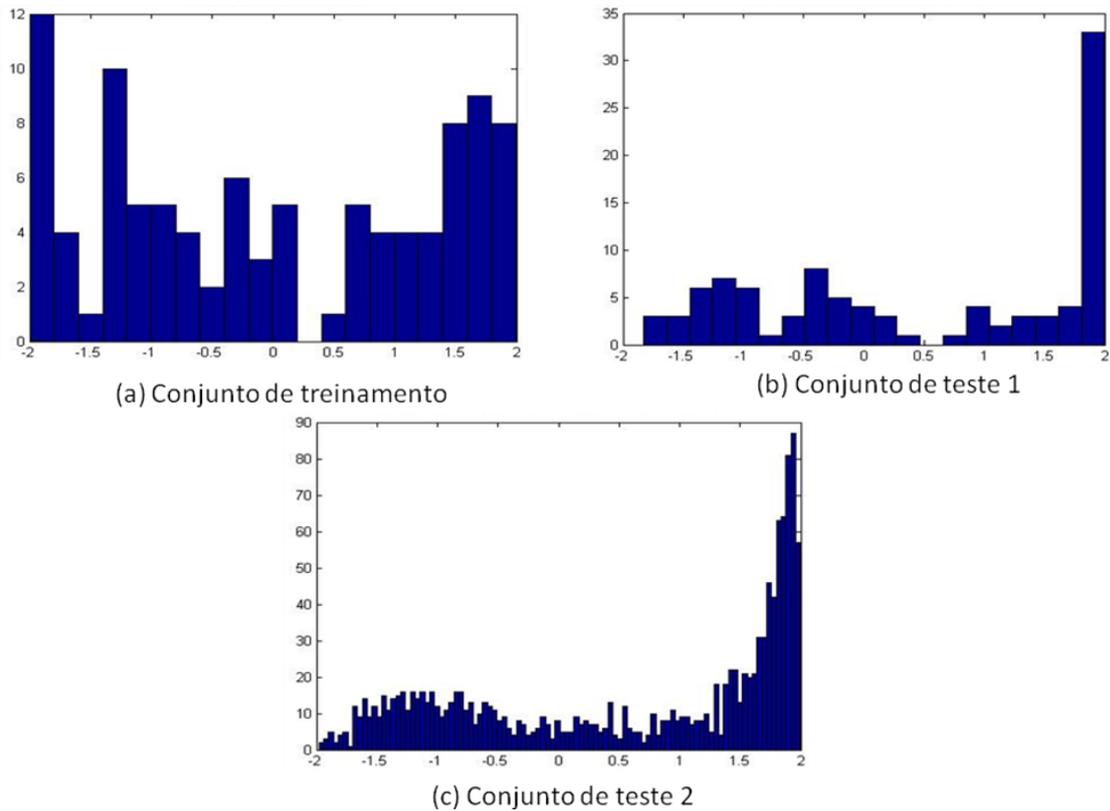


Figura 29 - Ensaio 1 - Distribuição dos valores de  $Z_2$  para a classe PE em relação aos novos conjuntos sorteados para classificação. (a) Conjunto de treino; (b) Conjunto de teste 1; (c) Conjunto de teste 2.

As Figuras 28 e 29 mostram que muitos dos sinais SP foram classificados como PE. Contudo, a Figura 29-c apresenta um aumento na taxa de acerto e o pico em torno de 2, mostrando que para os sinais da classe PE a nova rede obteve uma melhora na classificação. Embora longe do ideal esperado para discriminação destas duas classes de sinais de emissão acústica.

#### 5.1.1.4 Classificação com Novo Critério de Separação das Classes

Continuando a busca por resultados melhores de classificação, um novo critério de classificação foi definido, onde se definiu que se a pressão for mantida constante e o

defeito mesmo assim crescer, na curva de Crescimento da Trinca, da figura 30, há crescimento instável do mesmo, definindo os sinais da classe PI. Na situação de crescimento da pressão sem crescimento de defeito, define-se SP, e para as faixas de tempo com crescimento da pressão e crescimento do defeito, define-se PE. Duas novas redes foram treinadas com dois conjuntos de treinamento diferindo apenas nos intervalos de tempo selecionados de PE. As Tabelas 9 e 10 apresentam as faixas de formação das classes das redes A e B, respectivamente.

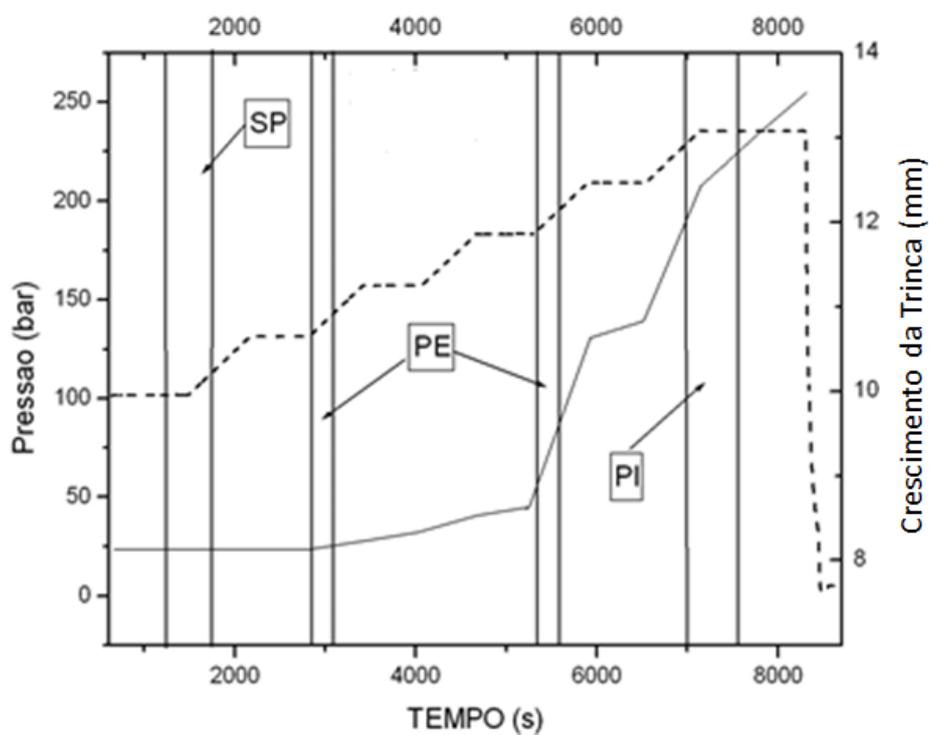


Figura 30 – Ensaio 1 - Separação dos dados de treinamento para Rede A de acordo com o novo critério proposto.

Tabela 9 - Definição da separação entre as classes para o treinamento da rede A

TIPO DE SINAL	TEMPO (s)	QUANTIDADE DE SINAIS
SP	1250 a 1750	500
PE	2850 a 3100 e 5350 a 5600	500
PI	7000 a 7500	500

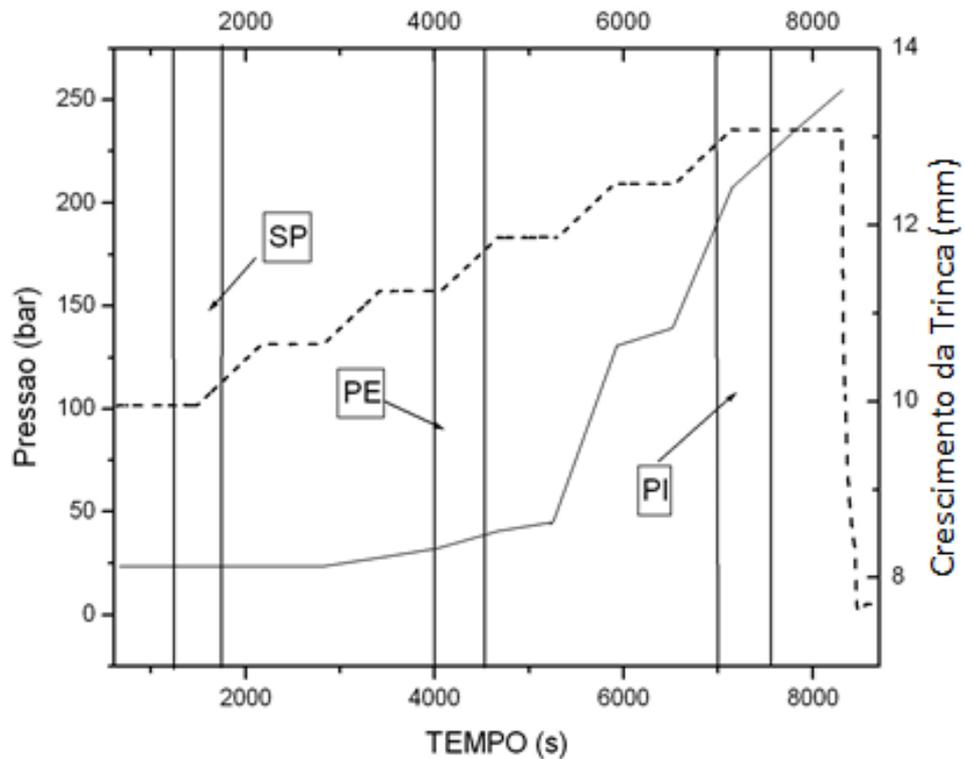


Figura 31 - Ensaio 1 - Separação dos dados de treinamento para Rede B de acordo com o novo critério proposto.

Tabela 10 - Definição da separação entre as classes para o treinamento da rede B

TIPO DE SINAL	TEMPO (s)	QUANTIDADE DE SINAIS
SP	1250 a 1750	500
PE	4000 a 4500	500
PI	7000 a 7500	500

As Tabelas 11 e 12 comprovam a dificuldade de classificar o sinal SP. Somente 50% desta classe são classificados corretamente, observa-se um aumento significativo na taxa de acerto da classificação de PE e PI, entretanto, ainda insatisfatório.

Tabela 11 - Tabela confusão para dados de treinamento da rede A

	<b>Conjunto de Treinamento</b>		
	<b>SP</b>	<b>PE</b>	<b>PI</b>
<b>SP</b>	41%	53%	6%
<b>PE</b>	23%	73%	3%
<b>PI</b>	11%	18%	71%
<b>ACERTOS</b>	62%		

Tabela 12 - Tabela confusão para dados de treinamento da rede B

	<b>Conjunto de Treinamento</b>		
	<b>SP</b>	<b>PE</b>	<b>PI</b>
<b>SP</b>	48%	47%	5%
<b>PE</b>	27%	70%	3%
<b>PI</b>	11%	19%	70%
<b>ACERTOS</b>	63%		

Desta forma, conclui-se que com o novo critério de classificação não foi possível alcançar melhora significativa dos resultados, sendo desnecessária a avaliação da rede com os dados de teste.

Para as saídas das classificações das redes A e B, de acordo com as Figuras 32 e 33 os sinais de SP e PE estão no entorno de zero, respectivamente, ratificando a dificuldade de discriminação entre estas duas classes.

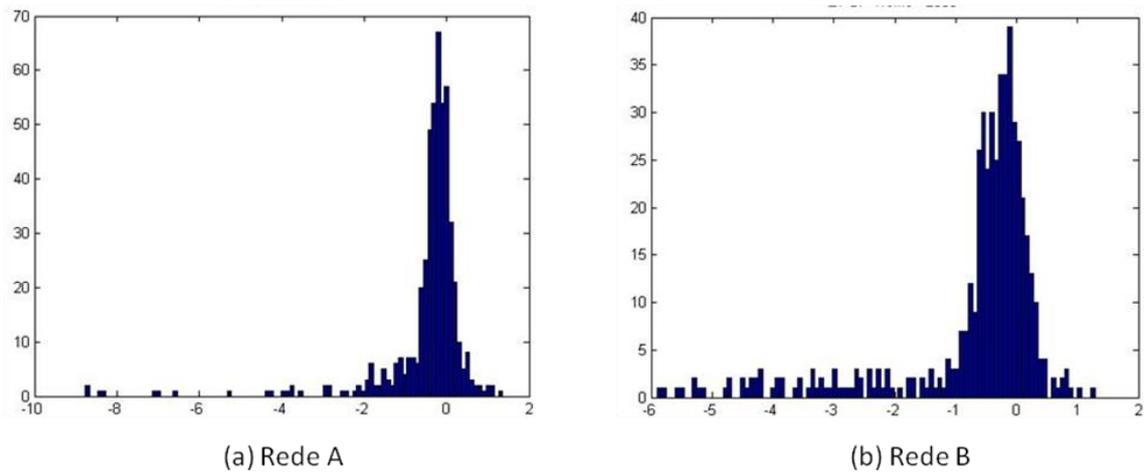


Figura 32 – Ensaio 1 - Distribuição dos valores de  $Z_{sp}$  para a classe SP em relação aos intervalos definidos. (a) Rede A; (b) Rede B.

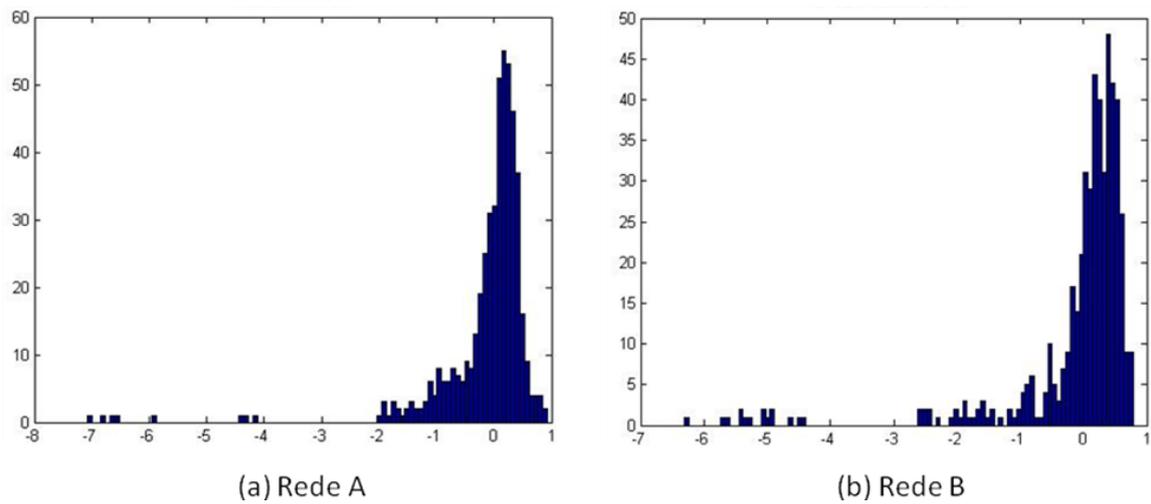


Figura 33 – Ensaio 1 - Distribuição dos valores de  $Z_{pe}$  para a classe PE em relação aos intervalos definidos. (a) Rede A; (b) Rede B.

A Figura 34, apresenta as distribuições de  $Z_{pi}$ , e reforça os resultados apresentados pela rede treinada na seção 5.1.1.2.

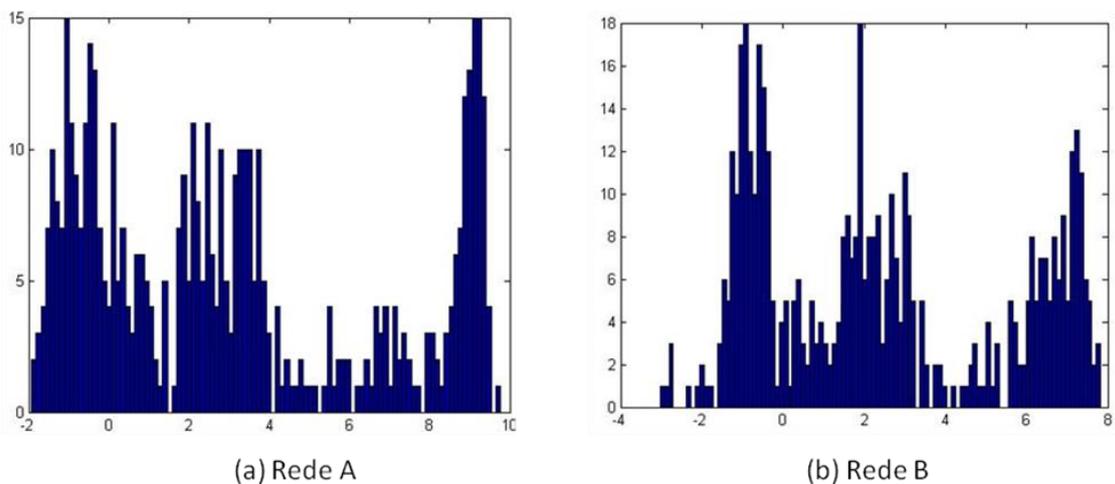


Figura 34 – Ensaio 1 - Distribuição dos valores de  $Z_{PI}$  para a classe PI em relação aos intervalos definidos. (a) Rede A; (b) Rede B.

Apesar de o resultado ideal ser um único pico afastado de zero, a distribuição apresentada, figura 34, indica que os dados da classe PI podem ser discriminados dos demais com índices melhores de acerto.

## 5.1.2 Ensaio 2

Conforme descrito no Capítulo 4, o sinal coletado de EA do Ensaio 2 teve o acréscimo de 6 parâmetros (FREQ-PP1, FREQ-PP2, FREQ-PP3, FREQ-PP4, C-FRQ e P-FRQ ). Neste ensaio ocorreu rompimento não brusco do corpo de prova.

Sua curva de Pressão vs. Tempo e Crescimento da Trinca vs. Tempo é apresentada na Figura 35, a partir do gráfico são definidos os intervalos de cada classe, nesta situação não foi empregado o método aplicado na seção 5.1.1.4, pois os resultados não

demonstraram evolução quando comparados com a metodologia tradicional de separação entre as classes. A classe SP foi definida até o tempo de 6868 s (181 bar), a classe PE entre 6869 e 8143 s (208 bar), e a classe PI entre 8144 s e 12837 s (233 bar). Resultando em 2207 sinais de SP, 1394 sinais de PE e 6439 sinais de PI.

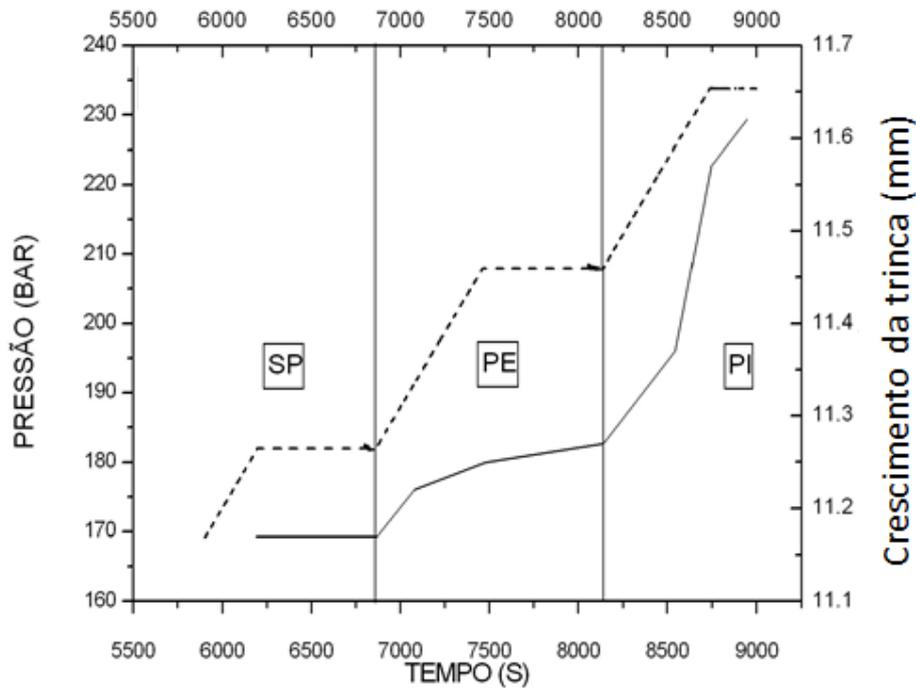


Figura 35 - Ensaio 2 - Curva de Pressão vs. Tempo de Ensaio – linha tracejada. Curva de Crescimento da trinca vs. Tempo de Ensaio – linha contínua. Separação ao longo do tempo das classes SP, PE e PI.

Um novo estudo de configuração ótima da rede foi realizado para evitar problemas de super treinamento (*overtraining*), já que os sinais obtidos no Ensaio 2 tiveram o acréscimo de novos parâmetros. De acordo com a Tabela 13, o melhor resultado para o conjunto de treino e teste foi com seis neurônios na camada intermediária, alfa de 0,05 variável e uso de momento em 0,9. Vale ressaltar que os índices de acerto são inferiores aos encontrados na seção 5.1.2.2, esta diferença ocorre porque no estudo de configuração

o treino é ajustado para 1000 épocas, enquanto que para treinar os classificadores de três e duas classes foram utilizadas 6000 épocas.

Empregando esta configuração, foram treinadas redes para classificar duas classes, SP e P, e classificadores de três classes, SP, PE e PI. Conforme descrito nos itens a seguir.

Tabela 13 - Índice de acerto em função da variação do número de neurônios na camada intermediária da rede treinada para classificar três classes.

Neurônios camada Intermediária	Sem momento		Com momento		Sem momento e Alfa variável		Com momento e Alfa variável	
	Treino	Teste	Treino	Teste	Treino	Teste	Treino	Teste
1	61,44	61,65	61,73	62,05	68,84	68,87	69,35	69,57
2	61,00	60,96	61,06	60,91	68,96	68,87	69,31	69,57
3	64,95	65,14	60,97	60,96	68,84	68,78	69,24	69,62
4	67,41	67,43	63,48	63,35	68,89	68,78	69,27	69,47
5	67,80	67,58	64,92	65,14	68,86	68,82	69,27	69,47
<b>6</b>	68,01	67,83	67,11	67,18	68,86	68,82	<b>69,27</b>	<b>69,57</b>
7	68,14	68,02	67,41	67,38	68,92	68,82	69,27	69,57
8	68,18	68,08	67,69	67,43	68,86	68,82	69,27	69,57
9	68,41	68,33	67,83	67,63	68,87	68,82	69,27	69,57
10	68,51	68,38	67,95	67,73	68,93	68,82	69,26	69,57

### 5.1.2.1 Separação em Duas Classes

Analisando o gráfico da Figura 36 a seguir, os sinais foram separados na classe SP (Sem Propagação) até o tempo de 6868 s (181 bar) e classe P (Propagação) entre 6869 s e 12837 s (233 bar). Resultando em 2207 sinais de SP e 7834 de P.

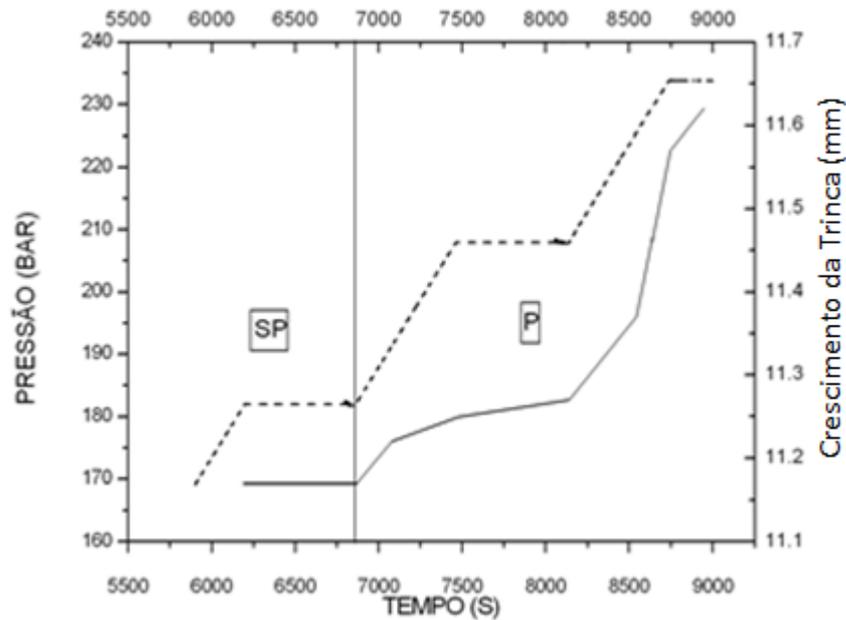


Figura 36 - Ensaio 2 - Curva de Pressão vs. Tempo de Ensaio – linha tracejada. Curva de Crescimento da trinca vs. Tempo de Ensaio – linha contínua. Separação ao longo do tempo das classes SP e P.

Foram sorteados aleatoriamente 10 pares de conjunto de treinamento e teste (80% para treino e 20% para teste). A Tabela 14 a seguir apresenta os valores de média de acerto em percentual referentes aos 10 conjuntos sorteados de treinamento e teste. A Tabela 15 apresenta os desvios padrões da média.

Tabela 14 – Ensaio 2 – Resultado da média de acerto para os 10 conjuntos de treino e teste (duas classes)

Conjuntos de treinamento			Conjuntos de teste		
	SP	P		SP	P
SP	73%	27%	SP	75%	25%
P	5%	95%	P	12%	88%
ACERTOS	90%		85%		

Na Tabela 14, os valores de acerto de treinamento são compatíveis com o esperado para discriminação de duas classes, já que no Ensaio 1 ficou evidente que a classe PI é bem definida e dificuldade está em separar SP de PE. O mesmo ocorrendo com os sinais

usados para testar os classificadores, a pouca diferença entre a média de acerto de treinamento e teste comprova a generalização do classificador.

Tabela 15 – Ensaio 2 - Resultados do desvio padrão da média de acerto para os 10 conjuntos de treino e teste (duas classes). STD – Desvio padrão da média geral de acerto.

Conjuntos de treinamento			Conjuntos de teste		
	SP	P		SP	P
SP	1%	1%	SP	9%	9%
P	0%	0%	P	12%	12%
STD	0%		9%		

A Tabela 15 apresenta os valores de desvio padrão entre as dez redes treinadas, mostrando que os conjuntos de teste apresentam bastante dispersão, porém, os desvios de acerto geral são admissíveis se considerando a quantidade de sinais em cada conjunto de teste.

### 5.1.2.2 Separação com Três classes

Para situação de classificação com três classes, a separação foi feita conforme já descrito na seção 4.1.2. Inicialmente, foram feitos testes com o sistema de classificação considerando apenas o único valor positivo na saída dos neurônios, isto é, o que se denomina **Sem Reclassificação** e em seguida procedeu-se com o teste denominado **Com Reclassificação** (DA SILVA, 2003).

## Ensaio 2 – Classificação Sem Reclassificação

Pela Tabela 16 de confusão a seguir, a acurácia de acerto com três classes **Sem Reclassificação** atinge 74% para os conjuntos de treinamento e 71% com os conjuntos de teste, comprovando a generalização dos classificadores não lineares. Há de se destacar que a configuração da rede neural foi a mesma em todas as situações, conforme explanado anteriormente. Estes valores, comparados aos encontrados no Ensaio anterior (atingiram pouco mais 50% de acerto geral), na mesma condição, são significativamente maiores, indicando que a inclusão dos seis parâmetros influenciou neste aumento relevante de acerto. Este fato sugere que estes parâmetros são fundamentais na aquisição dos sinais e um estudo mais aprofundado será realizado na seção 5.1.2.3.

Tabela 16 – Ensaio 2 - Tabela de Confusão média para os 10 conjuntos de treinamento e teste (três classes sem reclassificação). NC – não classificado

	Conjuntos de treinamento						Conjuntos de teste			
	SP	PE	PI	NC			SP	PE	PI	NC
SP	83%	4%	13%	12%	SP	82%	4%	14%	12%	
PE	16%	77%	7%		PE	15%	77%	8%		
PI	4%	4%	92%		PI	4%	4%	1129/92%		
ACERTO	78%					77%				

Analisando-se separadamente os índices médios de acerto pra cada uma das três classes agora estudadas, a classe PI é a que tem a melhor acurácia de classificação (92%), o que era esperado, pois fenomenologicamente é quando há o crescimento instável do defeito e os eventos de emissão acústica se tornam mais perceptíveis no sistema de aquisição. A classe PE confunde com SP e também com PI, o que prova que constatar o exato momento de transição do estado de não propagação do defeito para o estado de uma propagação elástica, estável, assim como a transição do regime elástico para o plástico é consideravelmente mais complexa. Os valores de Não Classificação (mais de uma saída

positiva ou todas negativas) estão dentro do esperado no que normalmente acontece em reconhecimento de padrão.

Na análise dos desvios padrões (Tabela 17), constata-se que os valores são pequenos, não havendo muita dispersão dos percentuais de acerto entre os 10 pares de conjuntos sorteados.

Tabela 17 - Tabela de Confusão do desvio padrão para os 10 conjuntos de treinamento e teste (três classes sem reclassificação). NC – não classificado. STD – Desvio padrão da média geral de acerto.

	Conjuntos de treinamento					Conjuntos de teste			
	SP	PE	PI	NC		SP	PE	PI	NC
SP	3%	2%	2%	1%	SP	3%	3%	3%	1%
PE	1%	1%	1%		PE	2%	2%	2%	
PI	0%	0%	0%		PI	1%	1%	1%	
STD	1%				1%				

## Ensaio 2 – Classificação Com Reclassificação

O próximo passo nos testes foi avaliar a classificação dos mesmos pares de conjuntos formados no item anterior no sistema de **Reclassificação**. Nesta metodologia, lembrando, o neurônio que indica a classe é o de maior valor, apontando a maior probabilidade de que um sinal pertença a essa classe.

A Tabela 18 de confusão apresenta os resultados obtidos nesta classificação. As acurácias de treinamento e teste aumentaram em relação à situação anterior, como era de se esperar. Em treinamento a média chegou a 85%, e nos testes, 84%, 7% a mais que para **Sem Reclassificação**. O resultado final indica cerca de 30% a mais de acerto para sinais usados em teste em ao Ensaio 1. Esta tabela de confusão também indica que apesar de

menor o índice de acerto quando comparado com a classe PI, as classes SP e PE conseguiram ser discriminadas.

Tabela 18 - Tabela de Confusão da média para os 10 conjuntos de treinamento e teste (três classes com reclassificação).

	Conjuntos de treinamento				Conjuntos de teste		
	SP	PE	PI		SP	PE	PI
SP	77%	10%	13%	SP	76%	10%	14%
PE	18%	74%	8%	PE	16%	74%	10%
PI	5%	4%	91%	PI	5%	5%	90%
ACERTO	85%				84%		

A Tabela 19 apresenta os valores de desvio padrão entre classes e geral, apresentando valores compatíveis com os da Tabela 17.

Tabela 19 - Tabela de Confusão do desvio padrão para os 10 conjuntos de treinamento e teste (três classes com reclassificação). STD – Desvio padrão da média geral de acerto.

	Conjuntos de treinamento				Conjuntos de teste		
	SP	PE	PI		SP	PE	PI
SP	/3%	3%	1%	SP	4%	3%	2%
PE	2%	1%	/2%	PE	3%	2%	1%
PI	0%	0%	0%	PI	1%	1%	1%
STD	1%				1%		

### 5.1.2.3 Estudo da Relevância das Entradas

Ao comparar as taxas de acerto na classificação dos dados do Ensaio 1 com os do Ensaio 2, se observa o aumento dos índices de acerto na classificação indicou que os parâmetros acrescidos são importantes para o bom desempenho do classificador, desta forma uma investigação mais detalhada de cada parâmetro se faz necessária. Para isso, se utilizou a metodologia apresentada na seção 4.1.4 e o conjunto de dados do Ensaio 2 para o treinamento da rede neural.

A Figura 37 apresenta o índice de relevância de cada para cada uma das três classes. O gráfico mostra que o AMP e ASL influenciam apenas na classificação de SP e PI, enquanto que o I-Freq e o C-Freq, são fundamentais para a discriminação de PE, assim como Freq-PP3. O parâmetro I-Freq contribuiu para a identificação de SP e PE, enquanto que FreqPP1 e Freq PP2 para as três classes. Os demais parâmetros contribuem pouco para a discriminação entre as classes.

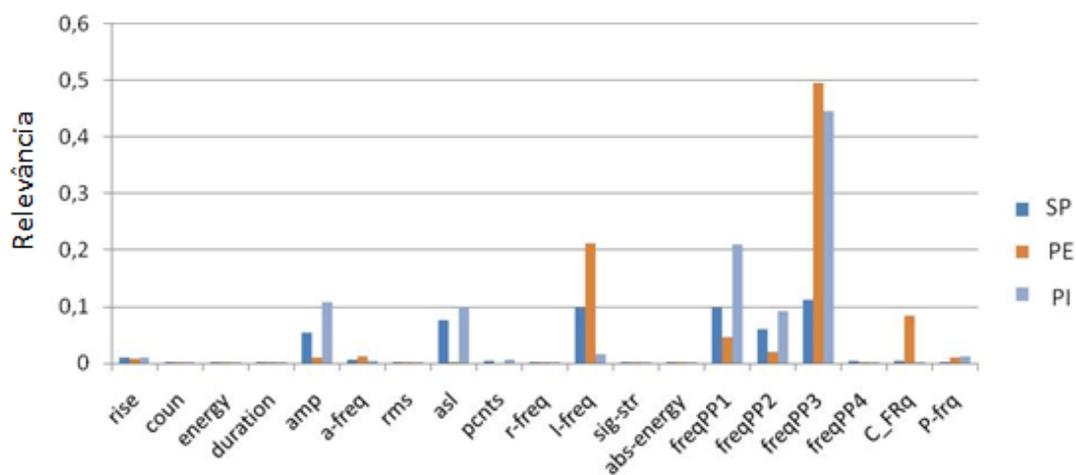


Figura 37 - Gráfico da relevância de cada parâmetro para cada uma das três classes

A Figura 38 apresenta o histograma dos índices de relevância, no eixo vertical esquerdo estão todos os dezenove parâmetros analisados, no eixo horizontal está o valor do índice de relevância e no eixo vertical direito a altura da coluna do histograma.

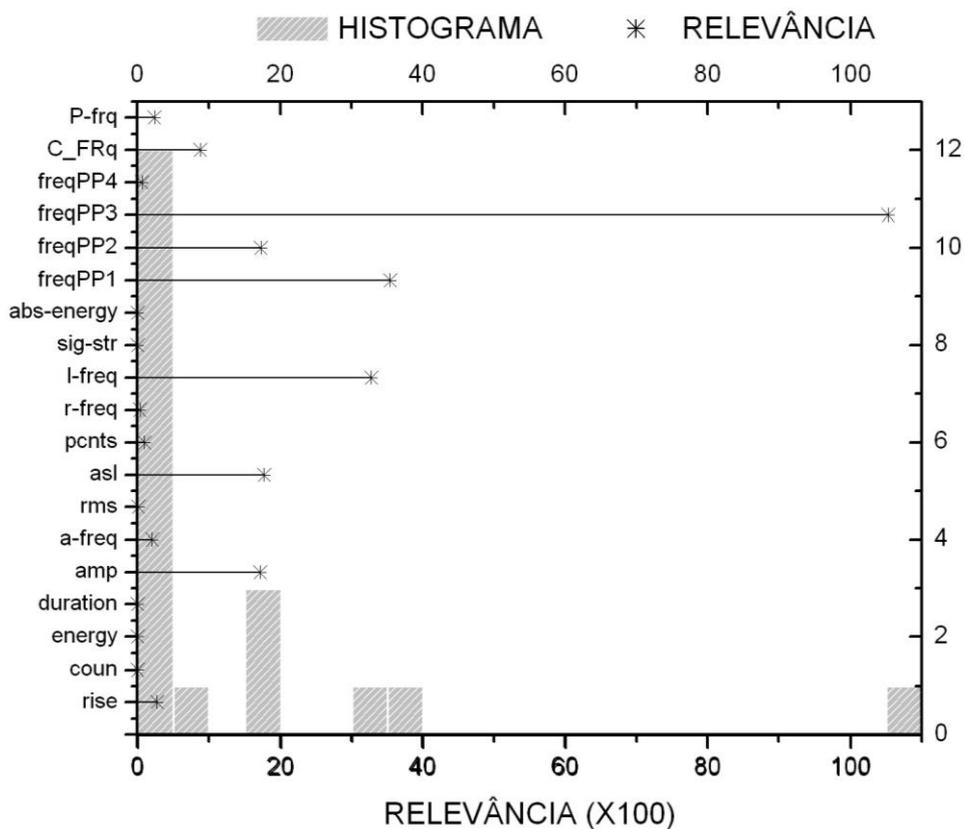


Figura 38 - Em cinza o histograma das relevâncias para as três classes juntas. As estrelas indicam a relevância de cada parâmetro para as três classes juntas.

O parâmetro de maior relevância é o Freq-PP3, depois o Freq-PP1 e o I-Freq com uma relevância em torno de 30. O AMP, ASL e o Freq-PP2 apresentam relevância um pouco abaixo de 20 e o C-Freq entre 5 e 10. Os demais parâmetros apresentaram valores abaixo de 5, indicando pouca ou nenhuma influência na classificação.

Para confirmar a influência de cada parâmetro na discriminação das classes, criaram-se cinco conjuntos com os pares de entrada e saída, conforme descrito na figura 38, quanto mais no interior, maior a relevância do parâmetro.

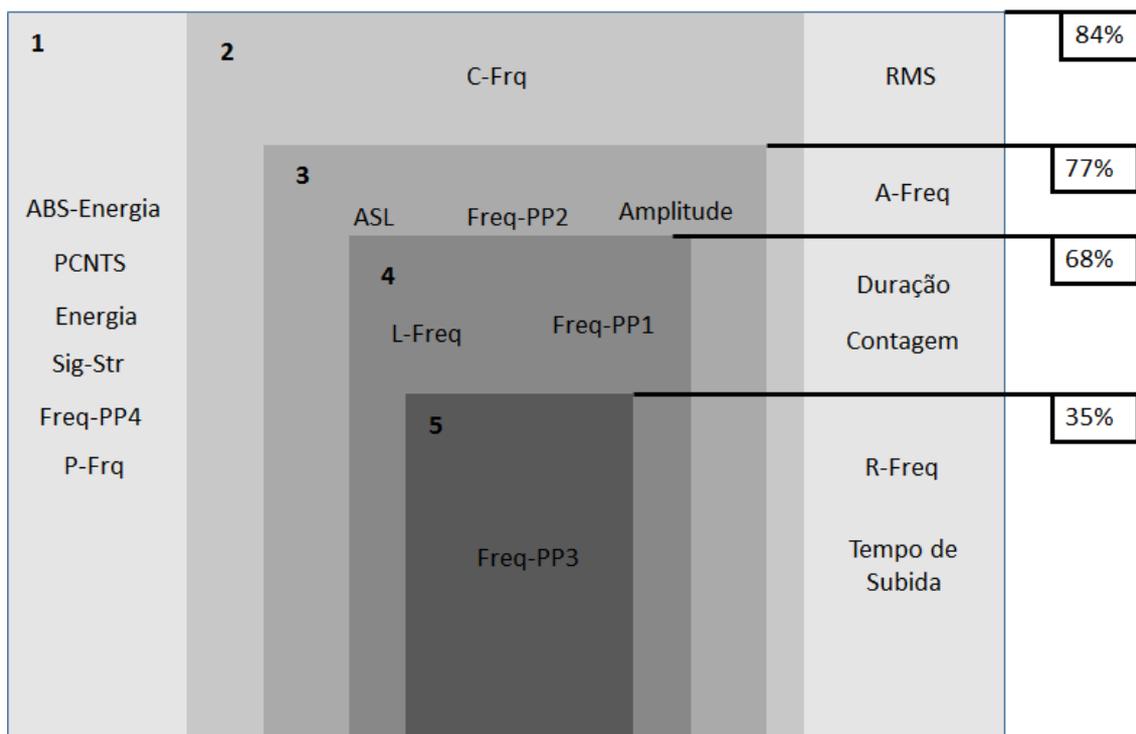


Figura 39 - Separação de conjuntos pela relevância. À direita o percentual de acerto na classificação de cada conjunto.

O conjunto de entrada é formado da seguinte forma, o valor do parâmetro contido no conjunto é mantido inalterado e os não contidos no conjunto são substituídos pelo seu valor médio. Por exemplo, no conjunto 5 os valores de Freq-PP3 se mantêm enquanto que os demais parâmetros são substituídos pela média. Depois de formado, o conjunto é aplicado ao classificador.

A Figura 39 indica que a taxa de acerto entre o conjunto 1 e o conjunto 2 são iguais, confirmando que os parâmetros com relevância inferior a 5 não influenciam na classificação. A eliminação de C-Frq reduziu o acerto em 7%. O conjunto 4 alcançou quase de 70% de acerto, usando apenas 3 parâmetros, e o conjunto 5, 35%, com apenas 1 parâmetro. Este resultado confirma, o indicado pela figura 35, que os parâmetros com relevância menor que 5 praticamente não influenciam na classificação.

Com objetivo de corroborar os resultados apresentados, uma nova rede foi treinada utilizando os mesmos pares de entrada e saída já utilizados nesta seção. Contudo a entrada contém apenas os parâmetros do conjunto 2 da Figura 36, isto é, apenas os sete mais relevantes. A configuração da rede foi a mesma utilizada na seção 5.1.2.2.

As Tabelas 20 e 21 apresentam os resultados obtidos na classificação com a rede treinada com todos os parâmetros de entrada e a classificação com a rede treinada com os sete parâmetros mais relevantes (C-Frq, ASL, AMP, I-Frq, Freq-PP1, Freq-PP2, Freq-PP3), respectivamente.

Tabela 20 – Ensaio 2 – Estudo da relevância dos parâmetros de entrada. Tabela confusão da rede treinada com todos os 19 parâmetros de entrada.

	Conjuntos de treinamento				Conjuntos de teste		
	SP	PE	PI		SP	PE	PI
SP	75%	12%	13%	SP	76%	13%	11%
PE	18%	74%	8%	PE	14%	77%	9%
PI	5%	5%	90%	PI	6%	4%	90%
ACERTOS	84%				85%		

Tabela 21 – Ensaio 2 – Estudo da relevância dos parâmetros de entrada. Tabela confusão da rede treinada com os 7 parâmetros mais relevantes (C-Frq, ASL, AMP, I-Frq, Freq-PP1, Freq-PP2, Freq-PP3).

	Conjuntos de treinamento				Conjuntos de teste		
	SP	PE	PI		SP	PE	PI
SP	55%	24%	21%	SP	69%	14%	17%
PE	11%	74%	15%	PE	16%	67%	17%
PI	4%	4%	92%	PI	4%	3%	93%
ACERTOS	81%				84%		

A rede treinada com os sete parâmetros mais relevantes alcançou um desempenho muito próximo da rede treinada com todos os parâmetros, apresentando uma redução de 3% na classificação correta no conjunto de treinamento e de apenas 1% no conjunto de teste.

O conjunto dos sete parâmetros identificados como os mais relevantes contém quatro parâmetros que foram acrescentados no Ensaio 2 (C-Frq, Freq-PP1, Freq-PP2, Freq-PP3) e o considerado o mais relevante para a discriminação das classes, Freq-PP3, também não estava presente no Ensaio 1. Este estudo atesta que a inclusão dos parâmetros no Ensaio 2, influenciou no aumento relevante do desempenho do classificador quando comparado com o Ensaio 1. Este fato indica que estes parâmetros são fundamentais na aquisição dos sinais e não devem ser descartados.

### **5.1.3 Ensaio 3**

Conforme descrito no Capítulo 4, o sinal coletado de EA do Ensaio 3 teve o acréscimo de 6 parâmetros (FREQ-PP1, FREQ-PP2, FREQ-PP3, FREQ-PP4, C-Frq e P-Frq).

De acordo com o tempo do Ensaio 3 os dados foram separados em: classe SP entre 4000 e 6000 segundos, classe PE entre 6000 e 8000 segundos e classe PI entre 8000 e 13000 segundos, figura 40. Resultando em um total de 2053 amostras de SP, 1045 de PE e 383 de PI. Neste ensaio, não foi possível obter dados da pressão no duto ao longo do tempo e ocorreu rompimento brusco do corpo de prova.

Na seção 5.1.2, Ensaio 2, foram definidos os parâmetros “ótimos” de treinamento da rede neural com dezenove parâmetros de entrada, desta forma os mesmos parâmetros foram empregados no desenvolvimento do classificador deste ensaio. Assim como no Ensaio 2, o desequilíbrio dos dados não afetou o desempenho da rede neural treinada.

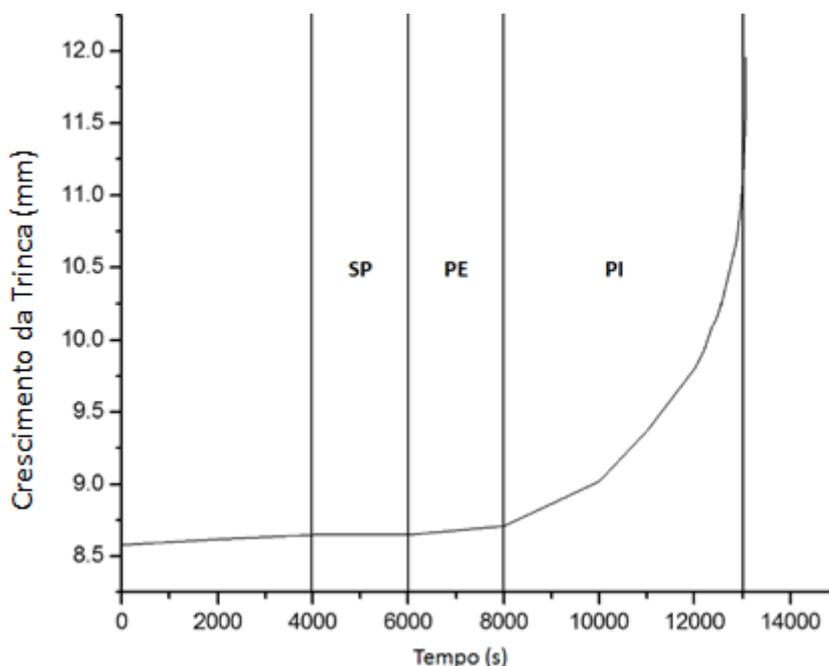


Figura 40 – Ensaio 3 – Curva de Crescimento da trinca vs. tempo.

A tabela 22 apresenta o resultado obtido na classificação do sinal, sem reclassificação.

Tabela 22 - Ensaio 3 - Tabela de Confusão média para os 10 conjuntos de treinamento e teste (três classes sem reclassificação). NC – não classificado

	Conjunto de treinamento					Conjunto de teste			
	SP	PE	PI	NC		SP	PE	PI	NC
SP	92%	6%	0%	0%	SP	93%	6%	0%	0%
PE	10%	86%	4%		PE	9%	84%	4%	
PI	1%	4%	95%		PI	1%	8%	91%	
ACERTOS	91%					91%			

O classificador alcançou 91% de acerto no conjunto de treino e no de teste, maior taxa de acerto encontrada até este momento do estudo. Analisando individualmente cada classe, conclui-se que a rede neural discriminou corretamente as três classes, incluindo a classe PE, a qual apresentou um aumento na acurácia de 13% quando comparada com os resultados do Ensaio 2. Os valores não classificados (mais de uma saída positiva ou todas negativas) foram próximos de zero.

A falta dos dados da pressão deste ensaio impede a comparação gráfica entre o Ensaio 2 e o Ensaio 3. Existem indícios que o rompimento brusco do corpo de prova pode ter contribuído para uma melhor caracterização das três classes. Outro fator relevante é que neste ensaio a separação das classes foi baseada apenas na curva de crescimento da trinca e este procedimento pode ter favorecido uma melhor identificação do limiar de separação entre as classes.

## 5.2 Curva PoP

Esta seção apresenta os resultados obtidos para cada uma das classes ao aplicar o método proposto. A primeira curva PoP é gerada a partir dos dados obtidos no Ensaio 3 e a segunda a partir dos dados do Ensaio 2.

A tabela 23 apresenta a função de regressão calculadas a partir da equação 10, página 48, para cada uma das classes. Através destas, pode-se calcular a probabilidade do sinal de entrada pertencer a cada classe, SP, PE e PI.

Tabela 23 - Equações de regressão tangente hiperbólica.

Classe	Equação	
SP	$P_{SP}(t) = 0.4951 \times \tanh(3.507 \times Z_{SP}(t) - 1.372) + 0.4999$	(14)
PE	$P_{PE}(t) = 0.4951 \times \tanh(0.7004 \times Z_{PE}(t) + 0.4588) + 0.4940$	(15)
PI	$P_{PI}(t) = 0.4745 \times \tanh(1.811 \times Z_{PI}(t) + 3.114) + 0.4925$	(16)

A figura 41 apresenta as curvas de Possibilidade da classe SP em função do tempo, cada ponto representa a probabilidade para cada valor de  $Z$ , encontrada através do emprego da equação 14.

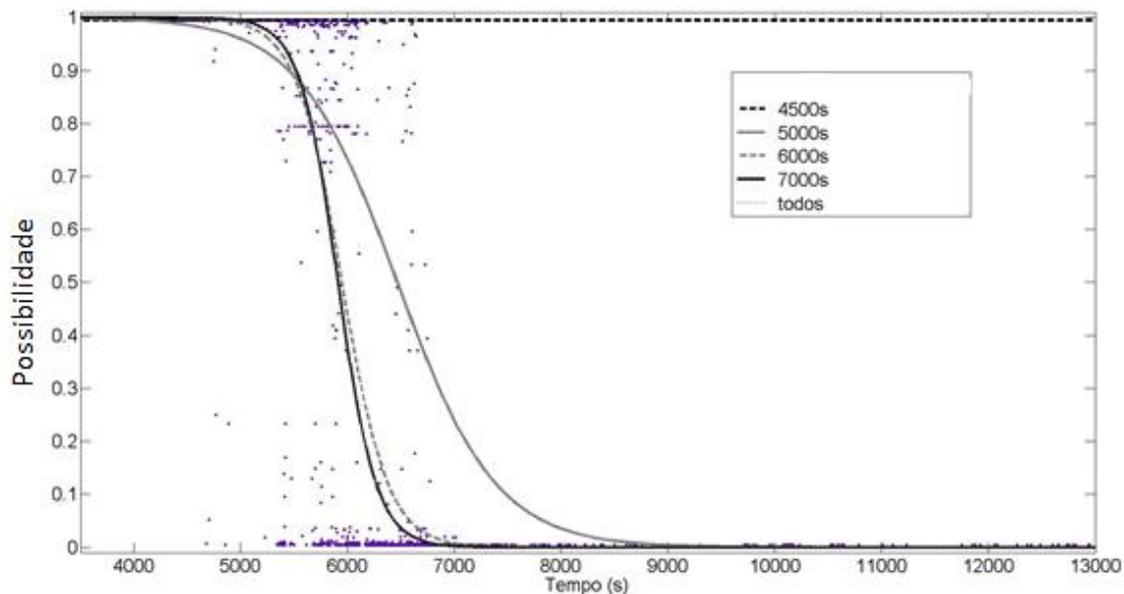


Figura 41 – Curvas de Possibilidade da classe SP para o Ensaio 3. Os pontos representam a probabilidade para cada valor de Z. A linha tracejada preta a curva estimada até 4500 segundos, a linha contínua cinza a curva até 5000s, a linha tracejada cinza a curva até 6000s, a linha contínua preta a curva até 7000s e a linha pontilhada cinza a curva estimada com todos os sinais do Ensaio 3.

Como esperado inicialmente, a maior concentração de pontos está próxima de um, com o aumento do tempo de ensaio a maior concentração de pontos encontra-se próxima de zero, de acordo com o aumento do tempo de ensaio a curva se aproxima da convergência.

As figuras 42 e 43 apresentam a convergência dos coeficientes “a” e “b” da equação 11, página 45, respectivamente, à medida que o tempo progride e mais dados são disponíveis para a construção da curva. Pode ser observado que próximo a 7000 segundos ocorre a convergência de ambos os coeficientes, tal fato pode ser comprovado observando na figura 41 a sobreposição das curvas de até 7000 segundos e com todos os sinais.

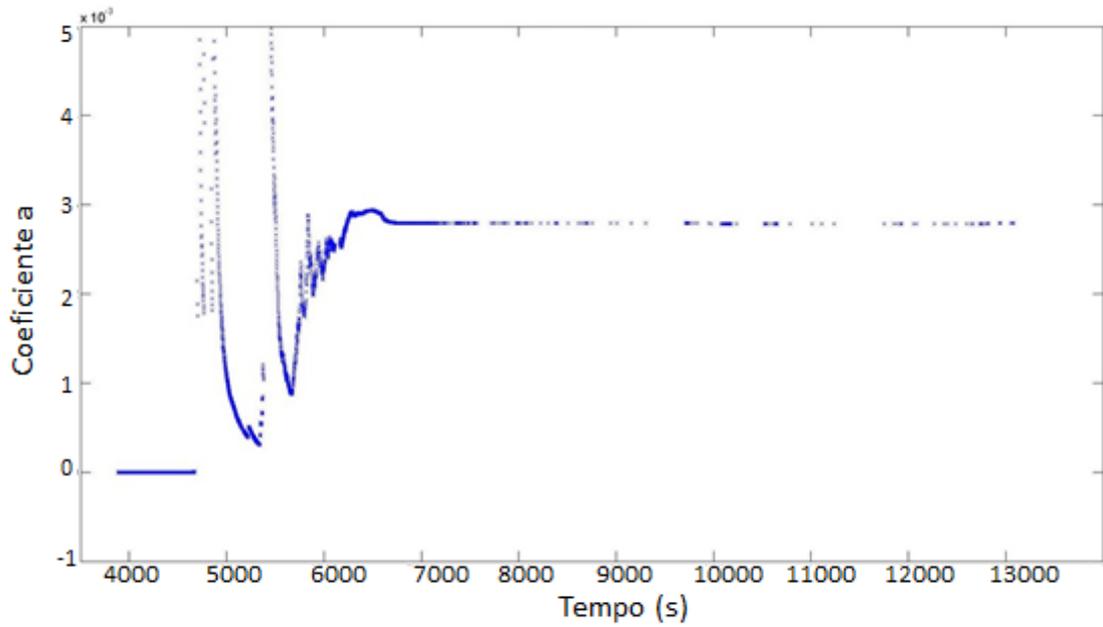


Figura 42 - Evolução do coeficiente “a” da equação de aproximação da curva de possibilidade da classe SP.

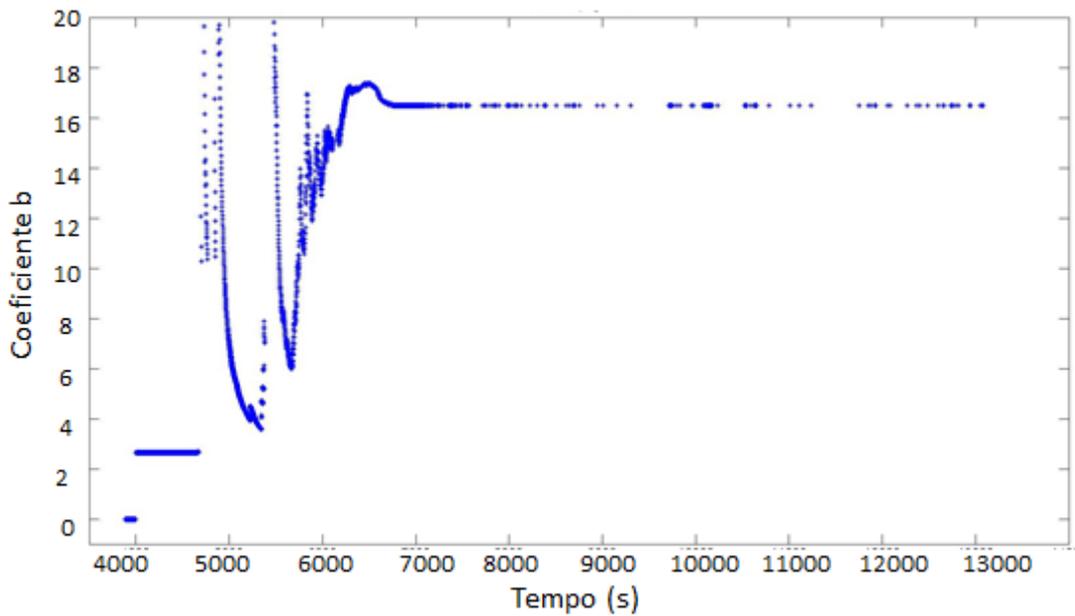


Figura 43 - Evolução do coeficiente "b" da equação de aproximação da curva de possibilidade da classe SP.

A curvas de possibilidades da classe de PE, figura 44 inicialmente apresentaram a maior concentração de valores próximos de zero, com o passar do tempo a maior concentração passou para próximo de um, continuando a aumentar o tempo a probabilidade volta a cair. O gráfico apresenta a aproximação da curva para diferentes intervalos de tempo, de acordo com o aumento do tempo de ensaio a curva se aproxima da convergência.

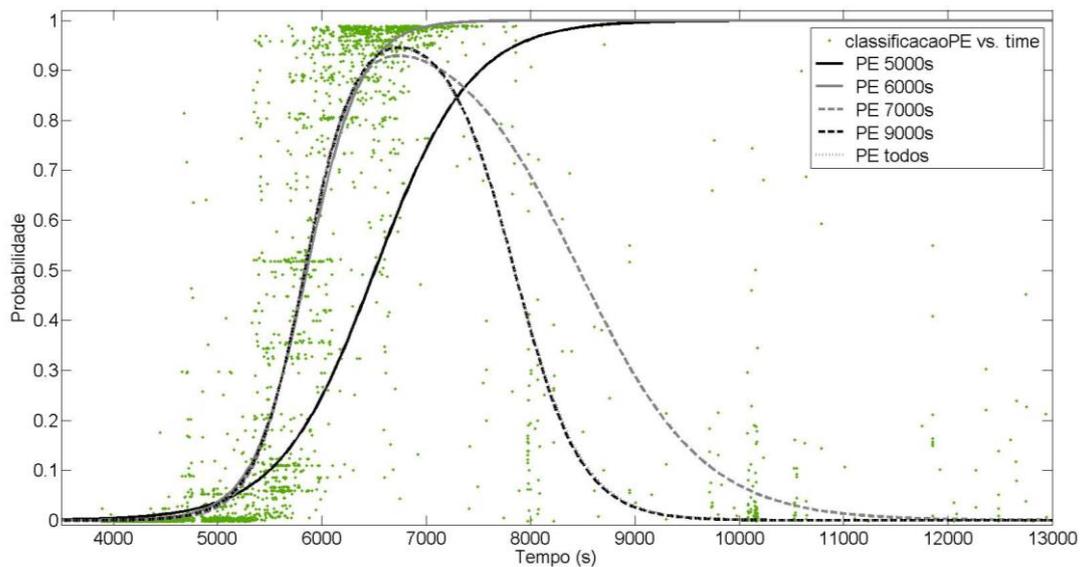


Figura 44- Curvas de Possibilidade da classe PE para o Ensaio 3. Os pontos representam a probabilidade para cada valor de Z. A linha contínua preta representa a curva estimada até 5000 segundos, a linha contínua cinza a curva até 6000s, a linha tracejada cinza a curva até 7000s, a linha tracejada preta a curva até 9000s e a linha pontilhada cinza a curva estimada com todos os sinais do Ensaio 3.

As figuras 45, 46, 47 e 48 apresentam a convergência dos coeficientes “a”, “b”, “c” e “d” da equação 12, página 45, respectivamente.

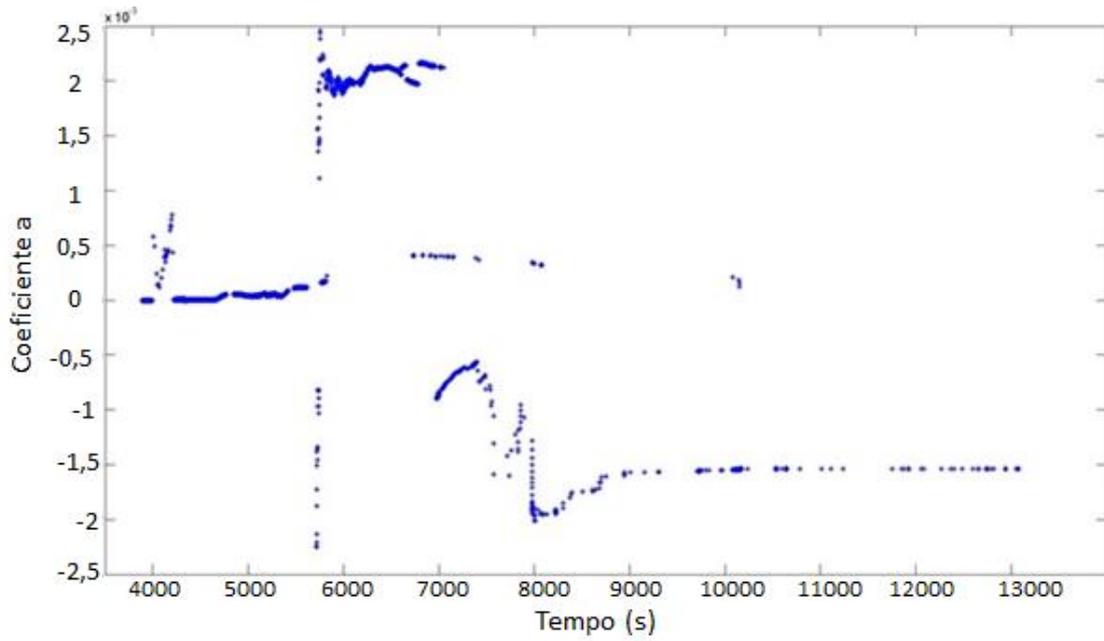


Figura 45 - Evolução do coeficiente “a” da equação de aproximação da curva de possibilidade da classe PE.

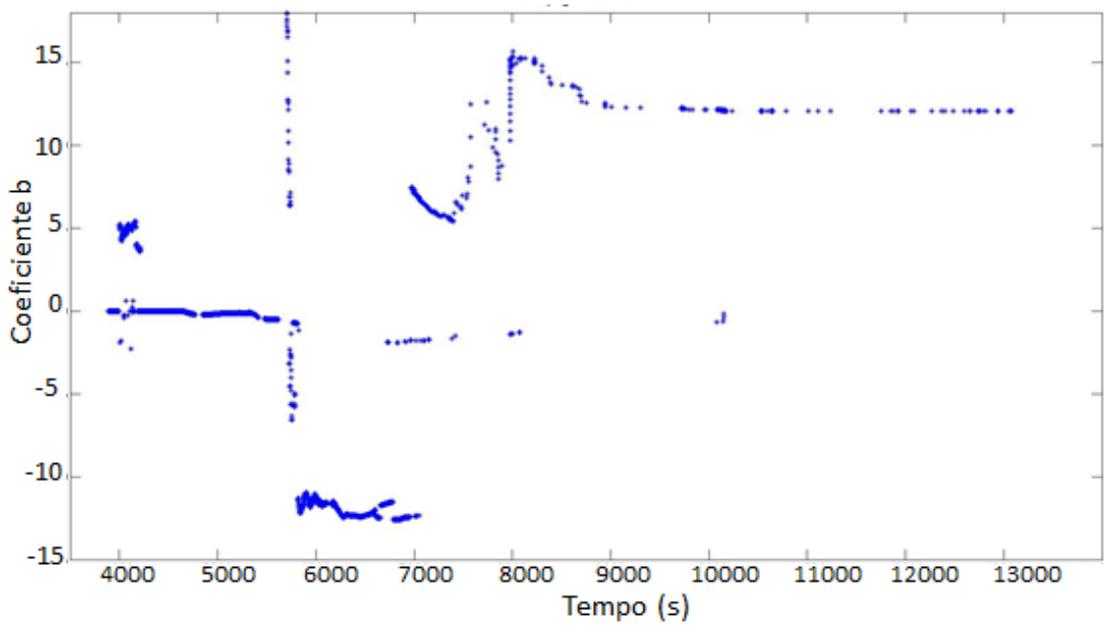


Figura 46 - Evolução do coeficiente “b” da equação de aproximação da curva de possibilidade da classe PE.

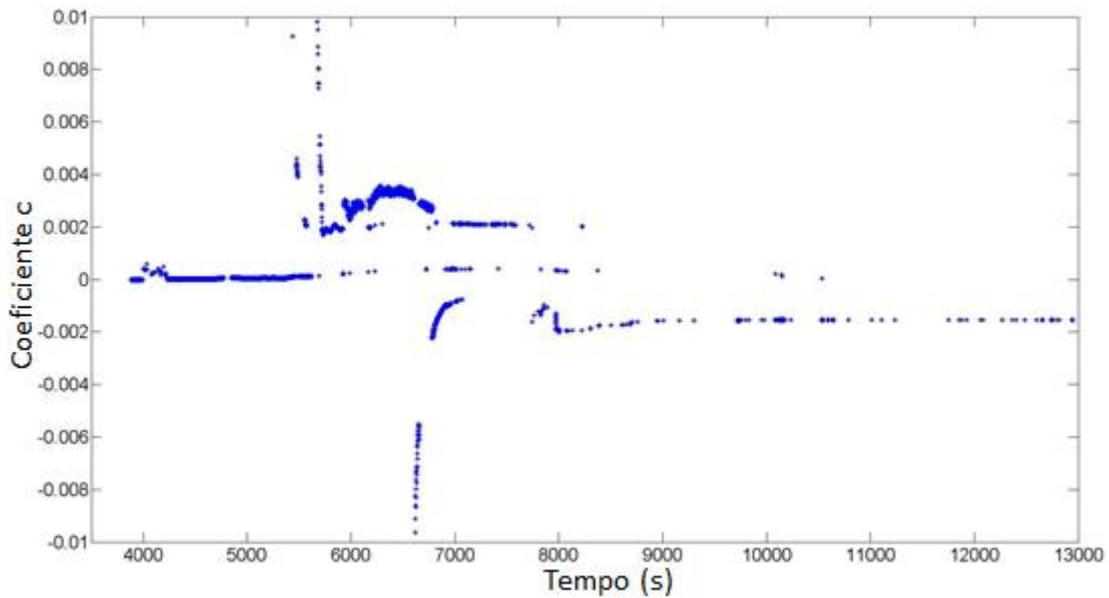


Figura 47 - Evolução do coeficiente “c” da equação de aproximação da curva de possibilidade da classe PE.

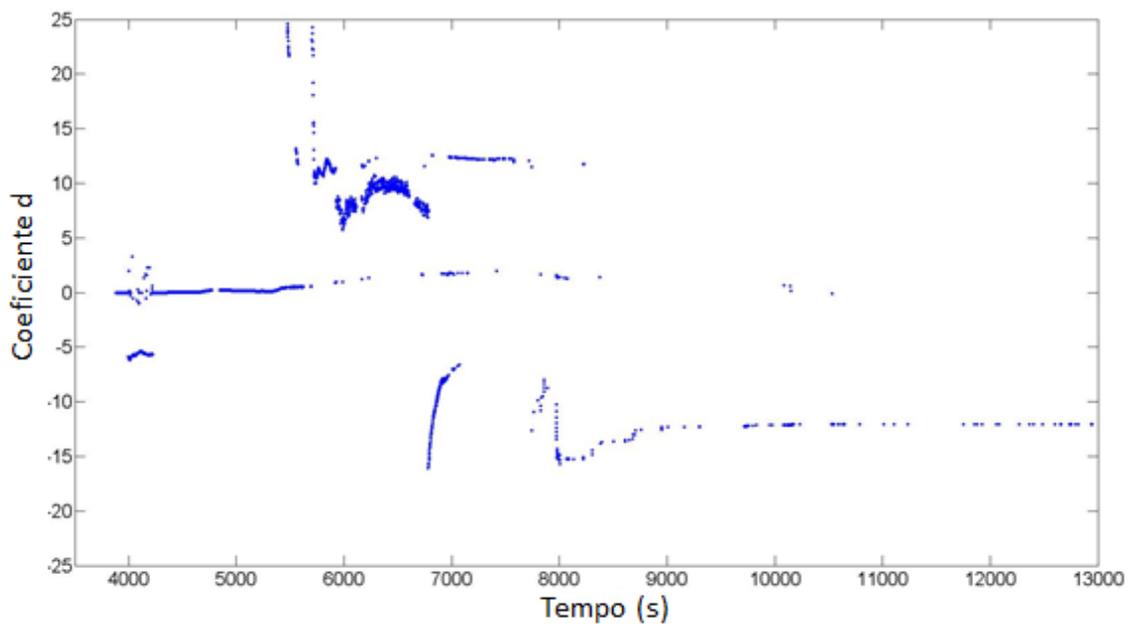


Figura 48 - Evolução do coeficiente “d” da equação de aproximação da curva de possibilidade da classe PE.

Pode ser observado que próximo a 9000 segundos ocorre a convergência de todos os coeficientes, tal fato pode ser comprovado observando na figura 44 a sobreposição das curvas de até 9000 segundos e com todos os sinais.

No gráfico da figura 49, são apresentadas as curvas de Possibilidades da classe PI, novamente como esperado inicialmente a maior concentração de valores iniciais está próxima de zero.

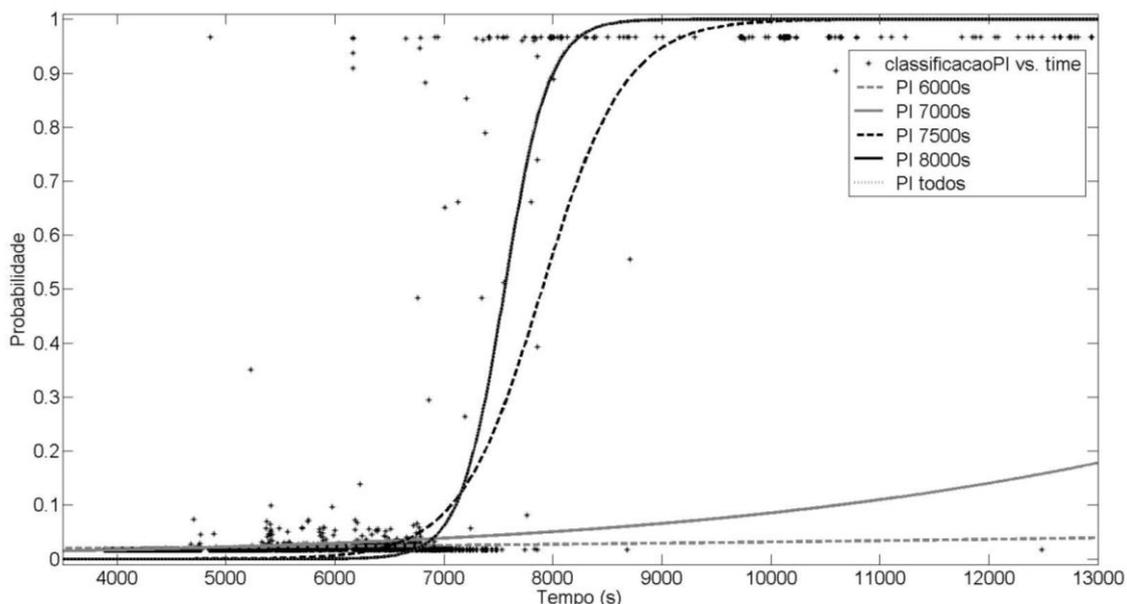


Figura 49 – Curvas de Possibilidade da classe PI. Os pontos representam a probabilidade para cada valor de Z. A linha tracejada cinza representa a curva estimada até 6000 segundos, a linha contínua cinza a curva até 7000s, a linha tracejada preta a curva até 7500s, a linha contínua preta a curva até 8000s e a linha pontilhada cinza a curva estimada com todos os sinais do Ensaio 3.

Próximo a 8000 segundos os valores passam a concentrar-se próximos de um e permanecem neste valor até o fim do ensaio. O gráfico apresenta a aproximação da curva de possibilidade para diferentes intervalos de tempo, de acordo com o aumento do tempo de ensaio a curva se aproxima da convergência.

As figuras 50 e 51 apresentam a convergência dos coeficientes “a” e “b” da equação 13, página 45, respectivamente. Pode ser observado que próximo a 8000 segundos ocorre a convergência de ambos os coeficientes, tal fato pode ser comprovado

observando na figura 49 a sobreposição das curvas de até 8000 segundos e com todos os sinais.

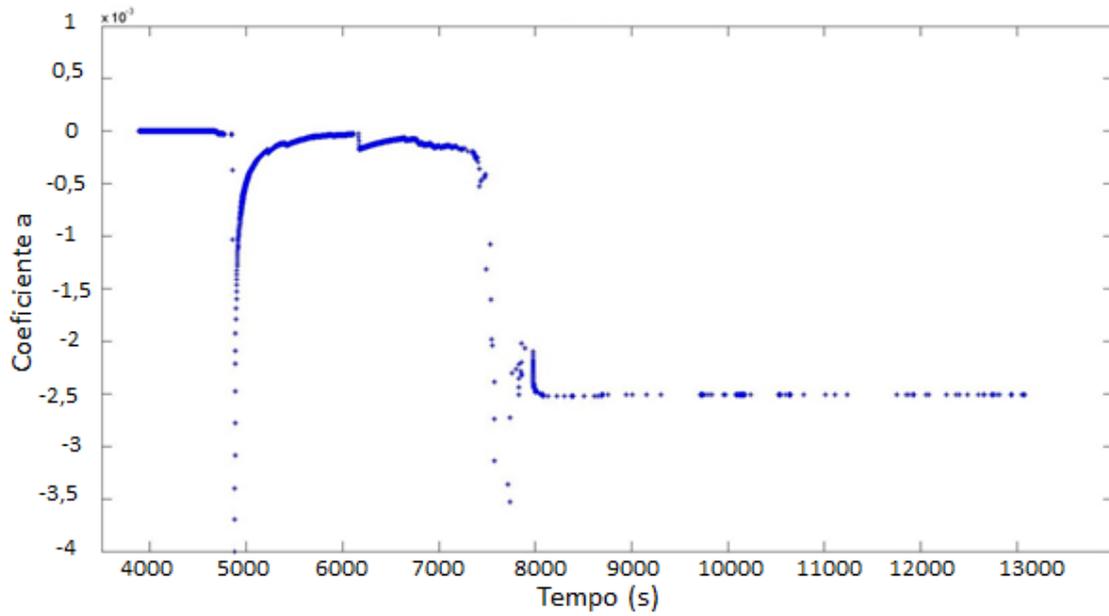


Figura 50 - Evolução do coeficiente “a” da equação de aproximação da curva de possibilidade da classe PI.

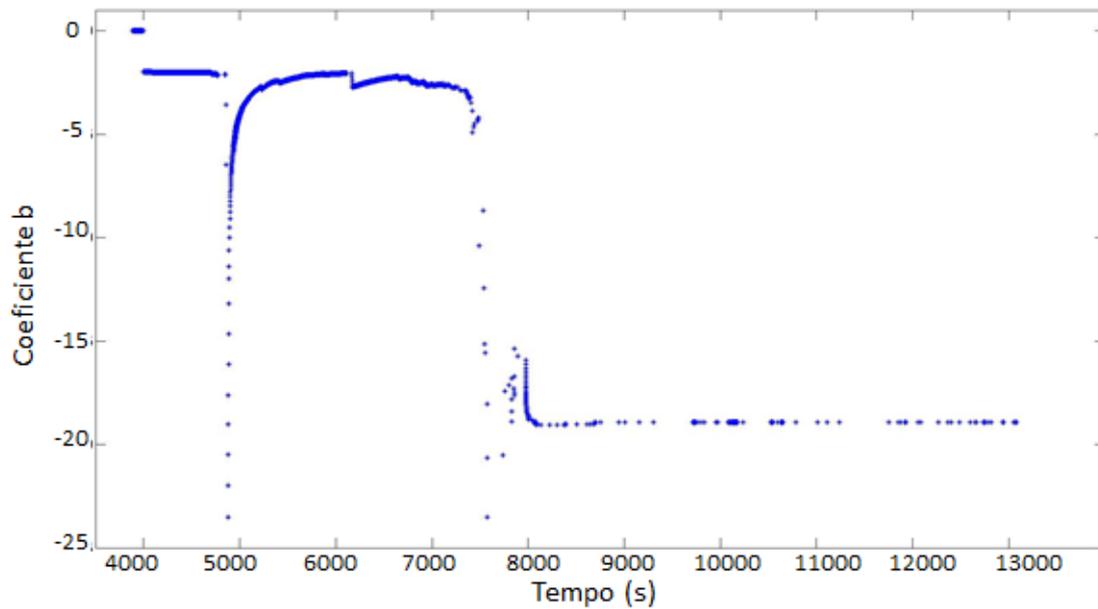


Figura 51 - Evolução do coeficiente “b” da equação de aproximação da curva de possibilidade da classe PI.

Finalmente, plotando as três curvas de possibilidades em um mesmo gráfico se pôde determinar a curva PoP, figura 52.

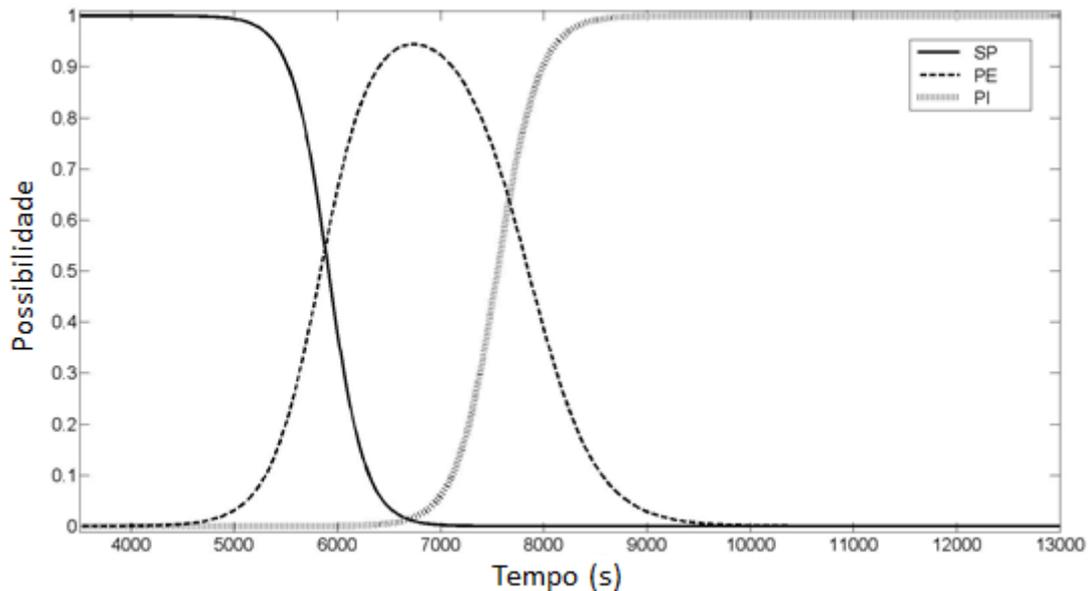


Figura 52 - Curva PoP do Ensaio 3.

Como a curva foi montada a partir do conjunto de dados do Ensaio 3, se sabe que até 6000 segundos os dados são SP, de 6000 até 8000 segundos os dados são PE e a partir de 8000 segundos os dados são PI.

Analisando a curva PoP estimada com os dados até 6000 segundos, figura 53, como era esperado até aproximadamente 6000 segundos o sinal de entrada possui maior possibilidade de ser classificado como SP. Quando chega em 5875 segundos, a possibilidade de ele ser classificado como PE ultrapassa a possibilidade de SP.

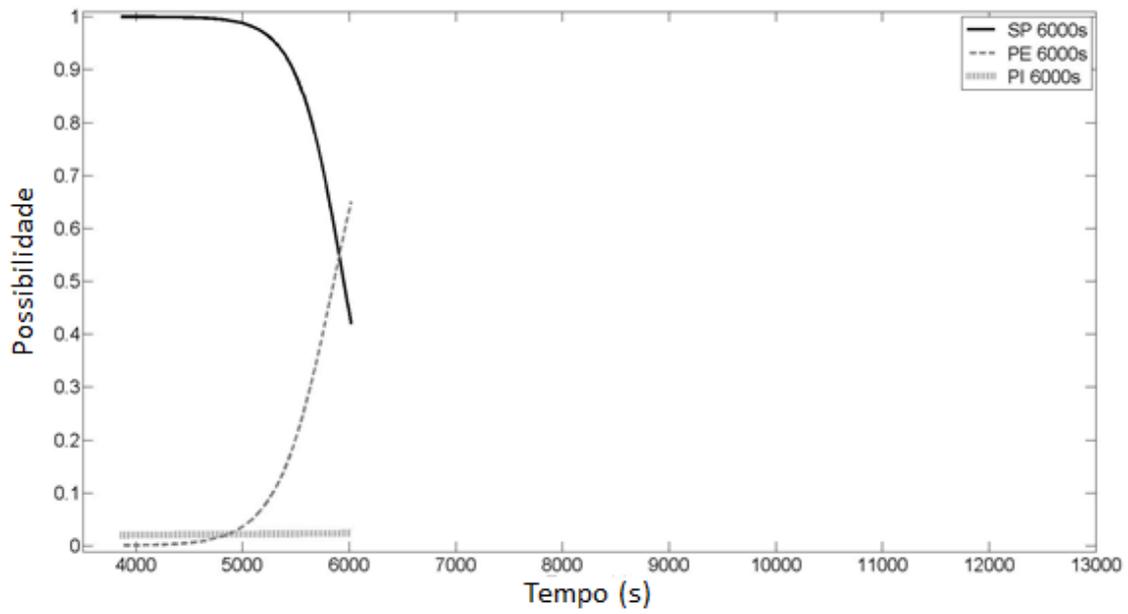


Figura 53 - Curva PoP do Ensaio 3– Curva estimada até 6.000 segundos.

A figura 54 apresenta a curva PoP estimada com os sinais até 8000 segundos.

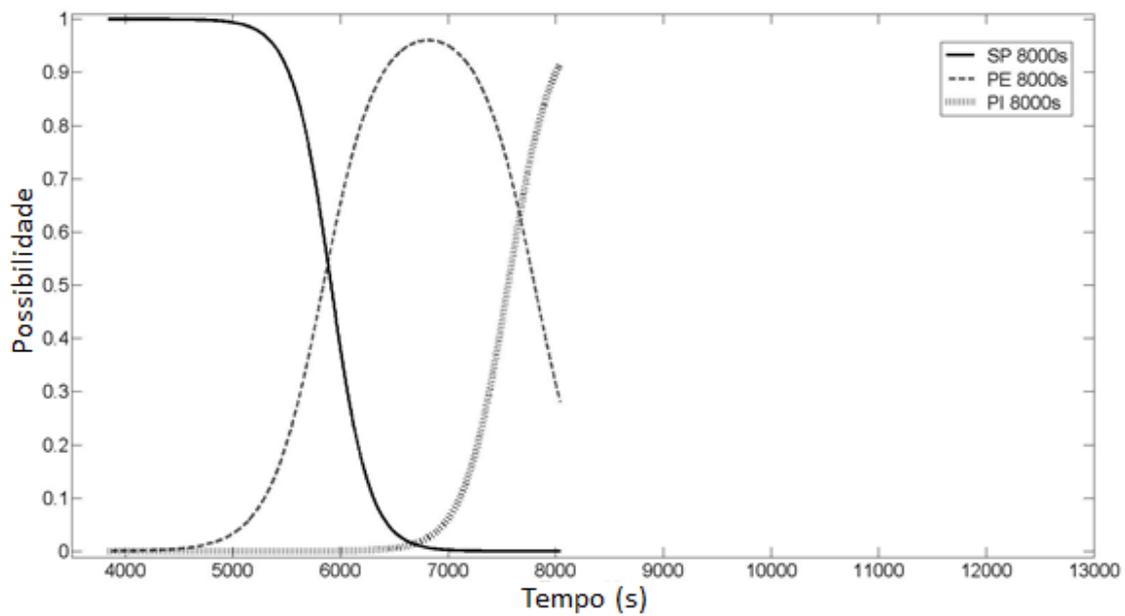


Figura 54 - Curva PoP do Ensaio 3 – Curva estimada com os dados até 8.000 segundos.

Em 6000 segundos, a possibilidade de o sinal ser classificado como PE é a maior dentre as três classes. A partir de 6850 segundos, a possibilidade de PE começa a diminuir e a de PI começa a crescer, em 7640 segundos a possibilidade de PI ultrapassa PE.

Quando o tempo de ensaio chega a 8.000 segundos a possibilidade da entrada ser classificada como PI é maior que 0,9, enquanto de ser PE é aproximadamente 0,25 e de ser SP é de quase zero.

Para ratificar a reprodutibilidade do método, o mesmo procedimento foi aplicado a um ensaio diferente, o Ensaio 2. E a tabela 24 apresenta as equações utilizadas para encontrar a probabilidade para cada valor de Z e a curva PoP obtida a partir destes valores é apresentada na figura 55.

Tabela 24 - Equações de regressão tangente hiperbólica de Ensaio 2.

Classe	Equação	
SP	$P_{SP}(t) = 0.4764 \times \tanh(0.9566 \times Z_{SP}(t) + 0.788) + 0.4984$	(17)
PE	$P_{PE}(t) = 0.4541 \times \tanh(0.6761 \times Z_{PE}(t) + 0.6295) + 0.5584$	(18)
PI	$P_{PI}(t) = 0.4657 \times \tanh(0.653 \times Z_{PI}(t) - 0.5569) + 0.5229$	(19)

De acordo com o descrito na seção 5.1.2, até 6870 segundos o sinal de entrada é classificado como SP, de 6870 até 8144s é classificado como PE, a partir de 8144s sua classificação passa a ser PI.

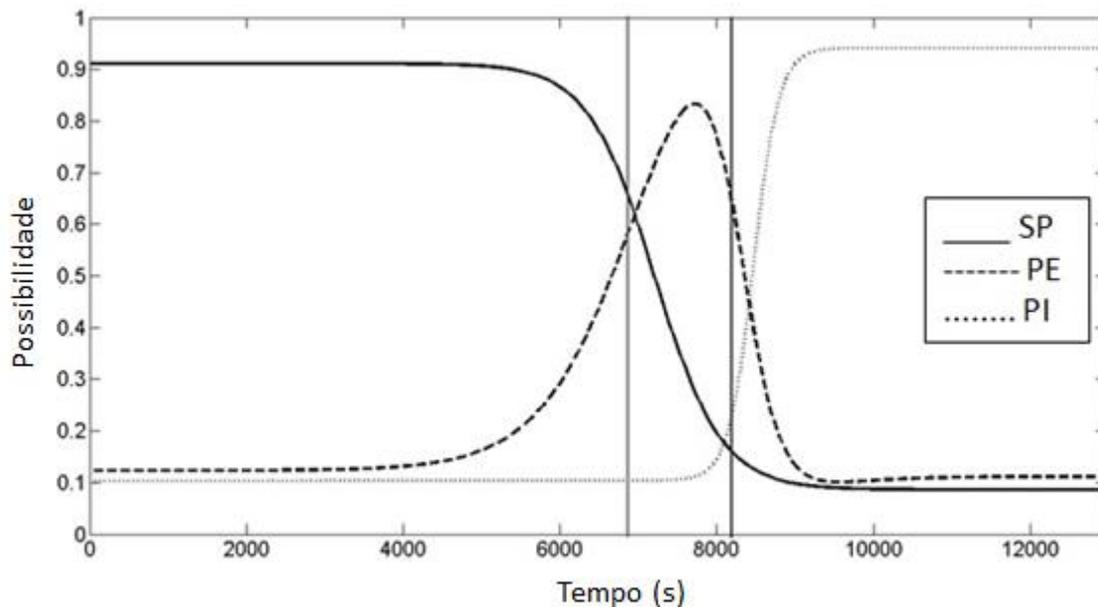


Figura 55 - Curva PoP –Ensaio 2 – separação das classes.

Analisando a figura 55, observa-se, como esperado, que a classe SP possui maior índice de possibilidade no início do ensaio, sendo este ultrapassado pelo valor da possibilidade de PE em 6957s, oitenta e sete segundos após ocorrer à transição da classe SP para a PE.

Enquanto a classe SP se manteve estável em 0,1, na transição da classe PE para a PI, a possibilidade de o sinal pertencer à classe PE ainda é maior, mas já está em declínio enquanto o índice de possibilidade da classe PI está em ascendência. A possibilidade de PI ultrapassa o valor de PE em 8144 segundos, isto é, com um atraso de 270s.

Definindo os atrasos como erro de classificação, se tem  $ERRO_{SP/PE}$  como sendo o erro da razão do tempo de atraso da transição de SP para PE pelo tempo total do ensaio e  $ERRO_{PE/PI}$  como sendo o erro da razão do tempo de atraso da transição de PE para PI pelo tempo total do ensaio, de acordo com a tabela 25. Os erros apresentados demonstram que a transição de classes apresentada pela curva PoP está muito próxima da transição real conhecida.

Tabela 25 - Tabela de erros de classificação percentual.

ERRO <sub>SP/PE</sub>	2.1%
ERRO <sub>PE/PI</sub>	0.68%

Como discussão final, destaca-se que o momento crucial de propagação está situado no limiar de transição entre as classes PE e PI, uma vez que o desejável é prever com antecedência a entrada no regime de propagação instável do defeito (ou propagação plástica). A figura 56, apresenta a curva PoP do Ensaio 3 estimada com os sinais adquiridos até 7500 segundos de ensaio.

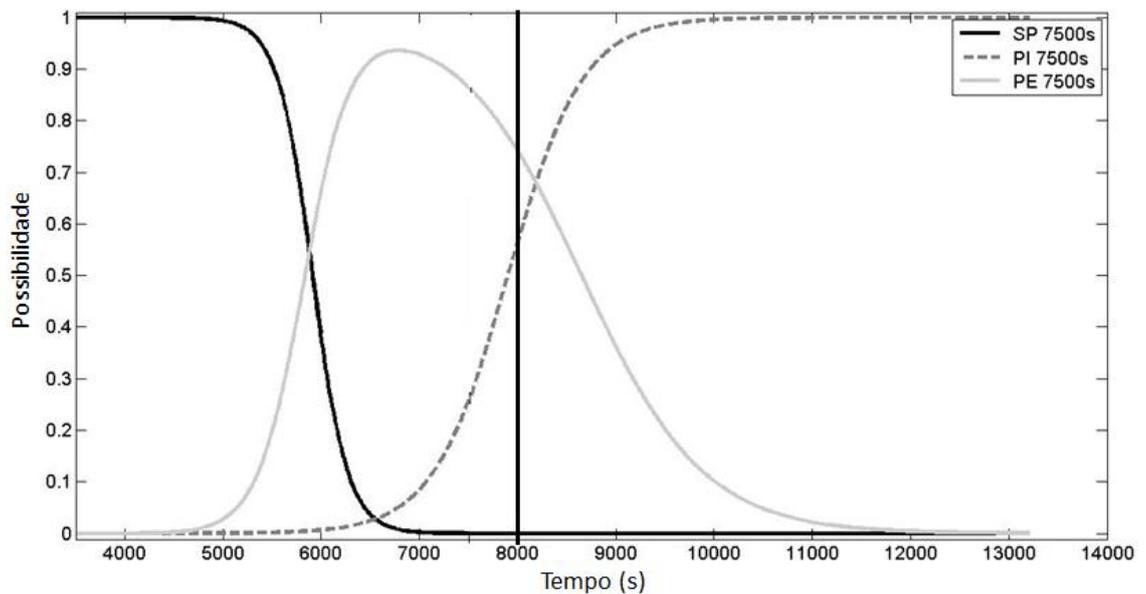


Figura 56 – Curva PoP do Ensaio 3 estimada até 7500 segundos.

Como já descrito na seção 5.1.2 o limiar de separação entre a classe PE e PI ocorre em 8000 segundos, ao analisar a curva construída, se observa que neste instante a curva PoP indica que a possibilidade do sinal ser PE é de aproximadamente 0,6 e de ser PI pouca mais que 0,7. Isto é, 500 segundos antes, da transição entre as classes, a curva consegue

indicar aproximadamente o limiar de transição e o momento em que a pressão no duto deve ser aliviada.

## 5.3 Análise de Agrupamentos dos Sinais de EA

Esta seção apresenta os resultados da classificação não supervisionada utilizando as técnicas de SOM e *K-means*. Os dados utilizados são os sinais de EA provenientes do Ensaio 3.

### 5.3.1 Primeiro Passo

Inicialmente, os parâmetros foram ajustados de acordo com o recomendado por HAYKIN (1999) e após sucessivos treinamentos modificados para a configuração final apresentada na tabela 26.

Tabela 26 - Parâmetros de construção do SOM. Os valores foram determinados empiricamente.

<b>Topologia</b>	Hexagonal
<b>Dimensões</b>	[10 10]
<b>Função de Distância</b>	Euclidiana
<b>Número inicial de vizinhos</b>	600
<b>Total de passos na fase de ordenação</b>	5000
<b>Total de passos na fase de convergência</b>	5000

A figura 57 apresenta o mapa de distâncias, os hexágonos representam os neurônios, as linhas representam as conexões com os neurônios vizinhos e as cores entre os neurônios as distâncias euclidianas entre si. A escala de cor varia de preto ao amarelo, onde quanto mais escuro maior a distância e quanto mais clara menor distância entre os neurônios.

Analisando o mapa de distâncias, é possível distinguir três regiões. A região 1 em amarelo claro demonstra neurônios muito próximos, entre a região 1 e 2 é identificada uma fronteira com neurônios mais distantes. As cores da região 3 indicam que os neurônios estão dispersos no espaço.

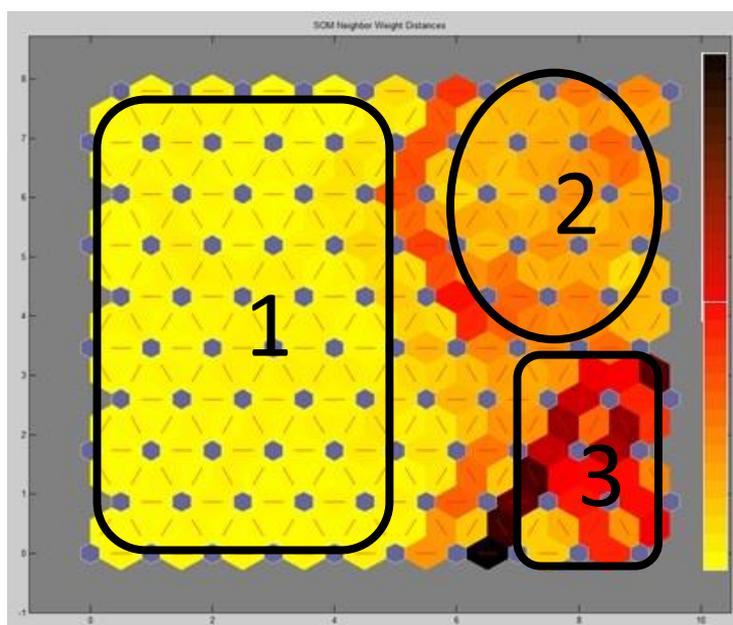


Figura 57 - Mapa de distâncias do Ensaio 3.

Buscando identificar a relação entre as regiões identificadas e as classes pré-definidas, uma diferente visualização para o mapa é desenvolvida e apresentada na figura 58. Nesta, cada hexágono representa um neurônio e o tamanho deste está diretamente relacionado com a quantidade de ativações recebidas.

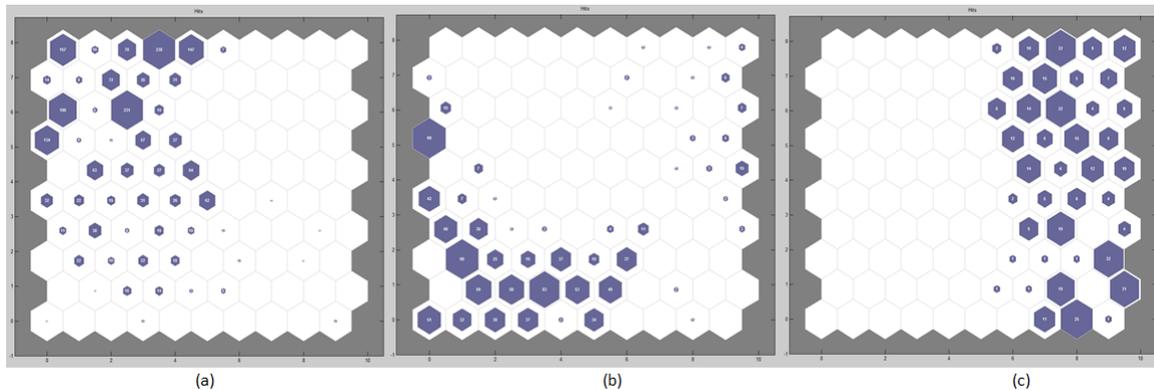


Figura 58 - Mapa das ativações dos neurônios. (a) ativação da classe SP. (b) ativação para classe PE. (c) ativação para classe PI.

Ao analisar a figura 58, é possível observar que os elementos da classe SP e PE estão em sua maioria na região 1 e os elementos da classe PI estão separados nas regiões 2 e 3. Pode-se verificar também que existem neurônios que são ativados por classes diferentes e que elementos das classes SP e PE ativam neurônios nas regiões 2 e 3. Este resultado indica que o limiar de separação entre as classes SP e PE é muito próximo e que a classe PI é facilmente distinguível das demais, contudo é representada por dois fenômenos distintos.

## 5.3.2 Segundo Passo

Os resultados obtidos na seção 5.3.1 indicam que as classes pré-definidas podem conter elementos não pertencentes à mesma. Objetivando eliminá-los, foi realizado o agrupamento por meio do algoritmo *K-means*. Os parâmetros ajustados são apresentados na tabela 27. Vale ressaltar que a quantidade de centros, isto é, a quantidade de agrupamentos, foi determinada a partir dos resultados apresentados no passo 1, os quais indicaram três regiões de separação no conjunto de dados.

Tabela 27 - Parâmetros de treinamento algoritmo *K-means*.

<b>Medida de distância</b>	Euclidiana
<b>Número de inicializações aleatórias dos centros</b>	100
<b>Número de centros</b>	3

A tabela de confusão é apresentada a seguir (tabela 28). As colunas indicam o agrupamento formado pelo algoritmo e as linhas são as classes previamente conhecidas do Ensaio 3.

Tabela 28 - Tabela Confusão.

	<b>Grupo 1</b>	<b>Grupo 2</b>	<b>Grupo 3</b>
<b>Classe SP</b>	100%	0%	-
<b>Classe PE</b>	95%	0%	5%
<b>Classe PI</b>	11%	26%	63%

A tabela 28, mostra que em um mesmo agrupamento (grupo 1) existe a maior concentração de elementos de duas classes, SP e PE, e a classe PI está mais concentrada em dois agrupamentos diferentes. Pelo exposto, um novo conjunto de dados para a criação de um classificador supervisionado foi proposto com os padrões em destaque da tabela 28, o qual foi denominado “Conjunto 1”.

A figura 59 apresenta um esquema detalhado do procedimento descrito. O grupo 1 contém apenas elementos das classes SP e PE e os grupos 2 e 3 apenas elementos da classe PI.

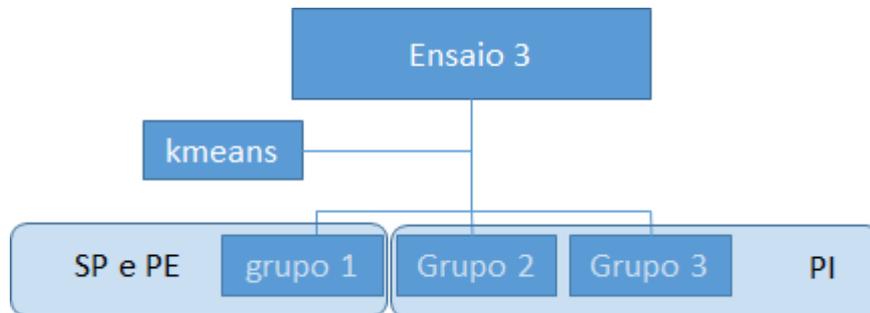


Figura 59 - Fluxograma da formação do novo conjunto de treinamento formado com os dados do Ensaio 3 da rede neural de múltiplas camadas.

As tabelas 29 e 30 apresentam os resultados obtidos do classificador treinado com os dados de Conjunto 1 e com os dados originais do Ensaio 3. Os parâmetros de treinamento são os mesmos empregados na seção 5.1.3.

Tabela 29 – Resultados da acurácia média para 10 conjuntos de treino e teste formados com os dados de Conjunto 1. NC – não classificado.

	Conjunto de Treino					Conjunto de Teste			
	SP	PE	PI	NC		SP	PE	PI	NC
<b>SP</b>	94%	6%	-	0%	SP	94%	6%	-	0%
<b>PE</b>	10%	90%	-		PE	8%	92%	-	
<b>PI</b>	-	-	100%		PI	-	-	100%	
<b>ACERTOS</b>	93%				94%				

Tabela 30 - Resultado da acurácia média para 10 conjuntos de treino e teste com os dados do Ensaio 3. NC – não classificado.

	Conjunto de Treino					Conjunto de Teste			
	SP	PE	PI	NC		SP	PE	PI	NC
<b>SP</b>	92%	6%	0%	0%	SP	93%	6%	0%	0%
<b>PE</b>	10%	87%	4%		PE	9%	84%	4%	
<b>PI</b>	1%	4%	95%		PI	1%	8%	91%	
<b>Média Total de acertos</b>	91%				91%				

Os resultados obtidos demonstram um aumento em 2% na acurácia para dados de treino e 3% para dados de teste em relação aos dados originais do Ensaio 3 confirmando que os dados excluídos estavam prejudicando a performance do classificador.

Estes resultados induzem a tentativa de separação dos dados presentes no Grupo 1 em destaque da tabela 28. Posteriormente, o algoritmo *K-means* foi novamente aplicado, mas desta vez apenas nestes dados. A figura 60 ilustra este novo passo.

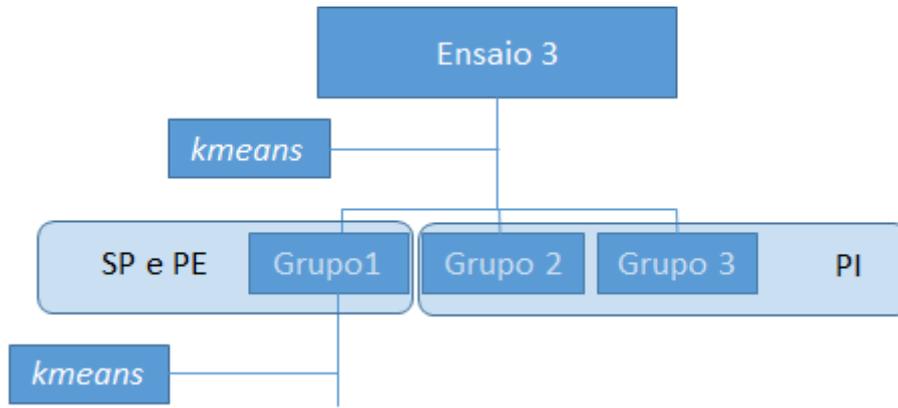


Figura 60 – Algoritmo *K-means* aplicado ao Grupo 1.

Com o objetivo de determinar a quantidade ótima de grupos, o agrupamento foi realizado para *K* variando de 2 a 5. Os resultados são apresentados nas tabelas 31, 32, 33 e 34, respectivamente.

Tabela 31 - Tabela confusão para *K*=2.

	<b>Grupo a</b>	<b>Grupo b</b>
<b>Classe SP</b>	68%	32%
<b>Classe PE</b>	0%	100%

Tabela 32 - Tabela confusão para *K*=3.

	<b>Grupo a</b>	<b>Grupo b</b>	<b>Grupo c</b>
<b>Classe SP</b>	1%	31%	68%
<b>Classe PE</b>	58%	42%	-

Tabela 33 - Tabela confusão para K=4.

	<b>Grupo a</b>	<b>Grupo b</b>	<b>Grupo c</b>	<b>Grupo d</b>
<b>Classe SP</b>	0%	68%	1%	31%
<b>Classe PE</b>	2%	-	60%	38%

Tabela 34 - Tabela confusão para K=5.

	<b>Grupo a</b>	<b>Grupo b</b>	<b>Grupo c</b>	<b>Grupo d</b>	<b>Grupo e</b>
<b>Classe SP</b>	38%	31%	0%	30%	1%
<b>Classe PE</b>	0%	38%	2%	-	60%

Os resultados apresentados não apontam evolução do agrupamento com K=4 para K=5. Para definir a quantidade de grupos existentes no conjunto de dados é utilizado o coeficiente de silhueta (TAN, 2005), a figura 61 apresenta o coeficiente de cada grupo encontrado para os diferentes valores de K.

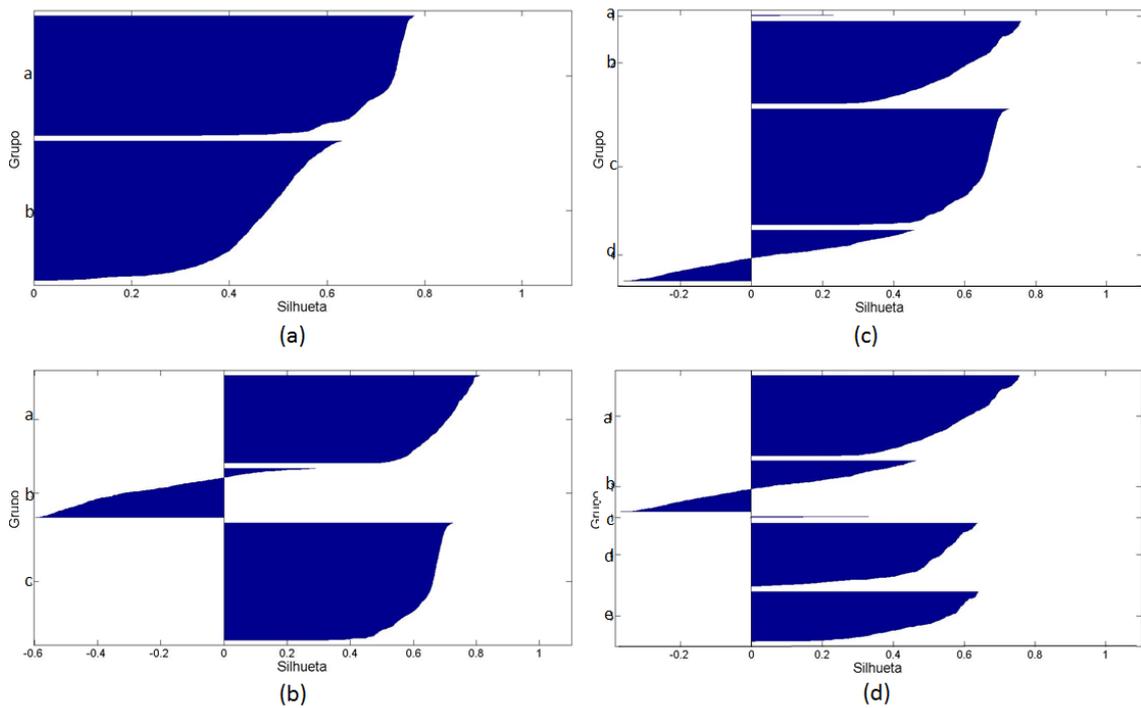


Figura 61 – Coeficiente de Silhueta dos grupos formados com os dados do Conjunto 1. (a) Silhueta para K=2; (b) Silhueta para K=3; (c) Silhueta para K=4; (d) Silhueta para K=5.

Analisando a figura 61, observa-se a presença de valores negativos de silhueta para K=3, K=4 e K=5, indicando que estes grupos não foram separados adequadamente. Para realizar uma análise mais quantitativa foi realizado a curva dos coeficientes médios das silhuetas, figura 63.

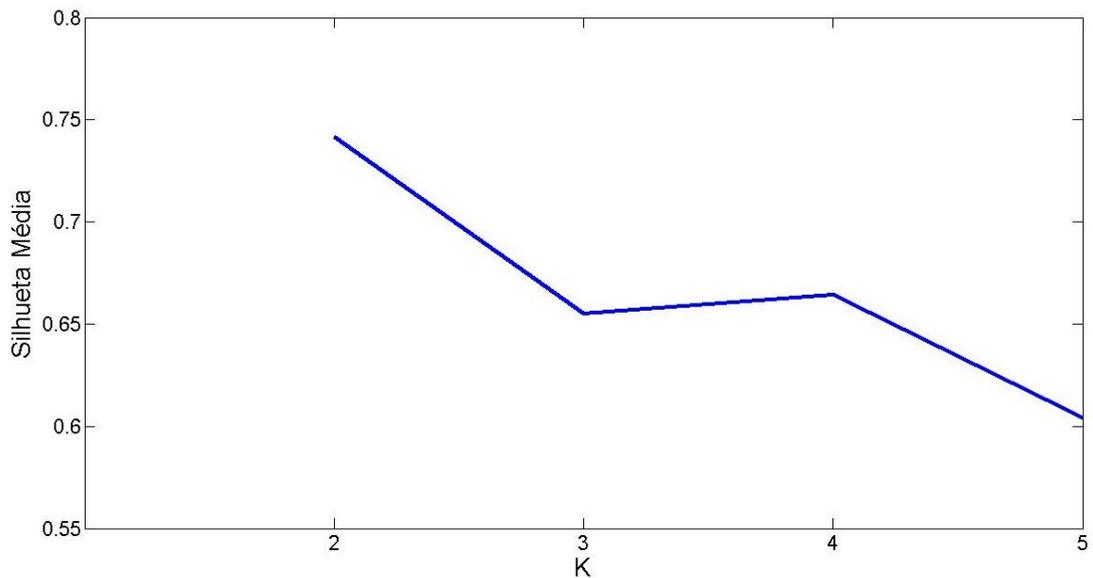


Figura 62 – Curva da Silhueta Média dos Agrupamentos formados. No eixo vertical o valor da Silhueta e no eixo horizontal os valores de K.

Analisando os resultados da figura 62 a melhor separação para o conjunto de dados é para  $K = 2$ , contudo o Grupo b da tabela 31 ainda está com muitos dados de SP e PE misturados. Entre os demais valores de K, o que apresenta a maior silhueta média é  $K=4$ .

O Grupo d da tabela 33 apresenta grande concentração de elementos de ambas as classes e valores negativos do coeficiente de silhueta (figura 61-c), objetivando a separação destes, o algoritmo de *K-means* foi novamente aplicado aos dados em destaque. A figura 63 apresenta o esquema desta nova separação.

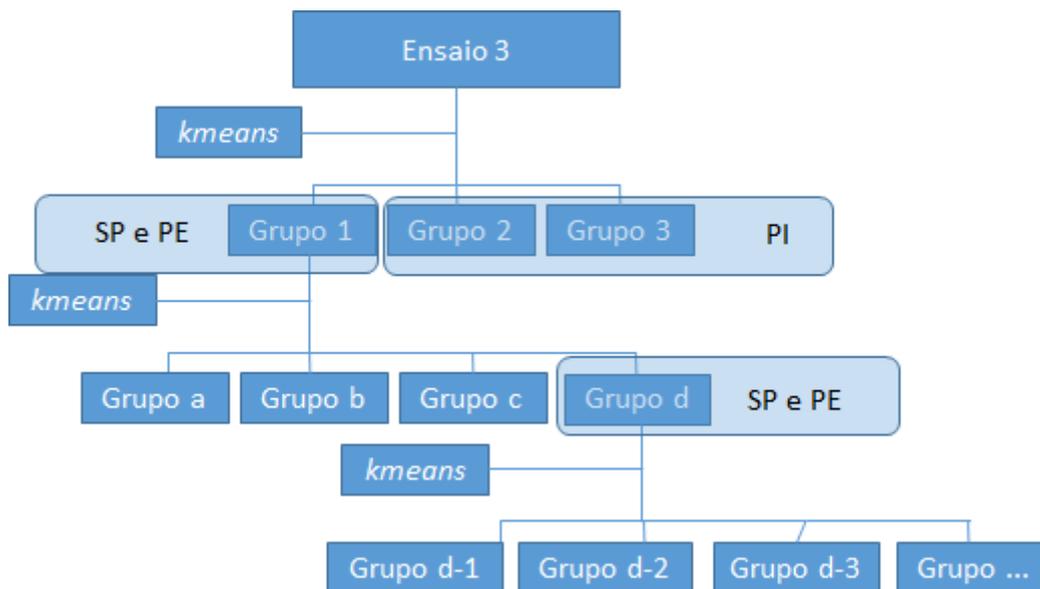


Figura 63 – Algoritmo K-means aplicado ao grupo d.

Novamente, são realizados agrupamentos para valores de K de 2 a 5, os resultados são apresentados nas tabelas 35, 36, 37 e 38.

Tabela 35 - Tabela confusão para K=2.

	<b>Grupo d-1</b>	<b>Grupo d-2</b>
<b>Classe SP</b>	22%	78%
<b>Classe PE</b>	29%	71%

Tabela 36 - Tabela confusão para K=3.

	<b>Grupo d-1</b>	<b>Grupo d-2</b>	<b>Grupo d-3</b>
<b>Classe SP</b>	29%	50%	21%
<b>Classe PE</b>	50%	21%	29%

Tabela 37 - Tabela confusão para K=4.

	<b>Grupo d-1</b>	<b>Grupo d-2</b>	<b>Grupo d-3</b>	<b>Grupo d-4</b>
<b>Classe SP</b>	3%	28%	21%	48%
<b>Classe PE</b>	-	50%	29%	21%

Tabela 38 – Tabela confusão para K=5.

	<b>Grupo d-1</b>	<b>Grupo d-2</b>	<b>Grupo d-3</b>	<b>Grupo d-4</b>	<b>Grupo d-5</b>
<b>Classe SP</b>	29%	0%	1%	49%	21%
<b>Classe PE</b>	50%	-	5%	21%	24%

Os resultados apresentados demonstraram que os dados do grupo d da tabela 33 não são passíveis de separação e, desta forma, os mesmos foram eliminados no novo conjunto formado.

O esquema da figura 64 apresenta o processo de formação do novo conjunto de dados denominado Conjunto 2. A tabela 39 detalha este conjunto.

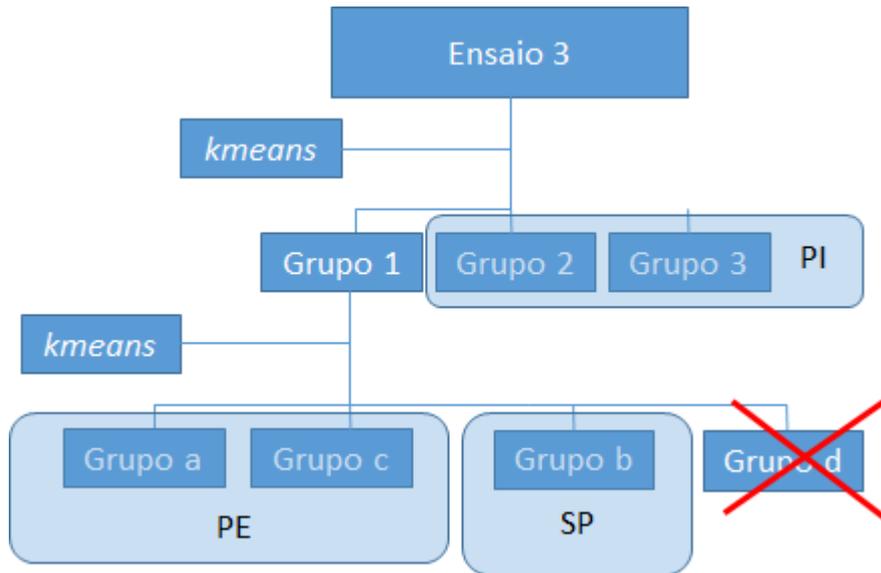


Figura 64 - Fluxograma de formação do Conjunto 2, a partir dos dados do Ensaio 3.

Tabela 39 – Tabela confusão do fluxograma apresentado na figura 60. Em destaque os dados formadores do Conjunto 2.

	Grupo 1				Grupo 2	Grupo 3
	Grupo a	Grupo b	Grupo c	Grupo d		
Classe SP	0%	68%	1%	30%	0%	-
Classe PE	1%	-	57%	36%	0%	5%
Classe PI	11%				26%	63%

## 5.3.3 Terceiro Passo

Com o novo conjunto de dados formados na seção 5.3.2, Conjunto 2, um novo classificador supervisionado foi desenvolvido com os mesmos parâmetros definidos na seção 5.1.3 e seus resultados são apresentados na tabela 40.

Tabela 40 - Resultados da acurácia média para 10 conjuntos de treino e teste formados com os dados de Conjunto 2. NC – não classificado.

	Conjunto de Treino					Conjunto de Teste				
	SP	PE	PI	NC		SP	PE	PI	NC	
SP	100%	-	-	-	SP	100%	-	-	-	
PE	-	100%	-		PE	-	98%	2%		
PI	-	-	100%		PI	-	-	100%		
Media Total acertos	100%				Media Total acertos	100%				

Os resultados demonstram uma evolução de acerto de aproximadamente 9%, quando comparado com os resultados da tabela 22, seção 5.1.3. Conclui-se que os dados do Conjunto 2 possuem características discriminatórias acentuadas de cada uma das classes.

Com o objetivo de visualizar o arranjo dos dados de Conjunto 2 e sua relação com as classes previamente divididas, um novo SOM foi treinado. A figura 65 apresenta o mapa das distâncias entre os neurônios.

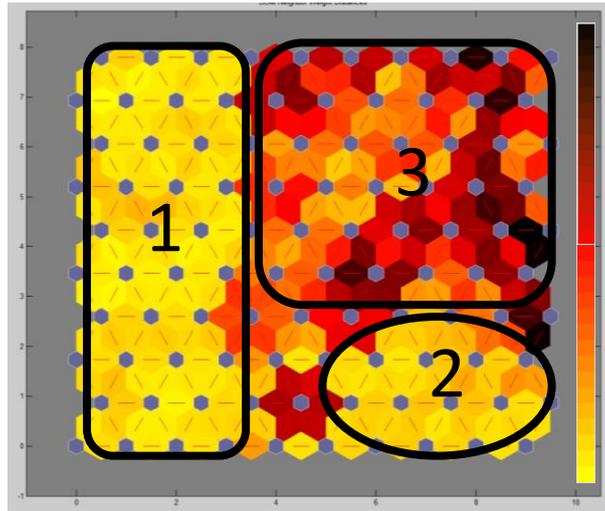


Figura 65 - Mapa das distâncias dos dados do Conjunto 2.

Ao observar o mapa, mais uma vez é evidente a presença de três regiões. As regiões 1 e 2 formadas por elementos muito próximos, e a região 3 formada por elementos dispersos. A fim de visualizar a relação entre as classes predefinidas e as regiões mostradas no mapa de distâncias, os mapas de ativação para cada classe foram criados, figura 66.

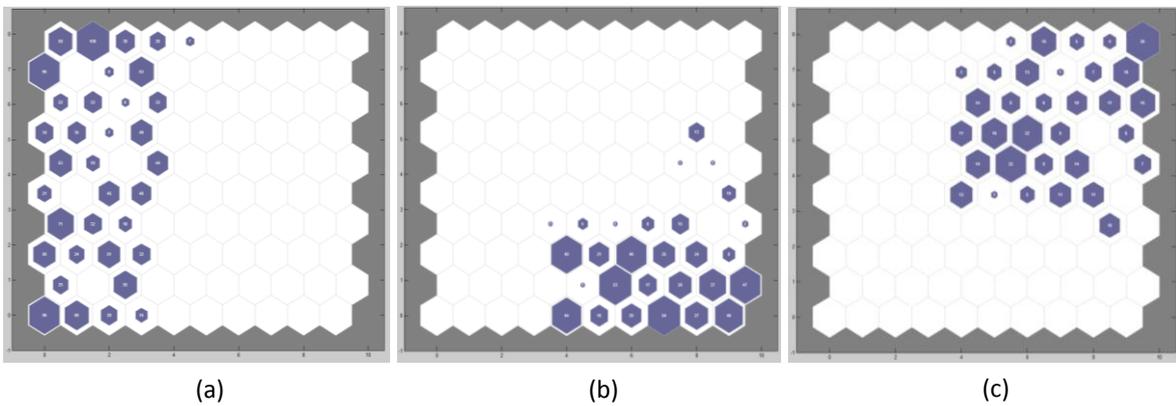


Figura 66 – Conjunto 2 - Mapa das ativações dos neurônios. (a) ativação da classe SP. (b) ativação para classe PE. (c) ativação para classe PI

Ao observar o novo mapa criado, percebe-se que as regiões definidas no mapa de distâncias estão diretamente relacionadas às classes pré-definidas. A região 1 é composta por elementos da classe SP, com exceção de 4 neurônios, a região 2 é composta de elementos da classe PE e a região 3 de classe PI. Notou-se também que não ocorreu mais a ativação do mesmo neurônio por elementos de classes diferentes.

Para avaliar o comportamento do classificador treinado em relação aos dados excluídos, foi aplicado ao classificador os dados do Ensaio 3. A tabela 41 apresenta os resultados obtidos.

Tabela 41 – Tabela confusão dos dados de Ensaio 3 aplicados ao classificador treinado com os dados do Conjunto 2. NC – não classificado

	Ensaio 3			
	SP	PE	PI	NC
SP	67%	31%	1%	0%
PE	0%	95%	5%	
PI	1%	4%	95%	
Média Total de acertos	79%			

Neste resultado, fica evidente que os dados eliminados confundem o classificador, já que o mesmo não é capaz de diferenciá-los, principalmente SP e PE. Para avaliar a posição em relação ao tempo dos elementos do Conjunto 2 e os dados excluídos do Ensaio 3, é realizado um gráfico dos elementos de cada classe em relação ao tempo, figura 67. As classes são apresentadas no eixo vertical e o tempo de ensaio no eixo horizontal.

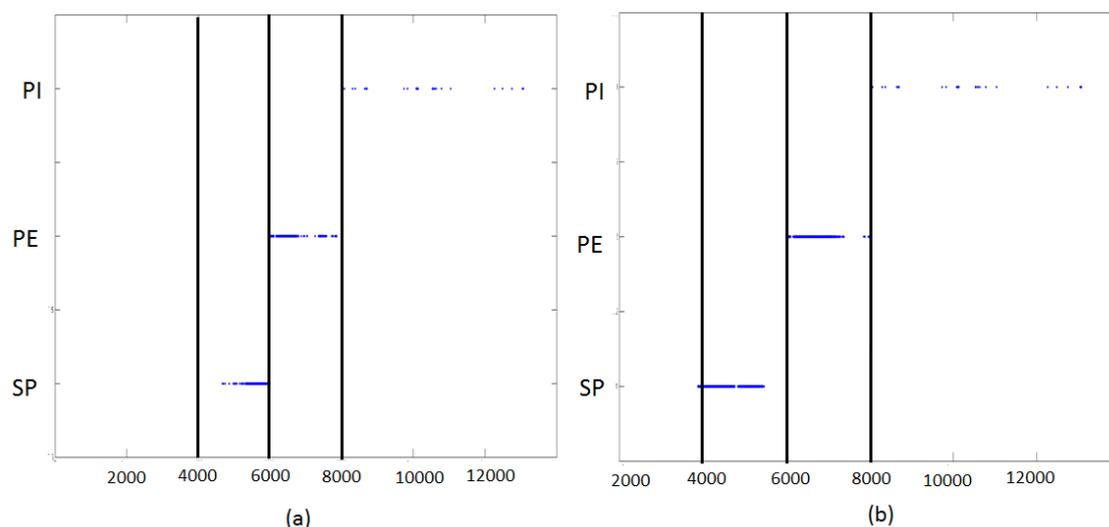


Figura 67 - gráfico de classes em relação ao tempo de ensaio. (a) dados excluídos do Ensaio 3. (b) Conjunto 2.

A figura 67, demonstra que existe sobreposição entre os dados excluídos e Conjunto 2, contudo é observado também regiões próximas ao limiar de separação entre as classes, indicando que o momento de transição entre a classe SP e PE escolhido possa estar atrasado.

Para comprovar esta hipótese, um novo conjunto foi formado deslocando o momento de transição da classe PE de 6000 para 5500 segundos. A tabela 42 apresenta os resultados da nova rede treinada.

Tabela 42 - Tabela confusão dos dados do Ensaio 2 com a transição da classe PE de 6000 para 5500 segundos

	Conjunto de Treino			NC		Conjunto de Teste			NC
	SP	PE	PI			SP	PE	PI	
SP	84%	15%	0%	1%	SP	84%	16%	0%	0%
PE	15%	81%	4%		PE	15%	83%	2%	
PI	3%	5%	92%		PI	5%	1%	93%	
Media Total acertos	84%				84%				

Os resultados da tabela 42 demonstram que o desempenho da rede diminuiu quando comparado com os resultados da tabela 22, seção 5.1.3. Tais resultados indicam que a hipótese da transição entre as classes SP e PE terem sido escolhidas de maneira incorreta, não é verdadeira. E a não classificação correta dos dados excluídos é devida as características particular das regiões de transição entre as classes, onde os elementos apresentam padrões de ambas as classes.

## 6 Conclusões

O presente trabalho apresentou uma metodologia inovadora voltada para identificar de forma automática a transição da propagação estável para instável de trincas em dutos rígidos pressurizados e monitorados pelo ensaio de emissão acústica.

O objetivo inicial do trabalho foi realizar uma série de investigações de separação das classes de sinais de emissão acústica para o monitoramento de dutos rígidos, dando continuidade a estudos anteriores (DA SILVA *et al.*, 2006). Até o presente momento tais estudos foram focados principalmente na tentativa de discriminar a classe Sem Propagação (SP) da classe Propagação Instável (PI).

Neste estudo, o classificador atingiu cerca de 91% de acerto total de classificação quando há propagação até rompimento do corpo de prova, índice considerado significativo em função dos poucos parâmetros empregados. Entretanto, a separação entre SP e PE é bem mais complexa que SP e PI e vice-versa, assim como entre PE e PI. Este resultado pode encontrar explicações na pouca diferença que há em termos de fenômeno de Emissão Acústica entre o momento de uma deformação elástica e início de uma deformação plástica. Há de se destacar, porém, que os resultados alcançados neste trabalho são bastante relevantes quando comparados aos anteriores, permitindo um desenvolvimento significativo no embasamento necessário de conhecimento para construção de um sistema artificialmente inteligente de detecção de propagação de defeitos em dutos rígidos.

Com relação a análise de agrupamentos, os resultados demonstraram que nas classes pré-divididas existem elementos que geram erro no treinamento do classificador. A metodologia proposta mostrou-se bastante eficiente no que diz respeito a pré-seleção de

dados, com fortes características discriminatórias entre as classes, para o treinamento do classificador supervisionado, chegando a atingir 100% de acertos em treino e teste na classificação dos sinais de EA. Contudo, não se pode afirmar que os dados excluídos do Ensaio 3 não pertencem a nenhuma das classes. Esta análise, servirá como base de futuros estudos na automatização da análise da curva de propagação da trinca.

Com relação às classes, pode-se confirmar que os sinais da classe SP e PE são muito próximos e que o fenômeno de PI é completamente distinguível dos demais. Conclui-se também que ao ajustar os dados gerando o conjunto 2, as regiões de separação entre as classes ficaram mais nítidas, principalmente entre SP e PE e os elementos internos a cada classe ficaram mais próximos entre si. Os sinais de PI estão mais dispersos no espaço em relação às demais classes evidenciando a característica peculiar do evento.

Com relação à metodologia proposta para a construção da curva PoP, esta se mostrou ser eficiente, pois em ambos os ensaios estudados obteve-se comportamento similar à curva teórica proposta.

Com relação à eficiência da curva PoP, os resultados obtidos são bastante promissores, pois apesar dos limites de transição entre as classes não terem coincidido com os pontos de interseções das curvas, situação ideal, a curva foi capaz de prever o momento de transição entre a classe PE e PI, objetivo principal do estudo, apresentando um erro irrelevante quando comparado com o tempo total de ensaio.

Concluindo, tais resultados demonstram a capacidade de se classificar a propagação das trincas em dutos rígidos e utilizar os classificadores de padrões das redes neurais em um índice de possibilidade a ser utilizado no desenvolvimento de um sistema automático de monitoramento de propagação de trincas nestes equipamentos.

## 7 Trabalhos Futuros

Em termos de seguimento a este trabalho, algumas sugestões podem ser colocadas.

Com relação a curva PoP, a próxima etapa para a criação de uma ferramenta aplicável em um duto em funcionamento, é aplicar a metodologia desenvolvida em corpos de prova maiores que os utilizados neste trabalho e observar se o seu desempenho está de acordo com o constatado neste trabalho.

Estudar as regiões de transição entre as classes utilizando metodologias diferentes das empregadas neste trabalho e determinar se os dados excluídos pertencem ou não a uma das classes.

Realizar a análise temporal das formas de ondas acústicas com dois objetivos, verificar se é possível realizar a partir destas a classificação da EA em uma das três classes apresentadas no trabalho e encontrar parâmetros mais eficazes que os utilizados atualmente.

## 8 Referências Bibliográficas

AGRAWAL, A., *A theoretical, numerical and experimental investigation of guided wave propagation in hollow cylinders*. Master thesis, Carnegie Mellon University, 2008.

AMN, NM 339:2014 - Ensaio não destrutivo - Ensaio de emissão acústica (EA) em vaso de pressão metálico durante o ensaio de pressão – *Procedimento, Asociación Mercosur de Normalización – AMN*, 2014.

COLOMBO, A. F., Lee, P., Karney, B.W., “A selective literature review of transient-based leak detection methods”, *Jornal of Hydro-environment Research* 2, pp. 212-227, 2009

DA SILVA ,R.R., Calôba, L.P., Siqueira , M.H.S., and Rebello, J.M.A., “Evaluation of the relevant characteristic parameters of welding defects and probability of correct classification using linear classifiers”. *Insight (Northampton)*, v. 44, No 10, pp. 616-622, 2002.

DA SILVA ,R.R., SOARES, S.D., Calôba, L.P., Siqueira , M.H.S., and Rebello, J.M.A., “Detection of the propagation of defects in pressurised pipes by means of the acoustic emission technique using artificial neural networks”. *Insight (Northampton)*, v. 48, No 1, pp. 45-51, 2006.

DA SILVA R. R., Calôba L. P., Siqueira M. H. S., Rebello J. M. A., “Pattern recognition of weld defects detected by radiographic test”. *NDT & E International*, v. 37, pp. 461–70, 2004.

DA SILVA, R.R., *Reconhecimento de Padrões de Defeitos de Soldagem em Radiografias Industriais*, D.Sc. Tese , Universidade Federal do Rio de Janeiro, Rio de Janeiro, Brasil, 2003.

DA SILVA, R.R.; Siqueira,M.H.S.; MARCIO, H.S.; SOUZA, M.P.V.; Rebello,J.M.A.; Calôba, L.P.. ‘Estimated accuracy of classification of defects detected in welded joints by radiographic tests’. *NDT & E International*, 38: 335-343, 2005.

DIAMANTIDIS, N.A., Karlis, D., Giakoumakis, E.A., “Unsupervised Stratification of Cross-Validation for Accuracy Estimation”, *Artificial Intelligence*, v.116, pp. 1-16, 2000.

DRLEFT, ‘Comparison of a histogram and a kernel density estimate.’,2010, Disponível em: <[http://en.wikipedia.org/wiki/File:Comparison\\_of\\_1D\\_histogram\\_and\\_KDE.png](http://en.wikipedia.org/wiki/File:Comparison_of_1D_histogram_and_KDE.png)>, acesso em: 23/04/2012.

DUDA, R.O.; HART, P.E., STORK, D.G.: *Pattern Classification*. 2nd edition , U.S.A., 2001.

EMAMIAN, V.;KAVEH, M.; TEWFIK, A.H.; SHI, Z.; JACOBS, J.L.; JARZYNSKI, J.; “Robust Clustering of Acoustic Emission Signals Using Neural Networks and Signal Subspace Projections”; *EURASIP Journal on Applied Signal Processing*; v. 2003:3; pp. 276–286; 2003.

ERHARD, A., Ewert, U., “The TOFD Method - Between Radiography and Ultrasonic in Weld Testing”, *NDTnet*, v.4, n°. , 1999, Disponível em: <<http://www.ndt.net/article/v04n09/ERHARD/ERHARD.htm>> , acesso em: 06/03/2015.

FUKUNAGA, K., *Introduction to Statistical Pattern Recognition*, 2nd edition, USA, 1990.

GODIN, N., HUGUET,S., GAERTNER,R., SALMON. L. “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*, Vol. 38, Issue 4, June 2005, pp. 299–309.

GODIN, N., HUGUET,S., GAERTNER,R., SALMON.L., “Clustering of acoustic emission signals collected during tensile tests on unidirectional glass/polyester composite using supervised and unsupervised classifiers”. *NDT & E International*, Vol. 37, Issue 4, June 2004, pp. 253–264.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J., *The Elements of Statistical Learning – Data Mining, Inference, and Prediction*, 2nd edition, USA, 2008.

HAYKIN, S., 1931 – *Neural networks: a comprehensive foundation* – 2nd ed –Prentice-Hall, 1999.

JIN, Y., EYDGAHI, A., “Monitoring of Distributed Pipeline Systems by Wireless Sensor Networks”, *IAJC-IJME - INTERNATIONAL ASSOCIATION OF JOURNALS AND CONFERENCES*, 2008.

JOODE, A.S., HOFFMAN, A. “Pipeline Leak Detection and Theft Detection Using Rarefaction Waves”, *6<sup>th</sup> Pipeline Technology Conference*, 2011.

KRAL, Z., HORN, W., STECK, J., “Crack Propagation Analysis Using Acoustic Emission Sensors for Structural Health Monitoring Systems”. *The ScientificWorld Journal*, Vol. 2013.

LIU, M., ZANG, S., ZHOU, D., “Fast Leak Detection and Location of Gas Pipelines Based on an Adaptative Particle Filter”, *Int. J. Appl. Math. Comput. Sci.*, v. 15, No. 4, pp. 541–550, 2005.

LOWRY, W., DUNN, S., WALSH, R., MEREWETHER, D., RAO, D., "Method and system to locate leaks in subsurface containment structures using tracer gases," US Patent 6,035,701, 2000.

MANDAL, P.C., "Gas Leak Detection in Pipelines & Repairing System of Titas Gas", *Journal of Applied Engineering (JOAE)*, v.2, Issue 2, 2014.

MAREC, A.; BERBAOUI, R.; TOMAS, J.; EL MAHI, A.; EL GUERJOUA, R.; "Investigation of damage mechanisms of polymer concrete: Multivariable analysis based on temporal features extracted from acoustic emission signals"; *7th International Symposium on Nondestructive Testing in Civil Engineering*; Nantes, France; 2009.

MIRANDA, A.C.O., *Propagação de trincas por fadiga em geometrias 2D complexas sob cargas cíclicas variáveis*, Tese D.Sc., Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Civil, Rio de Janeiro, Brasil, 2003.

MIX, P.E., *Introduction to nondestructive testing: a training guide*, 2nd ed., John & Sons, Inc., 2005.

NOCEDAL, J.; Wright, S.J. 'Numerical Optimization', 2<sup>a</sup> ed., USA, Springer Science, 2006.

PHMSA, 'Distribution, Transmission & Gathering, LNG, and Liquid Accident and Incident Data Pipeline and Hazardous Materials Safety Administration', 2015, Disponível em: <<http://www.phmsa.dot.gov/pipeline/library/data-stats>>, acesso em: 06/03/2015.

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

PINTO, C.F.C.; DA SILVA, R. R.; Calôba, L. P.; SOARES, S. D.; “Probability of defect propagation in pipelines (POP curves)”. *Insight (Northampton)*, v. 56, pp. 204-210, 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.

ROUGIER, J., “Probabilistic Leak Detection in Pipelines Using the Mass Imbalance Approach”, *Journal of Hydraulic Research*, v. 43, nº. 5, p. 556, 2005.

Silk, M.G., “The rapid analysis of TOFF data incorporating the provision of standards”, *NDTnet*, v. 2, nº 9, 1997, site: <http://www.ndt.net/article/tofd/silk/silk.htm>, em 06/03/2015.

SOARES, S.D., “Emissão Acústica”, Anotações Técnicas, 2008

SOARES, S.D., *Correlações entre emissão acústica de defeitos e parâmetros de mecânica da fratura na avaliação da integridade de equipamentos pressurizados*, Tese de D.Sc., COPPE/UFRJ, Rio de Janeiro, Brasil, 2008.

SPECHT, D.F., “Probabilistic Neural Network”, *Neural Network*, Vol. 3, pp. 109 – 118, 1990.

TAN, P.N., STEIMBACH, M., KUMAR, V., *Introduction to Data Mining*, 1ª ed., Boston, MA: Addison-Wesley Longman, 2005.

SPERL, J., "System pinpoints leaks on Point Arguello offshore line", *Oil and Gas Journal*, Vol. 89, No. 36, pp. 47-52, 1991.

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

ZAHHRAN, O., AI-NUMAIMY, W., “Automatic classification of defects in time-of-flight diffraction data”, *World Conference on NDT, Signal Processing*, 2004.

# Apêndice

## **Artigos completos publicados em periódicos**

1 - PINTO, C. F. C. ; SILVA, R. R. ; CALOBA, L. P. ; SOARES, S D . Probability of defect propagation in pipelines (POP curves). Insight (Northampton), v. 56, p. 204-210, 2014.

2 – PINTO, C.F.C. ; SILVA, R. R. ; SOARES, S. D. ; CALOBA, L. P.; SOARES, S D. Uso de redes neurais artificiais na detecção de propagação de defeitos em dutos rígidos. Matéria (UFRJ), v. 17, p. 1, 2013.

3 - PINTO, C.F.C. ; SILVA, R. R. ; SOARES, S. D. ; CALOBA, L. P.; SOARES, S D. Uso de Rede Neurais Artificiais na Detecção de Propagação de Defeitos em Dutos Rígidos. Revista Abende, v. 45, p. 39-46, 2011.

## **Trabalhos completos publicados em anais de congressos**

1 - PINTO, C. F. C. ; SILVA, R. R. ; Luiz P. CALÔBA ; Sergio D. SOARES ; Thomas CLARKE . New Approach in Automatic Detection of Defects Propagation in Pipelines. In: 5th Pan American Conference for NDT, 2011, Cancun. 5th Pan American Conference for NDT, 2011.

# Probability of defect propagation in pipelines (POP curves)

C F C Pinto, R R da Silva, L P Calôba and S D Soares

Submitted 27.10.13  
Accepted 02.03.14

*Monitoring equipment in real time has become increasingly important, mainly when operational safety is targeted. Acoustic emission (AE) testing has been applied to the inspection of various types of equipment, particularly rigid pipes. This paper presents a study on the use of acoustic emission to detect defect propagation in pressurised rigid pipes. The resulting AE signals were classified as no propagation (NP), stable propagation (SP) and unstable propagation (UP) and used as inputs in the implementation of non-linear classifiers by error back-propagation. The correct classification results reached close to 91%, proving the efficiency of the method in the conditions tested in this study. The methodologies used for the construction of the probability of propagation (POP) curve are presented, which are a great innovation in this research field and the focus of an international patent.*

**Keywords:** non-destructive testing (NDT), acoustic emission, non-linear pattern classifiers, neural network.

---

*Carlos Fernando Carlim Pinto graduated in electronic and computer engineering from the Federal University of Rio de Janeiro (UFRJ) in 2009 and attained his master's degree in electrical engineering from UFRJ in 2011. He is presently a DSc student in electrical engineering in the Signal Processing Laboratory, Federal University of Rio de Janeiro, Rio de Janeiro, Brazil, and works on research projects related to pattern recognition and neural networks. Email: carlos.fernando@lps.ufrj.br*

*Romeu Ricardo da Silva graduated in metallurgical engineering from the Federal University of Rio de Janeiro (UFRJ) in 1997, attained his master's degree in material and metallurgical engineering from UFRJ in 1999 and his DSc degree in material and metallurgical engineering from UFRJ in 2003, with a post-doctorate from the Universidad Católica de Chile in 2007. He is presently a technical consultant of projects with COPPE, Signal Processing Laboratory, Federal University of Rio de Janeiro, Rio de Janeiro, Brazil. Email: romeu@romeu.eng.br*

*Luiz Pereira Calôba graduated in electronic engineering from the Federal University of Rio de Janeiro (UFRJ) in 1969, attained his master's degree in electrical engineering from UFRJ in 1970 and a Dr Ing degree from the Université Scientifique et Médicale de Grenoble in 1974. He is presently Professor (Emeritus) in the Signal Processing Laboratory, Federal University of Rio de Janeiro, Rio de Janeiro, Brazil. His areas of interest are neural networks and signal processing. Email: caloba@lps.ufrj.br*

*Sergio Damasceno Soares graduated in mechanical engineering from the Faculdade de Engenharia Souza Marques in 1991, attained his master's degree in metallurgical and materials engineering from UFRJ in 1998 and his DSc degree in metallurgical and materials engineering from UFRJ in 2008. He is presently an engineer with the Research Center Leopoldo Américo Miguez de Mello (CENPES/PETROBRAS), Petrobras, Rio de Janeiro, Brazil. He has experience in the area of materials and metallurgical engineering, with an emphasis on non-destructive testing. Email: sdama@petrobras.com.br*

## Introduction

In the modern world, the use of non-destructive testing (NDT) to assess the structural integrity of equipment is of undeniable importance. In the past, tests were basically restricted to visual testing, liquid penetrant, magnetic particle, radiography and ultrasound. Among current NDT, the method of acoustic emission (AE) is based on the detection of sources of acoustic signals that are emitted during the propagation of discontinuities and sharp plastic deformation. As it is a qualitative method, the AE test does not provide the dimensions of the discontinuities, which are provided by other NDT methods such as ultrasound. Since it only provides indications of active discontinuities during the loading of structures, one of the main goals of its application is real-time monitoring of equipment.

Motivated by the importance of acoustic emission for non-destructive inspection of equipment, and the capability of implementing non-linear classifiers by neural network techniques, this paper describes a study developed to implement non-linear pattern classifiers, aiming to detect the growth of defects in rigid pipes using the parameters of AE signals as the input set<sup>[1]</sup>. The signals were divided into three classes: no propagation, stable propagation and unstable propagation, defined by ultrasound monitoring of growth defects, synchronised with hydrostatic testing<sup>[2]</sup>.

The results of the development of the classification probability techniques supply the foundation for the construction of probability of propagation (POP) curves, which have a similar shape to the well-known probability of detection (POD) curves; however, they are conceptually different. In this way, we present the concept of the formation of POP curves and the first results obtained, which will guide future studies.

## 2. Analysis of acoustic emission tests

### 2.1 Materials

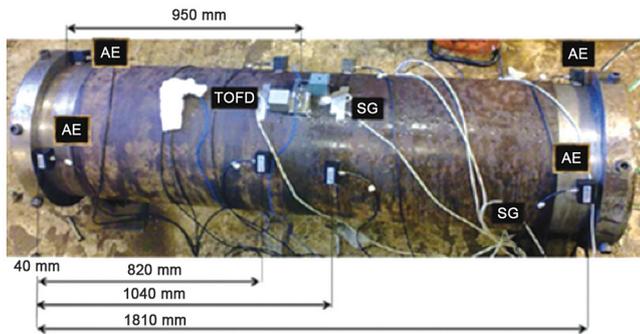
The specimens were made of API XL Grade 60 steel, 20 inches in diameter and 14.5 mm in thickness. An elliptical crack localised exactly on the TOFD transducer (Figure 1) was machined on the inner and outer surfaces of the pipes, with different dimensions for each test. For illustration, Figure 1 contains a typical schematic drawing of a pipe section with the instrumentation used for monitoring by hydrostatic tests.

The crack on the inner surface of the specimen was machined with a grinder using a cutting disc with a radius of 12 mm. The defect had a semi-elliptical shape 160 mm long, 1.1 mm wide and 7.33 mm deep.

### 2.2 Acquisition parameters of acoustic emission

Acoustic emission signals were acquired during the hydrostatic pressure tests, using the Disp 16 c equipment of PASA (Physical Acoustics South America). Eight sensors were used: four near the crack and two located at each o-ring. After the acquisition, the signals were processed in the same equipment.

According to Pinto<sup>[2]</sup>, the correct classification of AE signals into one of the three proposed classes requires nineteen features, which are described in Table 1.



**Figure 1. Schematic of positioning of the sensors close to the region of the crack on the inner surface of the specimens. Dimensions in mm. TOFD: ultrasound transducer; SG: strain gauge sensor; AE: acoustic emission sensor**

**Table 1. Acoustic emission features collected<sup>[2]</sup>**

Feature	Description
Rise	Time interval between the first peak that exceeds the reference threshold and the maximum peak amplitude.
Count	Number of times the signal exceeds the threshold, within the value set of HDT.
Energy	Integral of absolute value of each wave peak. Since this is a discrete time signal, sum up the values of the samples of rectified waveform. It must be pointed out that breadth here refers to a measure of voltage and not decibel.
Duration	Time interval between the first and the last thresholds exceeded within the pre-set value of HDT.
AMP	Maximum peak amplitude of the signal, in dB.
A-Freq	Average frequency: the definition is count over duration (count/duration).
RMS	The root of the integral values of voltage squared divided by the interval given by the time difference between the upper and lower limits of integration.
ASL	Average signal level, in dB.
PCNTS	Number of peaks until the maximum amplitude is reached, always taking into account the reference threshold.
R-Freq	Reverb frequency: defined by (count-count to peak)/(duration-rise time).
I-Freq	Initiation frequency: defined by (count to peak / rise time).
Sig-Strength	Signal strength or intensity: practically the definition of power, but with simpler coefficient of $\text{sen}(\pi/4)$ .
ABS-Energy	This is a normalised parameter that represents the real amount of energy in pico-joule. It is defined by the sum of the amplitudes of samples squared divided by 10 (kOhm impedance).
Freq-PP1	First partial power.
Freq-PP2	Second partial power.
Freq-PP3	Third partial power.
Freq-PP4	Fourth partial power.
C-Freq	Centroid frequency: not necessarily the centre frequency, corresponding to the centre of the spectrum, but choosing a setting that takes into account 'weights' due to the magnitude and spraying.
P-Freq	Peak frequency: frequency component of greater magnitude in the spectrum.

### 2.3 Synchronisation of files of acoustic emission signals

Since the monitoring of pressurisation and growth of artificial defects and the acoustic emission signals are always in separate files, a procedure for synchronising them was established, because the acoustic emission activity is related to the load and to the propagation of the defect. The AE signals resulting from tests were filtered to separate, by arrival time, just those that provided the sensors close to defects.

### 2.4 Separation of signals

After synchronising the files, the acoustic emission events were divided into the following classes: no propagation (NP), stable propagation (SP) and unstable propagation (UP)<sup>[2]</sup>.

### 2.5 The neural classifier

Artificial neural networks were used to implement non-linear pattern classifiers<sup>[3,4]</sup>.

The classifiers were developed using the back-propagation algorithm, a multilayer feed forward topology and performed as the hyperbolic tangent activation function. Some configurations of training parameters were studied to provide the best possible classification and to ensure the generalisation of classifiers<sup>[3,4]</sup>. Several datasets for training and testing were randomly selected without data replacement, aiming to estimate the accuracy of the identification signals of no propagation (NP), stable propagation (SP) and unstable propagation (UP) of defects, as well as two classes (NP and P).

After training had been conducted several times to assess which would be the best classifier configuration to be used with the inputs provided, aiming at the best possible generalisation (testing for three classes), we defined a good classifier with six neurons in the hidden layer and a momentum of 0.9, a variable learning rate with an initial value at 0.05, a growth factor of 1.05 and a decrease factor of 0.9, and set the maximum at 0.2 (parameters adjusted in the Matlab program). Once the best parameters to be used in network training were set, we decided to test them using a random selection without replacing the sets of training (80%) and test (20%)<sup>[5]</sup>. More details can be obtained in Silva *et al*<sup>[6]</sup>.

## 3. Probability of propagation (POP) curve

The main objective of the POP curve is to use the output values of each neuron of the classifier output layer for calculation of the probability of classification. To determine the probability, only two sets of data are relevant: the one that belongs to the class and the one that does not belong to the chosen class.

Figure 2 can be analysed in order to explain the methodology defining the NP class as stage 1 in propagation, SP as stage 2 and UP as stage 3, assuming that the probability in relation to time for the NP class is near 1, while the others are close to zero at the threshold of the definition of this class. When entering the second stage, the SP class probability should be close to one and the remainder close to zero. In the third and last stage, the probability of the UP class should be close to one and the remainder to zero. When plotting the three probabilities in one single graphic in relation to time, the probability of propagation (POP) curve is generated.

In an ideal situation, we assume that the AE testing for crack propagation monitoring in a pressurised equipment lasted 150 s, being that the signals of the first 49 s were defined as NP, from 50 s to 99 s as SP and from 100 s to 150 s as UP. Observing the graphic in Figure 3: from 0 s to 49 s, the probability of the signal being NP is equal to one, while the remainder is equal to zero; between 51 s and 99 s, the probability for SP is equal to 1 and the remainder is equal to zero; and from 100 s until the end of the testing, the probability for UP is equal to one and the remainder is equal to zero. However, it is highlighted that this would happen for an ideal signal characterisation situation, that is with 100% hit for

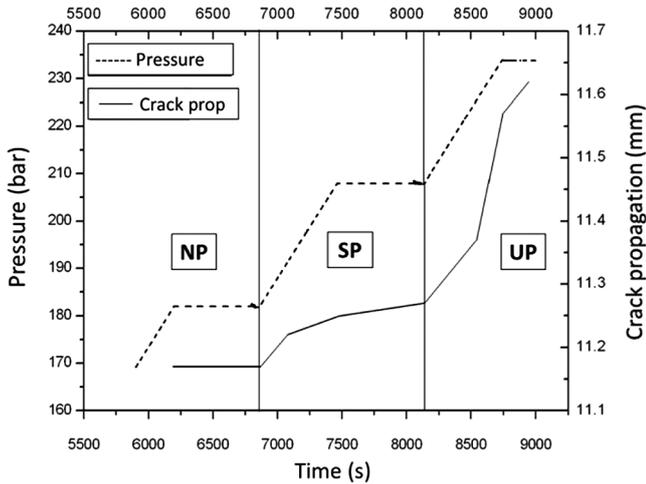


Figure 2. The dashed line represents the plot of pressure versus time and the continuous line represents the plot of crack propagation versus time

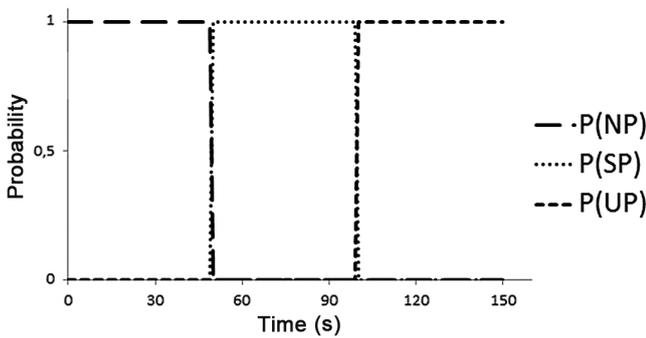


Figure 3. The long-dashed line represents the NP probability, the dotted line the SP probability and the short-dashed line the UP probability

the signals of each class in the defined region.

The testing time was used as a reference because, when there is a crack and the AE signal is captured, the tendency is for the propagation to occur until there is a rupture of the pipe, unless the pressure is relieved until the SP class. That is, in a  $t_{n+1}$  time, the size of the crack will be bigger or equal to the size in  $t_n$ , but never smaller.

This new approach can be characterised as a problem of recognition of statistical patterns, where the challenge lies in estimating the density functions in an  $n$ -dimensional space and dividing this space into classes<sup>[7]</sup>.

In this new context, among the many classifiers Bayes classifiers are considered to be the best, since they minimise the error probability in classification. In the first classification stage, the non-parametric probability density function is estimated, since the data distribution is completely unknown<sup>[7]</sup>. In the second and last stage, the classification is done using Bayes theorem<sup>[8]</sup>.

According to the neural network used to train the classifier, the classes were determined from the output value  $Y$ . Table 2 presents the values for each class.

Table 2. Neural network definitions

Class	Output vector $Y$
NP	$[1 \ -1 \ -1]^T$
SP	$[-1 \ 1 \ -1]^T$
UP	$[-1 \ -1 \ 1]^T$

According to Specht<sup>[9]</sup>, the similarity between the feed-forward neural networks and non-parametric pattern classifiers is noticeable. The author affirms that this similarity can be observed in probabilistic neural networks, where the hyperbolic tangent activation function is replaced by an exponential function, the

same as that used in the Gaussian kernel. Even though we are not developing a probabilistic neural network, we concluded that for the estimation of the probability distribution it is necessary that the activation function of each neuron of the output layer is removed according to Equation (1):

$$U_n = \tanh^{-1}(Y_n) \dots\dots\dots(1)$$

so that  $n$  is the neuron and  $Y$  is the neuron's output.

After eliminating the activation function, the next step is to estimate the probability densities. The non-parametric probability functions are extremely difficult to precisely estimate compared to the parametric ones. However, the objective is not the precision of the estimated function but to use the curve to model the classifier<sup>[7,8]</sup>.

Among the many methods for non-parametric estimation Parzen's stands out, which, when adjusted with a Gaussian kernel function  $K(\cdot)$  so that  $\int K(X)dX = 1$ <sup>[7,8]</sup>, can be interpreted as a weighted sum of the value of the  $K(\cdot)$  function for each  $X$  value, as shown in Figure 4<sup>[10]</sup>.

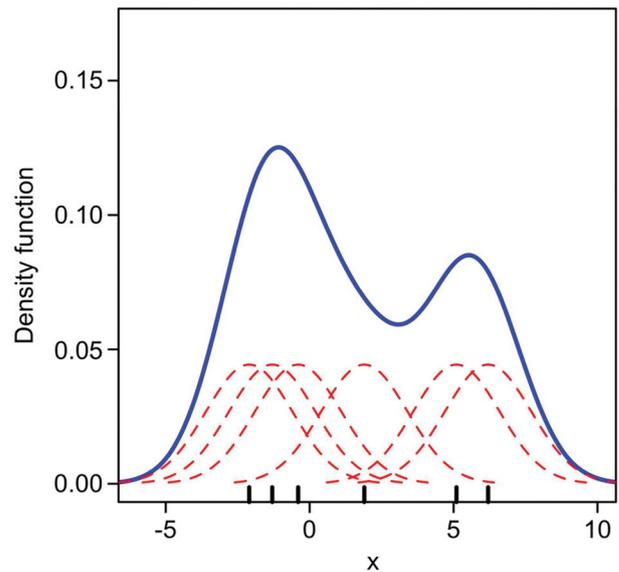


Figure 4. The curve with the continuous line is the estimated density and the dashed lines are the Kernel functions for each indicated point<sup>[10]</sup>

After estimating the probability density functions, the classification can be carried out using Bayes theorem, which will determine the *a posteriori* probability according to Equation (2)<sup>[8]</sup>. That is, given an input  $X$ , the probability of it belonging to the class is calculated:

$$\widehat{Pr}(G = j|X = x_0) = \frac{\hat{\pi}_j \hat{f}_j(x_0)}{\sum_{k=1}^J \hat{\pi}_k \hat{f}_k(x_0)} \dots\dots\dots(2)$$

$\hat{f}(X)$  – non-parametric estimated density function.

$\hat{\pi}$  – *a priori* class probability.

$J$  – number of classes.

Adjusting Equation (2) for the calculation of each class, NP, SP and UP, Equation (3) is obtained:

$$\widehat{Pr}(G = Class|X = x_0) = \frac{\hat{\pi}_{Class} \hat{f}_{Class}(x_0)}{\hat{\pi}_{Class} \hat{f}_{Class}(x_0) + \hat{\pi}_{notClass} \hat{f}_{notClass}(x_0)} \dots\dots(3)$$

Since each set of class and not-class is known, in order to eliminate any influence of an unbalancing of the sets, the *a priori* probability given any input  $x$  will be  $\hat{\pi}_{Class} = 0.5$  and  $\hat{\pi}_{notClass} = 0.5$ . In this way, the *a posteriori* probability will be a result of the estimated probability density.

According to Equation (3), the *a posteriori* probability depends on the estimated densities with the class and not-class elements.

Thus, it is necessary to define a new variable  $Z$ , described in Equation (4):

$$Z = U_l - \max(U_m, U_n) \dots\dots\dots(4)$$

such that  $l, m$  and  $n$  are the neurons of the output layer if, and only if,  $l \neq m \neq n$ .

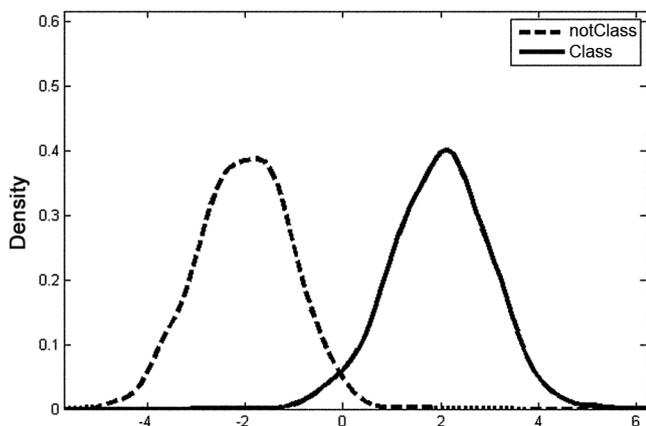
Using the neural classifier developed for the elements that belong to the class, the values of  $Z$  will be greater than zero (true positive) when properly classified and negative when wrongly classified (false negative). For the elements that do not belong to the class, the values of  $Z$  will be negative when properly classified (true negative) and greater than zero when classified as the class (false positive). Table 3 presents the equation used in each class; a similar approach is presented in Silva<sup>[11]</sup>.

**Table 3. Z equations for the respective classes**

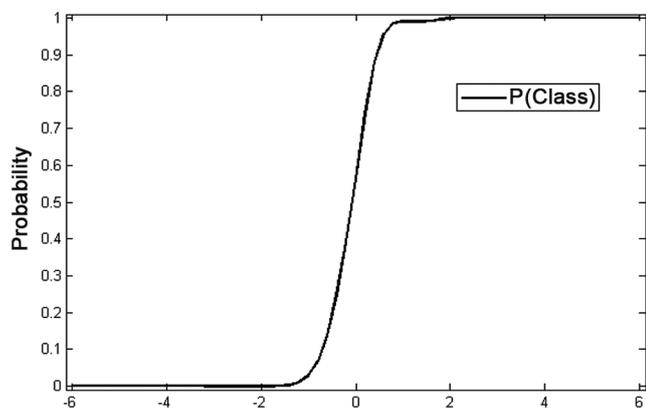
Class	Class elements set	Sum of the two sets that do not belong to the class
NP	$Z_{NP} = U_1 - \max(U_2, U_3)$	$Z_{notNP} = U_1 - \max(U_2, U_3)$
SP	$Z_{SP} = U_2 - \max(U_1, U_3)$	$Z_{notSP} = U_2 - \max(U_1, U_3)$
UP	$Z_{UP} = U_3 - \max(U_2, U_1)$	$Z_{notUP} = U_3 - \max(U_2, U_1)$

According to Hastie<sup>[8]</sup>, when two probability density curves follow the form presented in Figure 5, generated from hypothetical data, the *a posteriori* probability graphic calculated using Equation (3) will have the smooth form presented in Figure 6.

Observing the curve in Figure 6, a great similarity to the form of the curves generated from hyperbolic tangents is noticed, thus, for *posteriori* probabilities found, a regression using this function is carried out. From this moment on, the class probability can be written as a function of time and of  $Z$ , according to Equation (5):



**Figure 5. The continuous line represents the class probability density and the dashed line the density of the not-class. Hypothetical data**



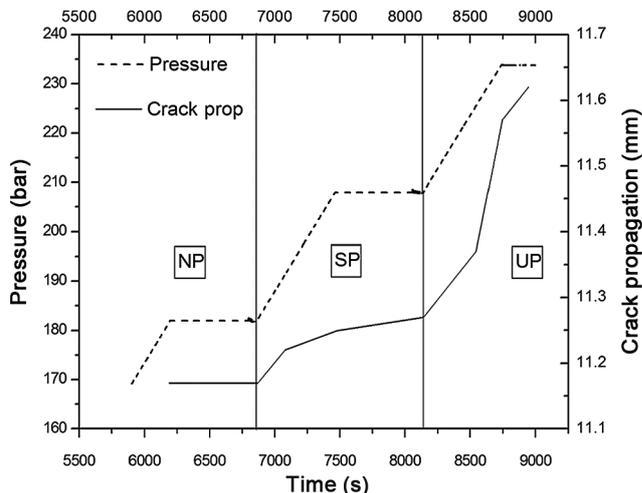
**Figure 6. Posteriori probability curve for the class, generated from the probability density**

$$P_{Class}(t) = a \times \tanh(b \times Z_n(t) - c) + d \dots\dots\dots(5)$$

## 4. Discussion and results

### 4.1 First testing

In order to sort the situation into three classes, the signals in Figure 7 were separated as NP class up to the time of 6868 s (181 bar), SP class (stable propagation) between 6869 s and 8143 s (208 bar) and UP class between 8144 s and 12,837 s (233 bar), resulting in 2207 samples being defined as NP, 1394 as SP and 6439 as UP. According to Pinto<sup>[2]</sup>, the unbalance of data between the classes does not affect the performance of the trained network.



**Figure 7. The dashed line represents the plot of pressure versus time and the continuous line represents the plot of crack propagation versus time**

Initially, tests were made with the classification system considering the single positive value at the network output layer that the authors had already called ‘without reclassification’. This methodology was presented by Silva *et al*<sup>[11]</sup>.

In order to evaluate the quality of the neural network, two sets were tested: the first one was the same as that which had trained the network (training sets) and the second one was the data that was never shown to the network (test sets).

Table 4 shows that the performance of classification into three classes attained 78% for the training sets and 77% for the test sets, the nearness of results proving the generalisation of non-linear classifiers. It must be noted that the configuration of the neural network was the same in all the situations, as explained above.

Analysing separately the average rates of success of each one of the three classes studied, UP was the class that had the best performance at 92%, which was expected, since when there is unstable propagation of the defect, the acoustic emission events become more noticeable in the acquisition system. The SP class reached 77%, which proves that finding the exact moment of transition from no propagation of the defect to elastic propagation, and then the transition from elastic to plastic, is considerably more complex. The ‘not classified’ values (more than one positive output or all negative<sup>[11]</sup>) were expected because they usually occur in pattern recognition.

### 4.2 Second testing

As described in Section 2.4, the signals were divided into NP class, SP class and UP class, resulting in 2053 samples being defined as NP, 1045 samples as SP and 383 samples as UP.

Table 5 shows that the performance of the classification into three classes attained 91% for both sets. Analysing each individual class, it is noted that the trained neural network could discriminate correctly the three classes, including the SP class, which obtained an accuracy increase of about 10% when compared to the results

**Table 4. Results of the average accuracy of 10 training and test sets (three classes without reclassification)**

	Performance (training set)					Performance (test set)			
	NP	SP	UP	NC		NP	SP	UP	NC
NP	83%	4%	13%	12%	NP	82%	4%	14%	12%
SP	16%	77%	7%		SP	15%	77%	8%	
UP	4%	4%	92%		UP	4%	4%	92%	
Average total success	78%				Average total success	77%			
NC – not classified									

**Table 5. Results of the average accuracy for 10 training and test sets (three classes without reclassification)**

	Performance (training set)					Performance (test set)			
	NP	SP	UP	NC		NP	SP	UP	NC
NP	92.2%	6.4%	0.3%	0.3%	NP	93%	6.1%	0.3%	0.3%
SP	9.7%	86.7%	4.0%		SP	8.9%	84%	4.2%	
UP	0.7%	3.8%	95.4%		UP	1.4%	7.6%	91.4%	
Average total success	91%				Average total success	91%			
NC – not classified									

of the first test. The ‘not classified’ values (more than one positive output or all negative) were insignificant at almost zero.

**4.3 POP curve**

This section presents the results obtained for each class when applying the proposed method. The first POP curve is generated from the data obtained in test 2 and the second one from the data obtained in test 1.

Table 6 presents the regression function calculated from Equation (5) for each class. Through these functions, the probability that the input signal belongs to each class NP, SP and UP can be calculated.

**Table 6. Hyperbolic tangent regression equations**

Class	Equation	
NP	$P_{NP}(t) = 0.4951 \times \tanh(3.507 \times Z_{NP}(t) - 1.372) + 0.4999$	(6)
SP	$P_{SP}(t) = 0.4951 \times \tanh(0.7004 \times Z_{SP}(t) + 0.4588) + 0.4940$	(7)
UP	$P_{UP}(t) = 0.4745 \times \tanh(1.811 \times Z_{UP}(t) + 3.114) + 0.4925$	(8)

Figure 8 presents the probability of the NP class as a function of time; each dot represents the probability for each Z value, found by using Equation (6). As initially expected, the greater concentration of dots is next to one. Then, with the increase in test time, the greater concentration of dots is found close to zero.

The SP probability curve, Figure 9, initially presented the biggest value concentration close to zero. As time passed, the greater concentration turned to one, and as time increased the probability dropped again. This trajectory can be best visualised using the regression curve.

The UP probability is presented in Figure 10. As expected, it starts with an initial value concentration close to zero and, as it reaches 8000 s, the values start to concentrate close to one and remain equal to this value until the end of the testing.

Finally, the POP curve could be determined by plotting the three probability regression curves in one single graphic, as shown in Figure 11.

Since the curve was built from the dataset of test 2, it is known that until 6000 s the data is NP, from 6000 s to 8000 s it is SP and

from 8000 s on it is UP.

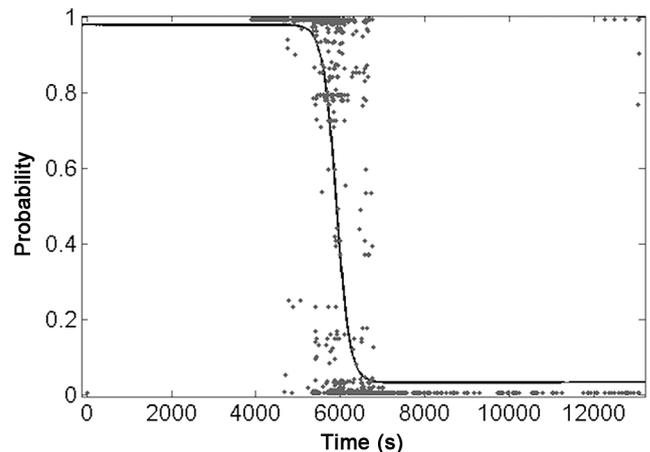
Analysing the POP curve until 6000 s, as shown in Figure 12, the input signal possesses a greater probability of being characterised as NP until about 6000 s. When it reaches 5875 s, the probability of being classified as SP exceeds the NP probability.

Figure 13 highlights the SP data. For 6000 s, the probability for the signal to be classified as SP is the greatest among the three classes. From 6850 s on, the probability of SP starts dropping and that of UP starts rising. As it reaches 7640 s, the probability of UP exceeds SP.

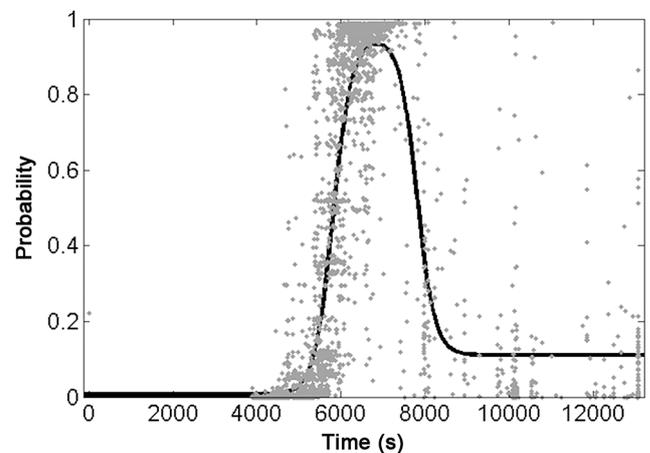
Figure 14 highlights UP data. As the test time reaches 8000 s, the probability of the input signal being classified as UP is over 90%, while that of SP is approximately 10% and that of NP is almost zero.

To ratify the reproducibility of the method, the same procedure was applied to a different test, test 1.

Table 7 presents the equations used to find the probability for each value of Z and the POP curve obtained from these values is presented in Figure 15. According to what is described in Section 4.1, until 6870 s the input signal is classified as NP, from 6870 s to 8144 s as SP and from 8144 s on the classification is of UP.



**Figure 8. Probability of the NP class. The dots represent the probability for each value of Z and the continuous line is the regression function of these dots**



**Figure 9. Probability of the SP class. The dots represent the probability for each value of Z and the continuous line is the regression function of these dots**

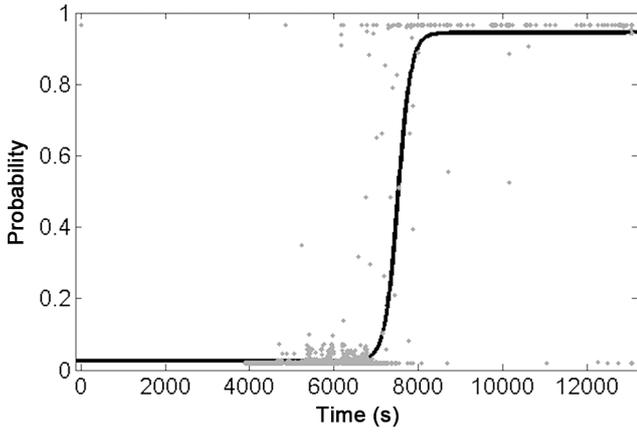


Figure 10. Probability for the UP class. The dots represent the probability for each value of  $Z$  and the continuous line is the regression function of these dots

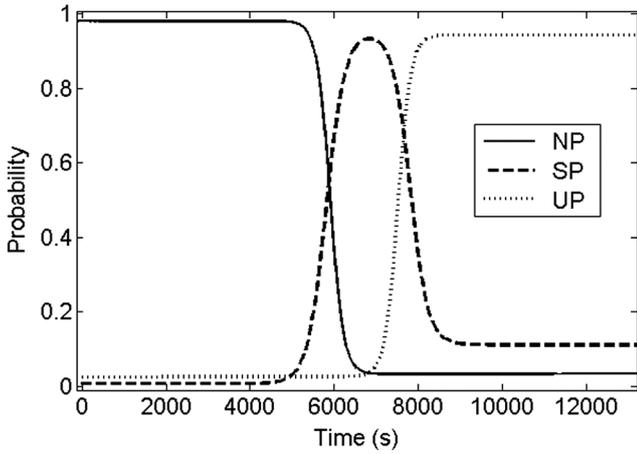


Figure 11. POP curve

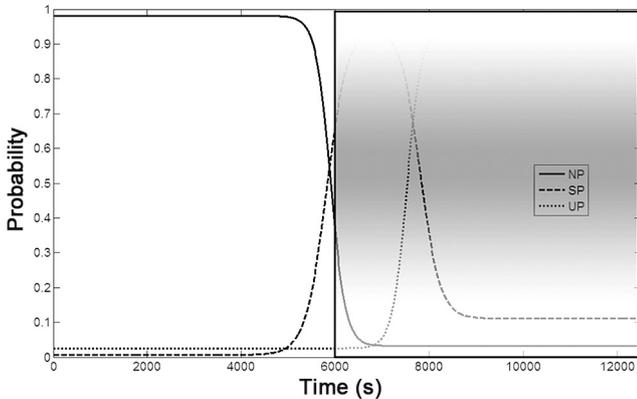


Figure 12. POP curve - highlighting NP data

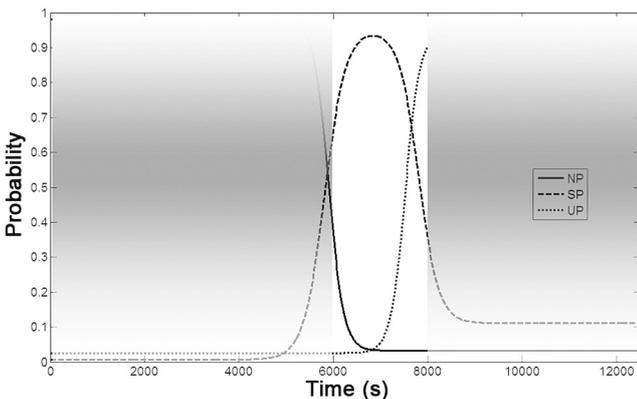


Figure 13. POP curve - highlighting SP data

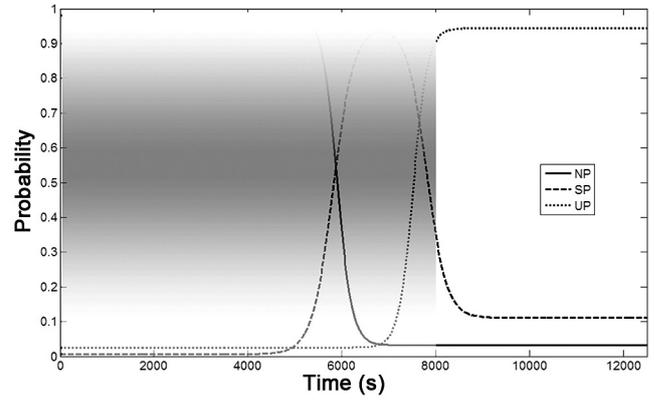


Figure 14. POP curve - highlighting UP data

Table 7. Hyperbolic tangent regression equations of test 1

Class	Equation	
NP	$P_{NP}(t) = 0.4764 \times \tanh(0.9566 \times Z_{NP}(t) + 0.788) + 0.4984$	(9)
SP	$P_{SP}(t) = 0.4541 \times \tanh(0.6761 \times Z_{SP}(t) + 0.6295) + 0.5584$	(10)
UP	$P_{UP}(t) = 0.4657 \times \tanh(0.653 \times Z_{UP}(t) - 0.5569) + 0.5229$	(11)

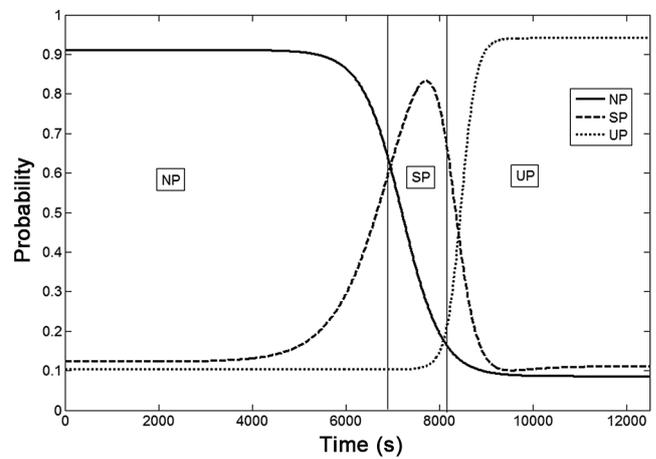


Figure 15. POP curve for test 1 - separated classes

Analysing Figure 15, it is observed, as expected, that the NP class possesses a greater probability value at the beginning of the test, being exceeded by the probability of SP at 6957 s, 87 s after the transition from NP to SP. While the NP class remains stable at 0.1 in the transition from SP to UP, the chance of a signal belonging to SP is even higher, but is already declining while the UP signal probability rises. The UP probability exceeds the SP value at 8414 s, that is with a delay of 270 s.

Defining the delays as classification errors, we have  $ERROR_{NP/SP}$  as the ratio of the delay of the transition of NP to SP by total test time, and  $ERROR_{SP/UP}$  as the ratio transition delay of SP to UP by total test time, according to Table 8. The errors presented show that the class transition presented by the POP curve is really close to the known real transition.

Table 8. Percentage classification error table

$ERROR_{NP/SP}$	2.1%
$ERROR_{SP/UP}$	0.68%

As a final discussion, it is highlighted that the crucial propagation moment is located at the threshold between the SP and UP classes, since the desired outcome is to predict, with a minimum advance, the beginning of an unstable defect propagation regime (or plastic propagation as denominated in fracture mechanics). Through the POP curves obtained so far, it has been proven that this technique is promising in this forecasting, it being possible to

transform the pattern classifiers of the neural networks in bases for the development of an automatic crack propagation monitoring system in this equipment.

## 5. Conclusion

The paper presents an innovative methodology to identify, in an automatic way, the transition from stable to unstable crack propagation in rigid pressurised pipes, monitored by acoustic emission tests.

This project aimed to conduct a series of investigations for the separation of classes of acoustic emission signals for the monitoring of rigid ducts, building on previous studies<sup>[1,12]</sup>. Until now, studies have been focused mainly on trying to discriminate the classes, stable propagation (SP) from unstable propagation (UP).

In this project, we innovatively used classification into three classes and we attained approximately 91% of classification accuracy from the beginning of crack propagation until total breaking of the specimen, a rate considered significant in terms of the few features applied. However, the separation between NP and SP is far more complex than that between both NP and UP and SP and UP. This fact can be explained by the little difference that there is in terms of acoustic emission phenomena between the time of elastic deformation and the beginning of plastic deformation.

The proposed methodology of POP curves proved to be efficient, since in both tests studied so far, for the construction of curves, a similar behaviour and a form close to the proposed theoretical curve were obtained.

In relation to the method accuracy, the results obtained are very promising, since although the transition limits between the classes did not match the curve intersection points, which is the ideal situation, both were really close, presenting an irrelevant error when compared to the total test time.

Even though initial, there being much to be developed, such results show the capacity of classifying the propagation of cracks in rigid pipelines in a probabilistic way. It is a pioneer study, thus there are no previous references with which to compare the results.

It is important to emphasise that we are not aware of similar studies, to date, with the approach developed in the area of acoustic emission monitoring of the propagation of defects, so we could not compare our results.

## 6. Further studies

Further studies will involve applying the data of a test in another one to observe the behaviour of the curve and the accuracy of the method and adjusting the parameters used to obtain regression curves so that the intersections of the probability curves are closer to the moment of class transition.

A new three-year project is starting, aiming at performing four new tests, this time using test specimens of 25 m in length to be nearer to real field situations. The resulting AE signals will be used to repeat the methodology presented and to optimise the behaviour of the curves.

## Acknowledgements

The authors would like to express their gratitude to CNPq, CAPES and FAPERJ for the financial support, the Signal Processing Laboratory at COPPE (LPS) for allowing the use of its computers and software, Petrobras for its cooperation and also the Federal University of Rio Grande do Sul.

## References

1. R R Silva, S D Soares, L P Calôba, M H S Siqueira and J M A Rebello, 'Detection of the propagation of defects in pressurised pipes by means of the acoustic emission technique using artificial neural networks', *Insight*, 48 (1), pp 45-51, 2006.

2. C F C Pinto, 'Monitoração de Defeitos em Dutos Rígidos por Emissão Acústica e Redes Neurais', MSc dissertation, Universidade Federal do Rio de Janeiro, Rio de Janeiro, Brazil, 2011.
3. S Haykin, *Neural Networks – A Comprehensive Foundation*, Macmillan College Publishing Inc, USA, 1994.
4. R O Duda, P E Hart and D G Stork, *Pattern Classification*, 2nd Edition, USA, 2001.
5. R R Silva, M H S Siqueira, H S Marcio, M P V Souza, J M A Rebello and L P Calôba, 'Estimated accuracy of classification of defects detected in welded joints by radiographic tests', *NDT&E International*, 38, pp 335-343, 2005.
6. R R Silva, 'Reconhecimento de Padrões de Defeitos de Soldagem em Radiografias Industriais', DSc thesis, Universidade Federal do Rio de Janeiro, Rio de Janeiro, Brazil, 2003.
7. K Fukunaga, *Introduction to Statistical Pattern Recognition*, 2nd Edition, USA, 1990.
8. T Hastie, R Tibshirani and J Friedman, *The Elements of Statistical Learning – Data Mining, Inference, and Prediction*, 2nd Edition, USA, 2008.
9. D F Specht, 'Probabilistic neural network', *Neural Network*, Vol 3, pp 109-118, 1990.
10. Drleft, 'Comparison of a histogram and a kernel density estimate', site: [http://en.wikipedia.org/wiki/File:Comparison\\_of\\_ID\\_histogram\\_and\\_KDE.png](http://en.wikipedia.org/wiki/File:Comparison_of_ID_histogram_and_KDE.png), 2010, em 23/04/2012.
11. R R Silva, L P Calôba, M H S Siqueira, L V S Sagrilo and J M A Rebello, 'Evaluation of the relevant characteristic parameters of welding defects and probability of correct classification using linear classifiers', *Insight*, 44 (10), pp 616-622, 2002.
12. R R Silva, D Mery and S D Soares, 'Evaluation of acoustic emission signal parameters for identifying the propagation of defects in pressurised tubes', *Materials Evaluation*, Vol 66, pp 493-500, 2008.
13. S D Soares, 'Correlações entre Emissão Acústica de Defeitos e Parâmetros de Mecânica da Fratura na Avaliação da Integridade de Equipamentos Pressurizados', DSc thesis, Universidade Federal do Rio de Janeiro, Rio de Janeiro, Brazil, 2008.

## Uso de redes neurais artificiais na detecção de propagação de defeitos em dutos rígidos

Use of artificial neural networks in detection of propagation of defects in pipelines rigid

Pinto, C.F.C.<sup>1</sup>; Silva, R.R.<sup>1</sup>; Calôba, L.P.<sup>1</sup>; Soares, S. D.<sup>2</sup>

<sup>1</sup> Laboratório de Processamento de Sinais, Universidade Federal do Rio de Janeiro; Rio de Janeiro, Brasil  
e-mail: [carlos.fernando@lps.ufrj.br](mailto:carlos.fernando@lps.ufrj.br); [romeu@romeu.eng.br](mailto:romeu@romeu.eng.br); [caloba@lps.ufrj.br](mailto:caloba@lps.ufrj.br)

<sup>2</sup> Centro de Pesquisa Leopoldo Américo Miguez de Mello, PETROBRAS; Rio de Janeiro, Brasil;  
e-mail: [sdama@petrobras.com.br](mailto:sdama@petrobras.com.br)

---

### RESUMO

O interesse no monitoramento de equipamentos em tempo real é crescente nos dias de hoje, visando a maior segurança de operação dos mesmos. O ensaio de Emissão Acústica vem sendo objeto de desenvolvimentos com o intuito de aplicação em diversos tipos de equipamentos, com destaque na inspeção de dutos rígidos e flexíveis. O presente trabalho apresenta a metodologia e os resultados obtidos de um estudo de aplicação do método de Emissão Acústica para detectar defeitos em propagação em dutos rígidos pressurizados, sendo um trabalho pioneiro nessa área de pesquisa. Para tal, foram confeccionados corpos de prova com defeitos inseridos artificialmente, empregando-se a técnica de ultrassom por *Time-of-flight diffraction* (TOFD) para acompanhar o crescimento dos defeitos no duto submetido a ensaio hidrostático. Os sinais resultantes foram divididos em classes de Propagação, Propagação Estável e Propagação Instável, e usados como dados de entrada na implementação de classificadores não lineares via Redes Supervisionadas do tipo Retropropagação do Erro. Os resultados atingiram acertos de classificação próximos a 86%, comprovando a eficiência do método para as condições testadas até o presente momento.

**Palavras-chave:** Ensaios não destrutivos, Redes Neurais, Emissão Acústica.

---

### ABSTRACT

The interest in monitoring equipment in real time is increasing in nowadays, mainly aiming the greater security of its operations. The Acoustic Emission (AE) testing has been the subject of developments with the aim of application in various types of equipment, especially in the inspection of rigid and flexible pipes. This paper presents the methodologies and results of a study of applying the method of Acoustic Emission to detect propagation in defects in pressurized rigid pipes, being a pioneering work in this area of research. In this way, specimens were manufactured with defects artificially inserted. These specimens were submitted to hydrostatic testing and the defect propagation was monitor by AE. The ultrasound by Time of Flight Diffraction (TOFD) was the technique chosen to monitor the defect growth. The AE resulting signals were divided into the classes No Propagation (SP), Stable Propagation (PE) and Unstable Propagation (PI) and used as inputs set in the implementation of nonlinear classifiers by error back propagation. The correct classification results reached close to 86%, proving the efficiency of the method for the conditions tested in this job.

**Keywords:** Nondestructive testing (NDT), acoustic emission, neural networks

---

## 1. INTRODUÇÃO

No mundo moderno, há inegável importância da utilização dos Ensaios Não Destrutivos (END) na avaliação da integridade estrutural de equipamentos. No passado, poucos eram os ensaios aplicáveis, basicamente se restringindo ao Ensaio Visual, Líquidos Penetrantes, Partículas Magnéticas, Radiografia e Ultrassom. Dentre os ensaios não destrutivos atuais, destaca-se o método de Emissão Acústica (EA), o qual está baseado na

detecção de fontes de sinais acústicos que são emitidas durante a propagação de descontinuidades e deformações plásticas acentuadas. Por ser um método qualitativo, o ensaio de emissão acústica não fornece as dimensões das descontinuidades, as quais são fornecidas por outros métodos de ensaios não destrutivos, como o ultrassom. Uma vez que só fornece indicações de descontinuidades ativas durante o carregamento das estruturas, um dos principais objetivos de sua aplicação é o monitoramento em tempo real de equipamentos.

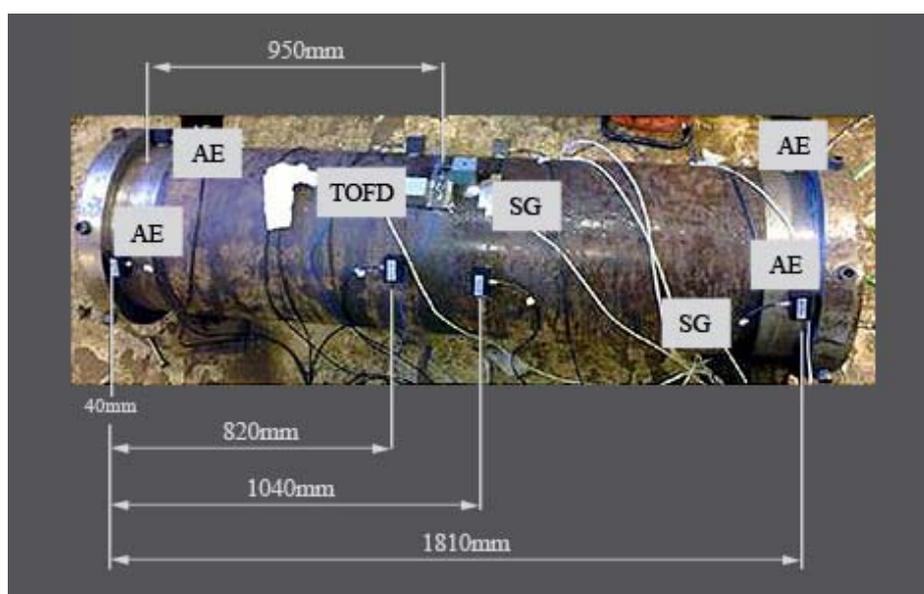
Uma das principais linhas de pesquisa e desenvolvimento hoje na área de END é a utilização de ferramentas de processamento de sinais, imagens e reconhecimento de padrões para semi-automatização ou automatização de processos de detecção e classificação de defeitos em equipamentos. Diversos destes trabalhos vêm sendo desenvolvidos na última década com os sinais de ultrassom computadorizado e imagens radiográficas digitais [1-6].

Motivado pela importância da Emissão Acústica entre os métodos não destrutivos usados na inspeção de equipamentos, e a potencialidade de se implementar classificadores não lineares pelas técnicas de rede neurais, o presente trabalho tem como objetivo desenvolver classificadores não lineares de padrões, tendo como entrada os parâmetros dos sinais de EA, visando detectar o crescimento dos defeitos em dutos rígidos em três classes de sinais: Sem Propagação, Propagação Estável e Propagação Instável, as quais foram definidas pelo acompanhamento por ultrassom de crescimento de defeitos usando a técnica *Time-of-flight diffraction* (TOFD) simultaneamente à realização de ensaio hidrostático em corpos de prova (trecho de dutos). É importante destacar que o presente trabalho faz parte de um trabalho de dissertação de mestrado e de um projeto de trabalho de pesquisa realizado entre Petrobras/CENPES/TMEC, LPS/COPPE e LAMEF/UFRGS.

## 2. ANÁLISE DOS ENSAIOS DE EMISSÃO ACÚSTICA

### 2.1. Materiais

O material dos corpos de prova é aço API XL Grau 60, tendo estes 20 polegadas de diâmetro e 14,5 mm de espessura. Os tubos tiveram suas extremidades usinadas a fim de que fossem montados dois flanges para contenção do fluido de pressurização (vedação feita com *o-rings* de borracha). Foram usinadas trincas elípticas nas superfícies internas e externas dos tubos, cujas dimensões eram diferentes em cada ensaio. Foram realizados seis ensaios ao todo no projeto, porém, apresentam-se neste artigo apenas os dois últimos ensaios por se tratarem dos resultados mais conclusivos do projeto. Para ilustração, a Figura 1 contém um desenho esquemático típico do corpo de prova com a instrumentação utilizada para o monitoramento dos ensaios hidrostático.



**Figura 1:** Esquema de posicionamento dos sensores próximos à região de presença da trinca interna na superfície do corpo de prova. Cotas em milímetros.

## 2.2. Aquisições dos parâmetros de emissão acústica

Os sinais de emissão acústica foram adquiridos durante os ensaios de pressão hidrostática, utilizando o equipamento Disp 16C da PASA (*Physical Acoustic South America*). Após a aquisição, os sinais foram processados no próprio equipamento, os parâmetros adquiridos são apresentados na Tabela 1 [1, 2].

Tabela 1: Parâmetros de Emissão Acústica coletados [1, 2]

PARÂMETRO	DESCRIÇÃO
<i>Rise</i>	Tempo do primeiro pico a ultrapassar o limiar de referência até o pico de amplitude máxima.
<i>Count</i>	Número de vezes em que o sinal ultrapassa o limiar, dentro do valor definido de HDT.
<i>Energy</i>	Integral do valor absoluto, ou módulo, de cada pico da onda. Como se trata de um sinal temporalmente discreto, somam-se os valores das amostras da forma de onda retificada. Cabe salientar que a amplitude aqui se refere a uma medida de tensão/voltagem e não decibel.
<i>Duration</i>	Intervalo de tempo entre a primeira e a última ultrapassagem do limite, dentro do valor pré-estabelecido de HDT.
AMP	Amplitude máxima do sinal, em dB.
A-Freq	Frequência Média: a definição é contagem sobre duração, [count/duration].
RMS	Raiz da integral dos valores de tensão ao quadrado dividida pelo intervalo de tempo dado pela diferença de tempo entre os limites superior e inferior de integração.
ASL	Nível médio do sinal, em dB.
PCNTS	Número de picos até a amplitude máxima ser alcançada, sempre levando em consideração o limiar de referência.
R-Freq	Frequência de reverberação: definida por: [contagem – contagem ao pico] / [duração - tempo de subida].
I-Freq	Frequência de Iniciação (definida por: contagem ao pico / tempo de subida)
<i>Sig-Strength</i>	Intensidade ou potência do sinal: praticamente a definição de energia, porém com coeficiente mais simples de $\sin(\pi/4)$ .
<i>ABS-Energy</i>	Energia Absoluta: quantidade real de energia sendo a unidade base pico Joule, definido pela soma das amplitudes das amostras ao quadrado dividido pela impedância de 10 kOhm. É importante lembrar que este parâmetro é normalizado.
Freq-PP1	Primeira potência parcial.
Freq-PP2	Segunda potência parcial.
Freq-PP3	Terceira potência parcial.
Freq-PP4	Quarta potência parcial.
C-Freq	Centróide de frequência: não necessariamente a frequência central, correspondente ao centro do espectro, mas uma frequência que leva em consideração “pesos” devido à magnitude e espalhamento.
P-Freq	Frequência pico: componente de frequência de maior magnitude no espectro.

## 2.3. Monitoramento do crescimento dos defeitos

O crescimento destas trincas foi monitorado através de ensaios de ultra-som usando a técnica TOFD (*Time of Flight Diffraction*).

## 2.4. Sincronização dos arquivos de emissão acústica e pressão

Com o monitoramento da pressurização e do crescimento dos defeitos artificiais, além dos sinais de emissão acústica, que se encontram sempre em arquivos distintos, foi estabelecido um procedimento para sincronizá-los, pois a atividade de emissão acústica está relacionada com o carregamento imposto e com a propagação do defeito. Os sinais de EA resultantes dos ensaios foram filtrados de maneira simples apenas para separar, por tempo de chegada, aqueles que proviam dos sensores próximos aos defeitos.

## 2.5. Separação dos sinais

Após sincronização dos arquivos, os eventos de emissão acústica foram divididos nas classes SP (Sem Propagação) e Propagação (P), ou SP, PE (Propagação Estável) e Propagação Instável (PI).

## 2.6. Pré-processamento dos dados

Primeiramente, os dados que estavam inicialmente em formato de arquivo DTA foram convertidos em formato ASC II. Posteriormente, os dados foram normalizados adequadamente para melhor desempenho no treinamento das redes neurais.

## 2.7. Análise de relevância dos parâmetros de emissão acústica

Este critério mede a relevância de cada parâmetro de entrada do classificador, isto é, mede o quanto este influencia no desempenho da rede neural. O método consiste em procurar mudanças significativas na resposta do classificador, ao substituir os valores de cada parâmetro pelo valor médio [7].

A relevância  $R(X_i)$  da componente  $X_i$  do vetor  $X$  pode ser calculada pela seguinte equação:

$$R(X_i) = \frac{\sum_{j=1}^P \|y(x_j) - y(x_{ji})\|^2}{P} \quad ((1))$$

$R(X_i)$ : relevância da componente  $x_i$  dos vetores de entrada  $x$  ;

$P$  : número de padrões (treinamento ou teste);

$y(x_j)$ : vetor de saída da rede neural para cada padrão  $i$  e  $x$  de entrada apresentado;

$x_{ji}$  : vetor de entrada  $x_j$  , em que a  $i$ -ésima componente foi substituída pelo seu valor médio tomado sobre todos os vetores de entrada;

$y(x_{ji})$  : saída da rede para a entrada  $x_{ji}$

## 2.8. Elaboração dos algoritmos para desenvolvimento dos classificadores e avaliação de classificação

Para implementação dos classificadores de padrões, foram implementados classificadores de padrões não lineares usando redes neurais artificiais [8,9].

Redes Neurais Artificiais (RNA) são estruturas inspiradas nas redes neurais biológicas. Seu comportamento se assemelha a capacidade de reconhecimento do cérebro humano, o qual funciona de maneira completamente diferente dos computadores digitais convencionais. Ele tem a capacidade de organizar suas estruturas, os neurônios, formando redes capazes de realizar operações (reconhecimento de padrões, percepção, controle motor e etc.) em menos tempo que o mais rápido computador da atualidade [8].

A ideia central das RNAs é combinar linearmente as entradas obtidas a partir dos parâmetros coletados, e modelar as saídas (resultado a ser atingido) como funções não lineares destes parâmetros [10]. Existe um amplo espectro de modelos de redes neurais, neste trabalho é aplicado o modelo chamado de *Multilayer Feedforward Networks*.

A menor unidade de uma RNA é o neurônio, ele é responsável pelo processamento da informação e é formado por três elementos básicos, as sinapses, um somador e uma função de ativação, a Figura 1 apresenta um esquema desta estrutura.

De acordo com a Figura 2, as sinapses são responsáveis por associar a cada entrada  $X_i$  um peso  $W_i$ , que determina o efeito da mesma sobre o neurônio. Estas são combinadas linearmente pelo somador e a função de ativação, geralmente uma função não linear, determina o nível de ativação do neurônio artificial. Estes são organizados em camadas e de acordo com a arquitetura utilizada, pode haver uma ou mais camadas.

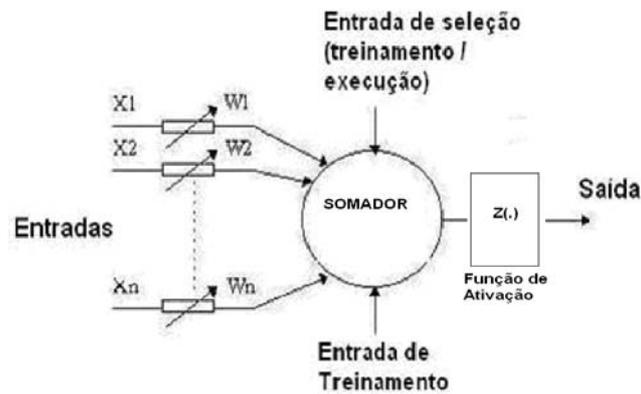


Figura 2: Modelo não linear de um neurônio.

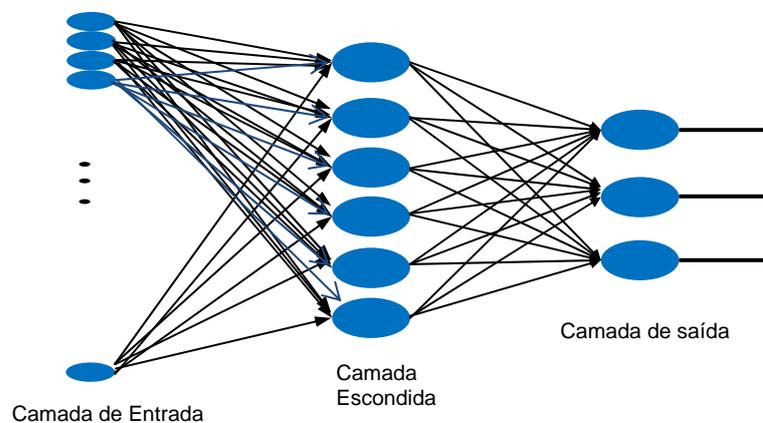


Figura 3: Rede Neural Artificial com 19 entradas, 1 camada escondida e 3 saídas.

No caso deste trabalho a rede está organizada em camada de entrada, uma camada escondida e uma camada de saída, como mostra a Figura 3. Na camada de entrada são utilizados dezenove neurônios, um para cada parâmetro, a camada escondida é composta por seis neurônios e a camada de saída três neurônios para o classificador de três classes e dois neurônios para o classificador de duas classes.

## 2.9. Treinamento dos classificadores

Os classificadores foram desenvolvidos se estimando seus parâmetros (vetores sinápticos e bias) usando o algoritmo de retropropagação do erro [8,9]. Algumas configurações de parâmetros de treinamento foram estudadas para fornecer o melhor resultado possível na distinção das classes e garantir a generalização dos classificadores [1, 2].

## 2.10. Estimação da acurácia dos classificadores

Em reconhecimento de padrões, uma das questões mais polêmicas é saber qual a verdadeira acurácia dos classificadores, isto é, qual o índice de acerto esperado para qualquer conjunto de sinais/dados testado na classificação. Vários conjuntos de dados para treinamento e teste foram sorteados aleatoriamente sem reposição de dados com intuito de estimar a acurácia de identificação dos sinais de Sem Propagação (SP), Propagação Estável (PE) e Propagação Instável (PI) de defeitos, assim como para duas classes (SP e P).

## 3. RESULTADOS E DISCUSSÕES

Inicialmente foram realizados diversos treinamentos para avaliar qual seria a melhor configuração do classificador a ser usada com as entradas apresentadas visando a melhor generalização possível (testes para

três classes). Foram treinadas redes sem momento, com momento, sem momento e alfa variável e com momento e alfa variável, variando-se de 1 a 10 neurônios na camada intermediária. Os testes foram realizados com taxa de aprendizagem de 0,1 e momento de 0,9, e depois com 0,5 e 0,9, respectivamente [8]. Definido os melhores parâmetros a serem utilizados no treinamento da rede, partiu-se para os testes com sorteio aleatório sem reposição de conjuntos de treinamento (80%) e teste (20%) [11]. Foi definido um classificador ótimo com 6 neurônios, sem momento, com valor de alfa inicial igual a 0,05, fator de incremento de alfa de 1,05 e fator de decréscimo de 0,9, alfa máximo de 0,2 (parâmetros ajustados no programa MATLAB).

### 3.1. Separação em duas classes (Primeiro ensaio)

Para este ensaio, foi usinada no corpo de prova uma trinca interna no centro do mesmo com uso de uma retifica manual com disco de corte com raio igual a 12 mm. A geometria do defeito ficou com um formato semi-elíptico com 160 mm de comprimento, 1,1 mm de largura e 7,33 mm de profundidade.

Analisando o gráfico da Figura 4 a seguir, para primeiramente uma situação de duas classes, os sinais foram separados na classe SP (Sem Propagação) até o tempo de 6868s (181 bar) e classe P (Propagação) entre 6869s e 12837s (233 bar). Resultando em 2207 sinais de SP e 7834 de P.

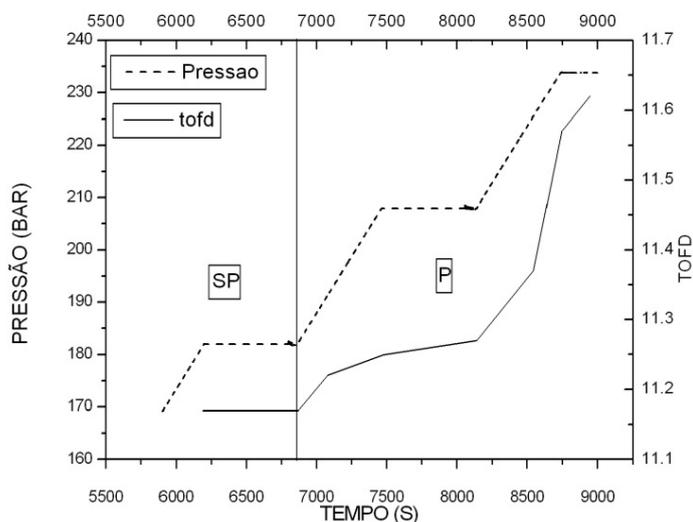


Figura 4: Crescimento do defeito com tempo e pressão de ensaio.

Foram sorteados aleatoriamente 10 pares de conjunto de treinamento e teste (20% dos sinais pra teste).

A Tabela 2 a seguir apresenta os valores de média de acerto (acurácia de classificação) em quantidade e percentual referentes aos 10 conjuntos sorteados de treinamento e teste. Analisando esta Tabela, os valores de acerto de treinamento são compatíveis com valores já encontrados nos projetos anteriores para discriminação com duas classes [5,12], o mesmo ocorrendo com os sinais usados para testar os classificadores. A pouca diferença entre a média de acerto de treinamento e teste comprova a generalização do classificador, sem provável supertreinamento.

Tabela 2: Resultados da média de acerto para os 10 conjuntos de treinamento e teste (duas classes).

ACERTOS (CONJUNTOS DE TREINAMENTO) QUANTIDADE/PERCENTUAL			ACERTOS (CONJUNTOS DE TESTE) QUANTIDADE/PERCENTUAL		
	SP	P		SP	P
SP	920/52,17%	843/47,83%	SP	261/58,91%	182/41,09%
P	235/3,74%	6035/96,26%	P	147/9,41%	1417/90,59%
Média total de acerto	6955/86,58%		1678/83,60%		

### 3.2. Separação em três classes sem reclassificação (primeiro ensaio)

Para situação de classificação com três classes, analisando a Figura 5, os sinais foram separados na classe SP (Sem Propagação) até o tempo de 6868s (181 bar), na classe PE (Propagação Estável) entre 6869 e 8143 s (208 bar) e na classe PI (Propagação Instável) entre 8144s e 12837s (233 bar). Resultando em 2207 sinais de SP, 1394 sinais de PE e 6439 sinais de PI.

Inicialmente, foram feitos testes com o sistema de classificação considerando apenas o único valor positivo na saída dos neurônios, isto é, o que se denomina sem reclassificação (mais conservador) [6].

Pela Tabela 3 de confusão a seguir, a acurácia de acerto com três classes sem reclassificação atinge 74% para os conjuntos de treinamento e 71% com os conjuntos de teste, comprovando a generalização dos classificadores não lineares. Há de se destacar que a configuração da rede neural foi a mesma em todas as situações, conforme explanado anteriormente.

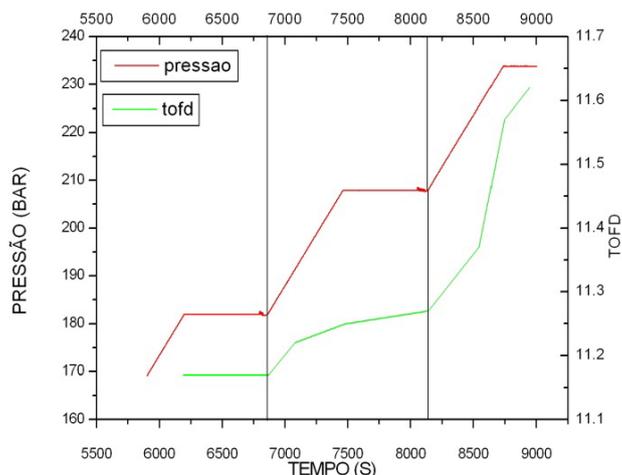


Figura 5: Crescimento do defeito com tempo e pressão de ensaio.

Analisando-se separadamente os índices médios de acerto pra cada uma das três classes agora estudadas, a classe PI é a que tem a melhor acurácia de classificação (95%), o que era esperado, pois fenomenologicamente é quando há o crescimento instável do defeito e os eventos de emissão acústica se tornam mais perceptíveis no sistema de aquisição. A classe PE confunde bastante com SP e também com PI, o que prova que constatar o exato momento de transição do estado de não propagação do defeito para o estado de uma propagação elástica, estável, assim como a transição do regime elástico para o plástico é consideravelmente mais complexa. Os valores de Não Classificação (mais de uma saída positiva ou todas negativas) estão dentro do esperado no que normalmente acontece em reconhecimento de padrão.

Tabela 3: Resultados da média de acerto para os 10 conjuntos de treinamento e teste (três classes sem reclassificação).

ACERTOS (CONJUNTOS DE TREINAMENTO) QUANTIDADE/PERCENTUAL				
	SP	PE	PI	NC*
SP	921/68,90%	54/4,02%	362/27,08%	157/8%
PE	89/13,82%	289/45,20%	262/40,97%	
PI	144/2,89%	107/2,14%	4737/94,97%	
Média total de acerto	5947/74,14%			
ACERTOS (CONJUNTOS DE TESTE) QUANTIDADE/PERCENTUAL				
	SP	PE	PI	NC*
SP	204/51,13%	21/5,17%	174/43,70%	157/8%
PE	28/12,66%	41/18,56%	150/68,76%	
PI	33/2,67%	17/1,38%	1187/95,94%	
Média total de acerto	1431/71,18%			

NC: Não classificação

### 3.3. Separação em três classes com reclassificação (primeiro ensaio)

O próximo passo nos testes foi avaliar a classificação dos mesmos pares de conjuntos formados no item anterior no sistema de Reclassificação. Nesta metodologia, lembrando, o neurônio que indica a classe é o de maior valor [6], apontando a maior probabilidade de que um sinal pertença a essa classe.

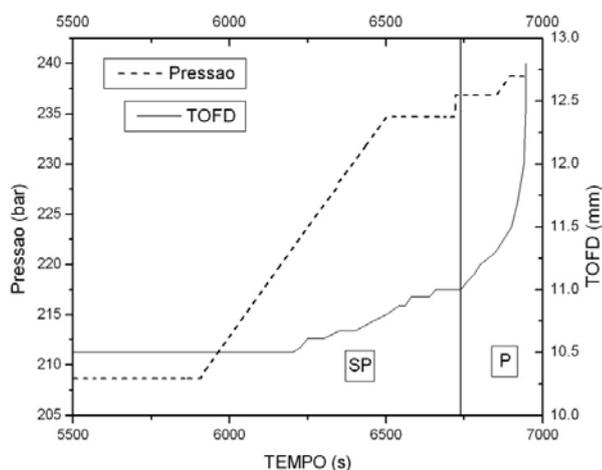
A Tabela 4 de confusão apresenta os resultados obtidos nesta classificação. As acurácias de treinamento e teste aumentaram em relação à situação anterior, como era de se esperar. Em treinamento a média chegou a quase 83%, e nos testes, 73,54%, 2,5% a mais que para Sem Reclassificação. Esta Tabela de confusão também indica que as classes que mais se confundem são PE com SP e PI, ratificando os resultados do item anterior.

**Tabela 4:** Resultados da média de acerto para os 10 conjuntos de treinamento e teste (três classes com reclassificação).

ACERTOS (CONJUNTOS DE TREINAMENTO) QUANTIDADE/PERCENTUAL			
	SP	PE	PI
SP	1149/65,54%	281/16,03%	323/18,43%
PE	144/12,98%	739/66,64%	226/20,38%
PI	206/3,99%	205/3,97%	4758/92,05%
Média total de acerto	6646/82,75%		
ACERTOS (CONJUNTOS DE TESTE) QUANTIDADE/PERCENTUAL			
	SP	PE	PI
SP	219/48,34%	23/5,08%	211/45,58%
PE	43/15,09%	47/16,49%	195/68,42%
PI	42/3,29%	19/1,49%	1215/95,22%
Média total de acerto	1481/73,54%		

### 3.4. Separação em duas classes (segundo ensaio)

A geometria e dimensões do corpo de prova e da trinca neste ensaio foram similares ao do ensaio anterior. Analisando o gráfico da Figura 6 a seguir, para primeiramente uma situação de duas classes, os sinais foram separados na classe SP (Sem Propagação) até o tempo de 6740s e classe P (Propagação) a partir de 6741s, resultando em 18908 sinais de SP e 810 de P. Foram sorteados aleatoriamente 10 pares de conjunto de treinamento e teste (20% para teste).



**Figura 6:** Crescimento do defeito com tempo e pressão de ensaio.

A Tabela 5 a seguir apresenta os valores de média de acerto em quantidade e percentual referentes aos 10 conjuntos sorteados de treinamento e teste.

Na Tabela 5, observam-se excelentes resultados de acurácia de classificação para os sinais de treinamento e teste com valores praticamente iguais, fato que comprova a generalização do classificador não

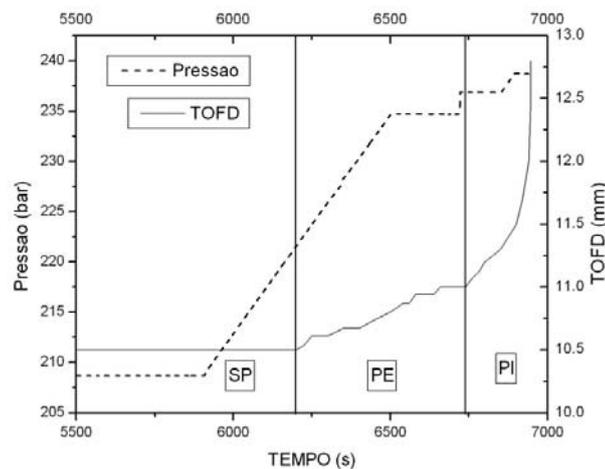
linear. Esses números são similares aos obtidos em publicações anteriores [5, 12] desenvolvido para uma situação em que se utilizaram todos os parâmetros relacionados, e também quando houve rompimento do corpo de prova. Certamente a provável causa pra estes resultados está no fato dos sinais de EA serem evidenciados no crescimento rápido da trinca até o rompimento (vazamento). Ressalta-se, também, que em relação ao ensaio anterior, a separação das classes SP e P foi realizada se somando os sinais de SP e PE, com PI representando P. Ao contrário, anteriormente os sinais de PE foram somados aos sinais de PI, o que também pode ter corroborado para o índice maior de acerto na atual situação.

**Tabela 5:** Resultados da média de acerto para os 10 conjuntos de treinamento e teste (duas classes).

ACERTOS (CONJUNTOS DE TREINAMENTO) QUANTIDADE/PERCENTUAL			ACERTOS (CONJUNTOS DE TESTE) QUANTIDADE/PERCENTUAL		
	SP	P		SP	P
SP	14909/98,53%	222/1,47%	SP	3721/98,54%	55/1,46%
P	17/2,64%	628/97,36%	P	5/3,19%	161/96,81%
Média total de acerto	15536/98,49%		3883/98,47%		

### 3.5. Separação em três classes sem reclassificação (segundo ensaio)

Para situação de classificação com três classes, analisando a Figura 7, os sinais foram separados na classe SP (Sem Propagação) até o tempo de 6200s, na classe PE (Propagação Estável) entre 6201 ate 6740s e na classe PI (Propagação Instável) a partir de 6741s, resultando em 16072 sinais de SP, 2836 sinais de PE e 810 sinais de PI.



**Figura 7:** Crescimento do defeito com tempo e pressão de ensaio.

Pela Tabela 6 de confusão a seguir, a acurácia de acerto com três classes Sem Reclassificação atinge cerca de 86% para os conjuntos de treinamento e teste, comprovando a generalização dos classificadores não lineares. Há de se destacar que a configuração da rede neural foi a mesma em todas as situações, conforme explanado anteriormente. Estes valores, comparados aos encontrados no teste anterior, na mesma condição, chegam a ter 15% acima de acurácia. Uma provável explicação para índice maior de acerto está no fato de ter acontecido um crescimento do defeito de forma rápida até o vazamento do corpo de prova, aumentando claramente o acerto da classe PI. Além disso, as classes SP e PI apresentaram médias de acerto bem maiores que no ensaio anterior, ao contrário de PE que teve uma redução significativa, havendo muita confusão dessa classe com SP, porém, a proporção de sinais desta classe é bem inferior a SP e PI. A quantidade de sinais não classificados é muito pequena para treinamento, apenas 39, e um pouco maior para teste, 175.

**Tabela 6:** Resultados da média de acerto para os 10 conjuntos de treinamento e teste (três classes sem reclassificação). NC – não classificado.

<b>ACERTOS (CONJUNTOS DE TREINAMENTO) QUANTIDADE/PERCENTUAL</b>				
	<b>SP</b>	<b>PE</b>	<b>PI</b>	<b>NC*</b>
<b>SP</b>	12815/99,86%	17/0,14%	1/0,01%	39/0,25%
<b>PE</b>	1864/82,63%	135/5,99%	257/11,38%	
<b>PI</b>	0/0%	13/1,93%	636/98,07%	
<b>Média total de acerto</b>	13586/86,12%			
<b>ACERTOS (CONJUNTOS DE TESTE) QUANTIDADE/PERCENTUAL</b>				
	<b>SP</b>	<b>PE</b>	<b>PI</b>	<b>NC*</b>
<b>SP</b>	3208/99,71%	9/0,28%	0/0,01%	175/8,73%
<b>PE</b>	452/81,50%	37/6,65%	66/11,86%	
<b>PI</b>	0/0%	3/1,68%	158/98,32%	
<b>Média total de acerto</b>	3403/86,31%			

### 3.6. Separação em três classes com reclassificação (segundo ensaio)

O próximo passo nos testes foi avaliar a classificação dos mesmos pares de conjuntos formados no item anterior no sistema de Reclassificação.

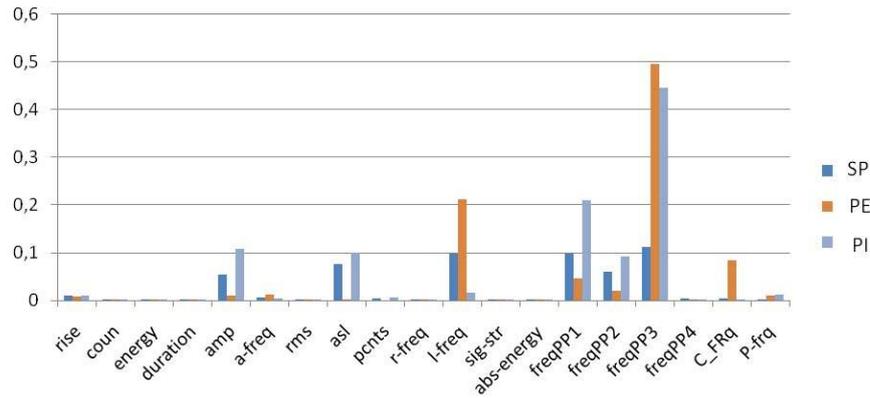
A Tabela 7 de confusão apresenta os resultados obtidos nesta classificação. As acurácias de treinamento e teste aumentaram em relação à situação anterior, porém, de forma insignificante, menos de 1%. Obtiveram-se valores idênticos entre o resultado de treinamento e teste (86,45%), provando a generalização do processo de classificação.

**Tabela 7:** Resultados da média de acerto para os 10 conjuntos de treinamento e teste (três classes com reclassificação).

<b>ACERTOS (CONJUNTOS DE TREINAMENTO) QUANTIDADE/PERCENTUAL</b>			
	<b>SP</b>	<b>PE</b>	<b>PI</b>
<b>SP</b>	12824/99,80%	24/0,19%	1/0,01%
<b>PE</b>	1871/82,52%	146/6,43%	250/11,05%
<b>PI</b>	0/0,02%	13/2,03%	637/97,95%
<b>Média total de acerto</b>	13607/86,45%		
<b>ACERTOS (CONJUNTOS DE TESTE) QUANTIDADE/PERCENTUAL</b>			
	<b>SP</b>	<b>PE</b>	<b>PI</b>
<b>SP</b>	3211/99,63%	12/0,36%	0/0,01%
<b>PE</b>	454/81,08%	40/7,08%	66/11,84%
<b>PI</b>	0/0%	3/1,74%	158/98,26%
<b>Média total de acerto</b>	3409/86,45%		

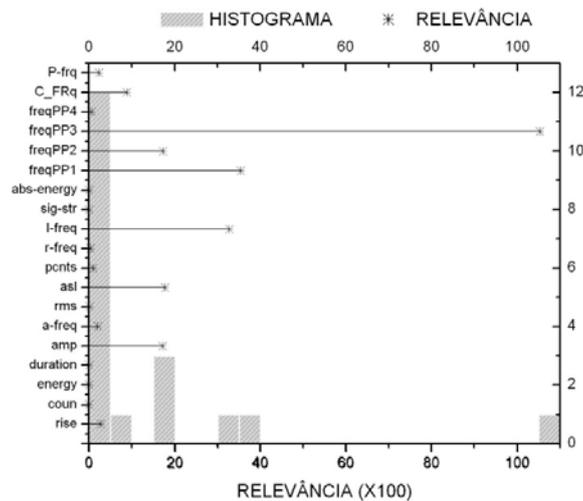
### 3.7. Relevância de parâmetros

Em relação às investigações da relevância dos parâmetros para discriminação das classes de sinais de EA, o gráfico da Figura 8 mostra que AMP e ASL influenciam apenas na classificação de SP e PI, enquanto que o I-Freq e o C-Freq são fundamentais para a discriminação de PE, assim como Freq-PP3. O parâmetro I-Freq contribuiu para a identificação de SP e PE, enquanto que Freq-PP1 e Freq-PP2 para as três classes. Os demais parâmetros contribuem pouco para a discriminação entre as classes.



**Figura 8:** Gráfico da relevância de cada parâmetro para cada uma das três classes.

O gráfico da Figura 9 (valores de relevância multiplicados por 100 para facilitar visualização) mostra que o parâmetro de maior relevância é o Freq - PP3, em seguida os parâmetros Freq-PP1 e I-Freq têm alta relevância, em torno de 30. Os AMP, ASL e o Freq-PP2 apresentam relevância um pouco abaixo de 20 e o C-Freq entre 5 e 10. O demais parâmetros apresentaram valores abaixo de 5, indicando pouca ou nenhuma influência na classificação.

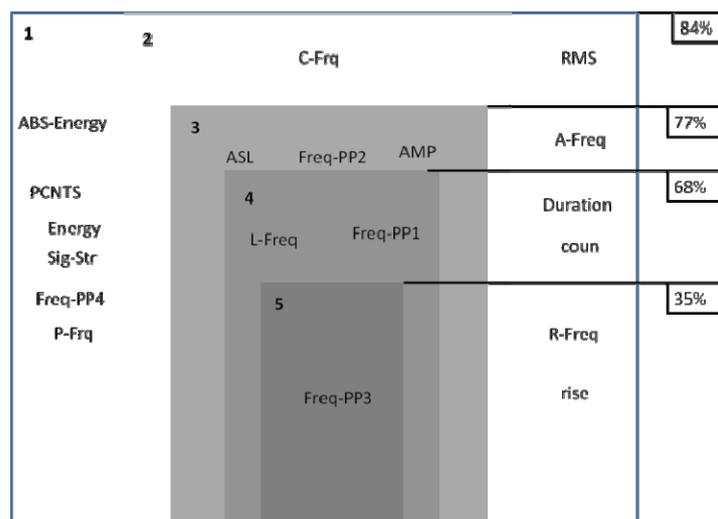


**Figura 9:** Em cinza o histograma das relevâncias para as três classes juntas. As estrelas indicam a relevância de cada parâmetro para as três classes juntas.

Para confirmar a influência de cada parâmetro na discriminação das classes, criaram-se cinco conjuntos com os pares de entrada e saída, conforme Figura 10. Quanto mais no interior do gráfico, maior a relevância.

Os conjuntos de entrada foram formados da seguinte forma: o valor do parâmetro contido no conjunto foi mantido inalterado e os não contidos no conjunto foram substituídos pelo seu valor médio. Por exemplo, no conjunto 5, os valores de Freq-PP3 foram mantidos, enquanto que os demais parâmetros foram substituídos pela média. Depois de formado, cada conjunto foi testado no classificador.

A Figura 10 indica que a taxa de acerto entre o conjunto 1 e o conjunto 2 é praticamente igual, confirmando que os parâmetros com relevância inferior a 5 não influenciam na classificação. A eliminação de C-Freq, reduziu o acerto em 7%. O conjunto 4 alcançou quase de 70%, usando apenas 3 parâmetros, e o conjunto 5, 35%, com apenas 1 parâmetro. Este resultado confirma o indicado pela Figura 9, que os parâmetros com relevância menor que 5 não influenciam significativamente na classificação.



**Figura 10:** Separação de conjuntos pela relevância. À direita o percentual de acerto na classificação de cada conjunto.

Com objetivo de corroborar os resultados apresentados, uma nova rede foi treinada utilizando os mesmos pares de entrada e saída já utilizados neste item. Contudo, a entrada contém apenas os parâmetros do conjunto 2 da Figura 10, isto é, apenas os sete mais relevantes. A configuração da rede foi a mesma utilizada nos testes anteriores.

As Tabelas 8 e 9 apresentam os resultados obtidos na classificação com a rede treinada com todos os parâmetros e a classificação com a rede treinada com os sete parâmetros mais relevantes (C-Freq, ASL, AMP, I-Freq, Freq-PP1, Freq-PP2, Freq-PP3), respectivamente.

**Tabela 8:** Tabela confusão da rede treinada com todos os 19 parâmetros de entrada.

ACERTOS (CONJUNTOS DE TREINAMENTO) QUANTIDADE/PERCENTUAL			
	SP	PE	PI
SP	1331/75,24%	210/11,87%	228/12,89%
PE	203/18,27%	817/73,54%	91/8,19%
PI	279/5,42%	235/4,56%	4638/90,02%
Média total de acerto	6786/84,49%		
ACERTOS (CONJUNTOS DE TESTE) QUANTIDADE/PERCENTUAL			
	SP	PE	PI
SP	333/76,03%	56/12,79%	49/11,19%
PE	40/14,13%	217/76,68%	26/9,19%
PI	71/5,52%	52/4,04%	1164/90,44%
Média total de acerto	1714/85,36%		

**Tabela 9:** Tabela confusão da rede treinada com os 7 parâmetros mais relevantes (C-Freq, ASL, AMP, I-Freq, Freq-PP1, Freq-PP2, Freq-PP3).

<b>ACERTOS (CONJUNTOS DE TREINAMENTO) QUANTIDADE/PERCENTUAL</b>			
	<b>SP</b>	<b>PE</b>	<b>PI</b>
<b>SP</b>	979/55,34%	418/23,63%	372/21,03%
<b>PE</b>	122/10,98%	818/73,63%	171/15,39%
<b>PI</b>	219/4,25%	185/3,59%	4748/92,16%
<b>Média total de acerto</b>	6545/81,49%		
<b>ACERTOS (CONJUNTOS DE TESTE) QUANTIDADE/PERCENTUAL</b>			
	<b>SP</b>	<b>PE</b>	<b>PI</b>
<b>SP</b>	301/68,72%	63/14,38%	74/16,89%
<b>PE</b>	44/15,55%	190/67,14%	49/17,31%
<b>PI</b>	48/3,73%	42/3,26%	1197/93,01%
<b>Média total de acerto</b>	1688/84,06%		

A rede treinada com os sete parâmetros mais relevantes alcançou um desempenho muito próximo da rede treinada com todos os parâmetros, apresentando uma redução de 4% na classificação correta no conjunto de treinamento e de apenas 1% no conjunto de teste. Destaca-se que nestes testes os valores de acerto foram maiores do que de treinamento, o que normalmente não acontece em classificação de padrão, porém, há possibilidade de que isso ocorra com alguns conjuntos de dados.

#### 4. CONCLUSÕES

O presente projeto almejava realizar uma série de investigações de separação de classes de sinais de Emissão Acústica para monitoramento de dutos rígidos, dando continuidade aos trabalhos anteriores [referências]. Inovadoramente, os estudos agora foram focados principalmente na tentativa de discriminar as classes Propagação Estável (PE) da classe Propagação Instável (PI). Levando-se em consideração que houve também a realização de testes com duas classes e estudo de relevância de parâmetros, as principais conclusões deste trabalho são:

- Havendo propagação da trinca até o rompimento do corpo de prova, atinge-se quase de 100% de acerto na separação das classes SP e P, quando o conjunto de sinais contém todos os parâmetros relevantes. Isso reforça estatisticamente os resultados obtidos nos trabalhos anteriores.
- Em relação à relevância dos parâmetros estudados (19 neste trabalho, máximo possível no aparelho de EA empregado), os parâmetros que se mostraram mais eficientes são FRQ PP3, FRQ PP1, I-FRQ, FRQ PP2, ASL, AMP e C-FRQ.
- Em relação às classificações com três classes, inovação neste projeto, atinge-se cerca de 86% de acerto total de classificação quando há propagação até rompimento do corpo de prova, índice considerado significativo em função dos poucos parâmetros empregados. Entretanto, a separação entre SP e PE é bem mais complexa que SP e PI e vice-versa, assim como entre PE e PI. Este resultado pode encontrar explicações na pouca diferença que há em termos de fenômeno de Emissão Acústica entre o momento de uma deformação elástica e início de uma deformação plástica. Há de se destacar, porém, que os resultados logrados neste trabalho são bastante relevantes quando comparados aos anteriores, permitindo um desenvolvimento significativo no embasamento necessário de conhecimento para construção de um sistema artificialmente inteligente de detecção de propagação de defeitos em dutos rígidos.
- Os testes com o sistema de Reclassificação, recorrendo a uma forma menos conservadora de classificação de padrões, permitem aumentar os índices de acerto.

#### 5. TRABALHOS FUTUROS

Uma sugestão de continuidade de estudo será estudar e viabilizar a formação de novos parâmetros característicos dos sinais, seja por combinação dos atuais em alguma forma de cálculo, ou através da análise

da forma de onda dos sinais, que foram adquiridas nos últimos ensaios deste projeto pela equipe do Laboratório de Metalurgia Física da UFRGS.

Há também a possibilidade de utilização de técnicas de processamento de sinais, como Análise dos Componentes Principais (PCA) para separar os sinais referentes à propagação do defeito dos demais sinais de outras fontes existentes no corpo de prova durante o ensaio hidrostático.

## 6. AGRADECIMENTOS

Os autores gostariam de agradecer ao CNPQ, a CAPES e FAPERJ, pelo suporte financeiro, ao Laboratório de Processamento de Sinais da COPPE (LPS) pela utilização de seus computadores e programas.

## 7. BIBLIOGRAFIA

- [1] Pinto, C.F.C., Silva, R.R., Calôba, L.P., *et al.*, ‘Automatic Detection of Defects Propagation in Pipelines: Part I – Pattern Recognition’, resultados submetidos.
- [2] Pinto, C.F.C, “Monitoração de Defeitos em Dutos Rígidos por Emissão Acústica e Redes Neurais, Dissertação M.Sc., Universidade Federal do Rio de Janeiro, Rio de Janeiro, Brasil, 2011.
- [3] Silva R. R, Calôba L. P, Siqueira M. H., *et al.*, “Pattern recognition of weld defects detected by radiographic test”., *NDT&E International*, v.37, n.6, 461-470., 2004.
- [4] Carvalho, A. A. Silva, R.R. Silva, Rebello, J.M.A., *et al.*, “Pattern Recognition Techniques Applied to the Detection and Classification of Welding Defects by Magnetic Testing”, *Research in Nondestructive Evaluation*, v.21, n. 2, 91-111, 2010.
- [5] Silva, R.R., Soares, S.D., Calôba, L.P., *et al.*, “Detection of the propagation of defects in pressurized pipes by means of the acoustic emission technique using artificial neural networks”. *Insight*, v.48, n.1, 45-51, 2006.
- [6] Silva, R. R., Calôba, L. P., Siqueira, M. H., *et al.*, “Evaluation of the relevant characteristic parameters of welding defects and probability of correct classification using linear classifiers”. *Insight*, v.44, n.10, 616-622, 2002.
- [7] J.M. Seixas, L.P. Calôba, Delpino, I., “Relevance Criteria for Variance Selection in Classifier Designs”. In: *International Conference on Engineering Applications of Neural Networks*, pp.451-454, 1996.
- [8] Haykin S., *Neural Networks – A Comprehensive Foundation.*, USA, Macmillan College Publishing. Inc., 1994
- [9] Duda, R.O., Hart, P.E., Stork, D.G., *Pattern Classification*, 2<sup>nd</sup> edition , U.S.A., 2001
- [10] T. Hastie, Tibshirani, R., Friedman, J., *The Elements of Statistical Learning – Data Mining, Inference, and Prediction*, 2<sup>nd</sup> edition, USA, 2008.
- [11] Silva, R. R., Siqueira, M.H.S., Souza, M.P.V., *et al.*, “Estimated accuracy of classification of defects detected in welded joints by radiographic tests”. In: *NDT & E International*, 38: 335-343, 2005.
- [12] Silva, R. R., Mery, D., Soares, S. D., “Evaluation of Acoustic Emission Signal Parameters for Identifying the Propagation of Defects in Pressurized Tubes”, *Materials Evaluation*, v. 66, p. 493-500, 2008.

# USO DE REDES NEURAIAS ARTIFICIAIS NA DETECÇÃO DE PROPAGAÇÃO DE DEFEITOS EM DUTOS RÍGIDOS

Carlos Fernando Carlim Pinto<sup>1</sup>, Romeu R. da Silva<sup>2</sup>, Luiz P. Calôba<sup>3</sup>  
e Sergio Damasceno Soares<sup>4</sup>

*Copyright 2011, ABENDI.*

*Trabalho apresentado durante a 11ª Conferência sobre Tecnologia de Equipamentos.*

*As informações e opiniões contidas neste trabalho são de exclusiva responsabilidade do(s) autor(es).*

## SINOPSE

O interesse no monitoramento de equipamentos em tempo real é crescente nos dias de hoje, visando a maior segurança de operação dos mesmos. O ensaio de Emissão Acústica vem sendo objeto de desenvolvimentos com o intuito de aplicação em diversos tipos de equipamentos, com destaque na inspeção de dutos rígidos e flexíveis. O presente trabalho apresenta a metodologia e os resultados obtidos de um estudo de aplicação do método de Emissão Acústica para detectar defeitos em propagação em dutos rígidos pressurizados, sendo um trabalho pioneiro nessa área de pesquisa. Para tal, foram confeccionados corpos de prova com defeitos inseridos artificialmente, empregando-se a técnica de ultrassom por TOFD para acompanhar o crescimento dos defeitos no duto submetido a ensaio hidrostático. Os sinais resultantes foram divididos em classes de Propagação, Propagação Estável e Propagação Instável, e usados como dados de entrada na implementação de classificadores não lineares via Redes Supervisionadas do tipo Retropropagação do Erro. Os resultados atingiram acertos de classificação próximos a 86%, comprovando a eficiência do método para as condições testadas até o presente momento.

<sup>1</sup> M.Sc., Engenheiro Elétrico – Laboratório de Processamento de Sinais (LPS/PEE/COPPE/UFRJ, [carloscarlim@gmail.com](mailto:carloscarlim@gmail.com)).

<sup>2</sup> D.Sc., Engenheiro Metalurgista – (LPS/PEE/COPPE/UFRJ, [romeu@romeu.eng.br](mailto:romeu@romeu.eng.br)).

<sup>3</sup> D.Sc., Engenheiro Elétrico - Laboratório de Processamento de Sinais (LPS/PEE/COPPE/UFRJ, [caloba@lps.ufrj.br](mailto:caloba@lps.ufrj.br)).

<sup>4</sup> D.Sc., Engenheiro Mecânico – (Petrobras/CENPES/TMEC, [sdama@petrobras.com.br](mailto:sdama@petrobras.com.br)).

## 1. INTRODUÇÃO

No mundo moderno, há inegável importância da utilização dos Ensaios Não Destrutivos (END) na avaliação da integridade estrutural de equipamentos. No passado, poucos eram os ensaios aplicáveis, basicamente se restringindo ao Ensaio Visual, Líquidos Penetrantes, Partículas Magnéticas, Radiografia e Ultrassom. Dentre os ensaios não destrutivos atuais, destaca-se o método de Emissão Acústica (EA), o qual está baseado na detecção de fontes de sinais acústicos que são emitidas durante a propagação de descontinuidades e deformações plásticas acentuadas. Por ser um método qualitativo, o ensaio de emissão acústica não fornece as dimensões das descontinuidades, as quais são fornecidas por outros métodos de ensaios não destrutivos, como o ultrassom. Uma vez que só fornece indicações de descontinuidades ativas durante o carregamento das estruturas, um dos principais objetivos de sua aplicação é o monitoramento em tempo real de equipamentos.

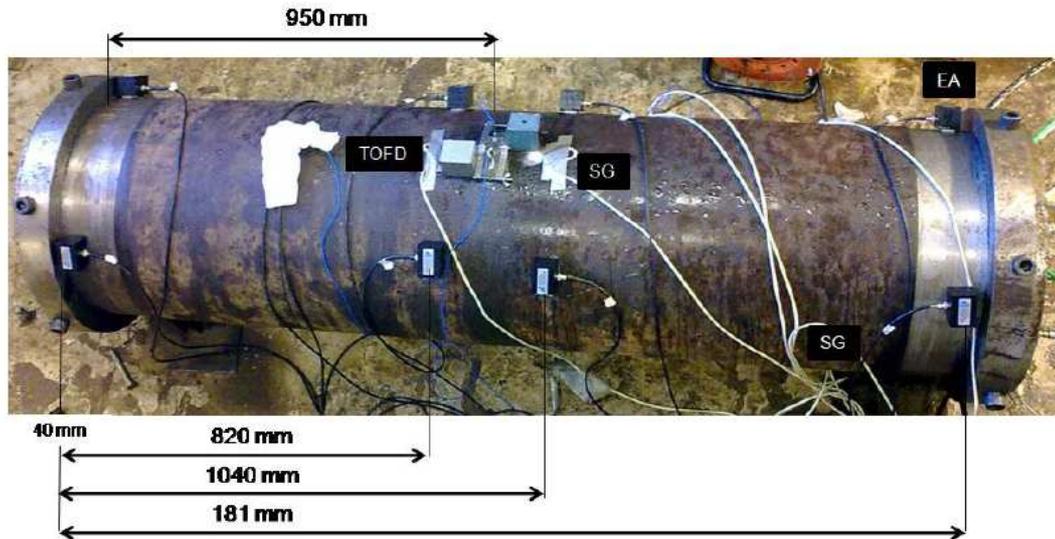
Uma das principais linhas de pesquisa e desenvolvimento hoje na área de END é a utilização de ferramentas de processamento de sinais, imagens e reconhecimento de padrões para semi-automatização ou automatização de processos de detecção e classificação de defeitos em equipamentos. Diversos destes trabalhos vêm sendo desenvolvidos na última década com os sinais de ultrassom computadorizado e imagens radiográficas digitais [1-5].

Motivado pela importância da Emissão Acústica entre os métodos não destrutivos usados na inspeção de equipamentos, e a potencialidade de se implementar classificadores não lineares pelas técnicas de rede neurais, o presente trabalho tem como objetivo desenvolver classificadores não lineares de padrões, tendo como entrada os parâmetros dos sinais de EA, visando detectar o crescimento dos defeitos em dutos rígidos em três classes de sinais: Sem Propagação, Propagação Estável e Propagação Instável, as quais foram definidas pelo acompanhamento por ultrassom (TOFD) de crescimento de defeitos simultaneamente à realização de ensaio hidrostático em corpos de prova (trecho de dutos). É importante destacar que o presente trabalho faz parte de um trabalho de dissertação de mestrado e de um projeto de trabalho de pesquisa realizado entre Petrobras/CENPES/TMEC, LPS/COPPE e LAMEF/UFRGS.

## 2. ANÁLISE DOS ENSAIOS DE EMISSÃO ACÚSTICA

### 2.1. *Materials*

O material dos corpos de prova é aço API XL Grau 60, tendo estes 20 polegadas de diâmetro e 14,5 mm de espessura. Os tubos tiveram suas extremidades usinadas a fim de que fossem montados dois flanges para contenção do fluido de pressurização (vedação feita com *o-rings* de borracha). Foram usinadas trincas elípticas nas superfícies internas e externas dos tubos, cujas dimensões eram diferentes em cada ensaio. Foram realizados seis ensaios ao todo no projeto, porém, apresentam-se neste artigo apenas os dois últimos ensaios por se tratarem dos resultados mais conclusivos do projeto. Para ilustração, a figura 1 contém um desenho esquemático típico do corpo de prova com a instrumentação utilizada para o monitoramento dos ensaios hidrostático.



**Figura 1:** Esquema de posicionamento dos sensores próximos à região de presença da trinca interna na superfície do corpo de prova. Cotas em milímetros.

## 2.2. Aquisição dos parâmetros de emissão acústica

Os sinais de emissão acústica foram adquiridos durante os ensaios de pressão hidrostática, utilizando o equipamento Disp 16C da PASA (*Physical Acoustic South America*). Após a aquisição, os sinais foram processados no próprio equipamento, sendo os parâmetros que foram adquiridos: Tempo de subida, Contagem, Energia, Duração, Amplitude, A-FRQ, RMS, ASL, PCNTS, R-FRQ, i-FRQ, SIG, Strength, ABS-Energy, FRQPP1, FRQPP2, FRQPP3, FRQPP4 e C-FRQ [6].

## 2.3. Monitoramento do crescimento dos defeitos

O crescimento destas trincas foi monitorado através de ensaios de ultra-som usando a técnica TOFD (*Time of Flight Diffraction*).

## 2.4. Sincronização dos arquivos de emissão acústica e pressão

Com o monitoramento da pressurização e do crescimento dos defeitos artificiais, além dos sinais de emissão acústica, que se encontram sempre em arquivos distintos, foi estabelecido um procedimento para sincronizá-los, pois a atividade de emissão acústica está relacionada com o carregamento imposto e com a propagação do defeito. Os sinais de EA resultantes dos ensaios foram filtrados de maneira simples apenas para separar, por tempo de chegada, aqueles que proviam dos sensores próximos aos defeitos.

## 2.5. *Separação dos sinais*

Após sincronização dos arquivos, os eventos de emissão acústica foram divididos nas classes SP (Sem Propagação) e Propagação (P), ou SP, PE (Propagação Estável) e Propagação Instável (PI).

## 2.6. *Pré-processamento dos dados*

Primeiramente, os dados que estavam inicialmente em formato de arquivo DTA foram convertidos em formato ASC II. Posteriormente, os dados foram normalizados adequadamente para melhor desempenho no treinamento das redes neurais.

## 2.7. *Análise de relevância dos parâmetros de emissão acústica*

Este critério mede a relevância de cada parâmetro de entrada do classificador, isto é, mede o quanto este influencia no desempenho da rede neural. O método consiste em procurar mudanças significativas na resposta do classificador, ao substituir os valores de cada parâmetro pelo valor médio [7].

A relevância  $R(X_i)$  da componente  $X_i$  do vetor  $X$  pode ser calculada pela seguinte equação:

$$R(X_i) = \frac{\sum_{j=1}^P \|y(x_j) - y(x_{ji})\|^2}{P} \quad (1)$$

$R(X_i)$ : relevância da componente  $i$  dos vetores de entrada  $x$  ;

$P$  : número de padrões (treinamento ou teste);

$y(x_j)$ : vetor de saída da rede neural para cada padrão  $i$   $x$  de entrada apresentado;

$x_{ji}$  : vetor de entrada  $j$   $x$  , em que a  $i$ -ésima componente foi substituída pelo seu valor médio tomado sobre todos os vetores de entrada;

$y(x_{ji})$  : saída da rede para a entrada  $x_{ji}$  .

## 2.8. *Elaboração dos algoritmos para desenvolvimento dos classificadores e avaliação de classificação*

Para implementação dos classificadores de padrões, foram implementados classificadores de padrões não-lineares usando redes neurais artificiais [8,9].

## 2.9. *Treinamento dos algoritmos*

Os classificadores foram desenvolvidos se estimando seus parâmetros (vetores sinápticos e bias) usando o método de retropropagação do erro. Algumas configurações de parâmetros de treinamento foram estudadas para fornecer o melhor resultado possível na distinção das classes e garantir a generalização dos classificadores [8, 9].

## 2.10. *Estimação das acurácia dos classificadores*

Em reconhecimento de padrões, uma das questões mais polêmicas é saber qual a verdadeira acurácia dos classificadores, isto é, qual o índice de acerto esperado para qualquer conjunto de sinais/dados testado na classificação. Vários conjuntos de dados para treinamento e teste foram sorteados aleatoriamente sem reposição de dados com intuito de estimar a acurácia de identificação dos sinais de Sem Propagação (SP), Propagação Estável (PE) e Propagação Instável (PI) de defeitos, assim como para duas classes (SP e P).

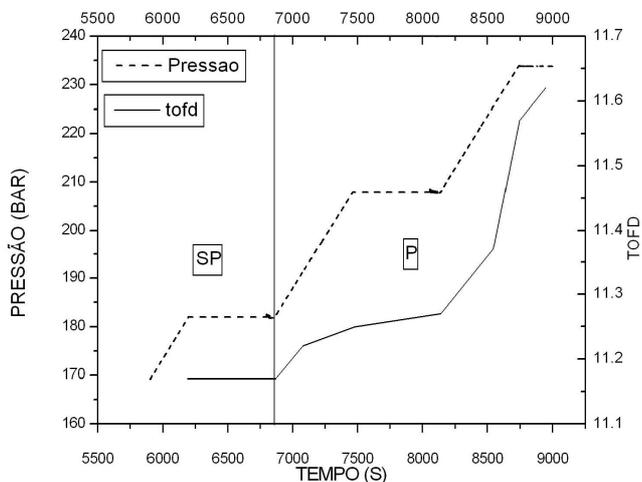
# 3. Resultados e Discussões

Inicialmente, foram realizados diversos treinamentos para avaliar qual seria a melhor configuração do classificador a ser usada com as entradas apresentadas visando a melhor generalização possível (testes para três classes). Foram treinadas redes sem momento, com momento, sem momento e alfa variável e com momento e alfa variável, variando-se de 1 a 10 neurônios na camada intermediária. Os testes foram realizados com taxa de aprendizagem de 0,1 e momento de 0,9, e depois com 0,5 e 0,9, respectivamente [8]. Definido os melhores parâmetros a serem utilizados no treinamento da rede, partiu-se para os testes com sorteio aleatório sem reposição de conjuntos de treinamento (80%) e teste (20%) [10]. Foi definido um classificador ótimo com 6 neurônios, sem momento, com valor de alfa inicial igual a 0,05, fator de incremento de alfa de 1,05 e fator de decréscimo de 0,9, alfa máximo de 0,2 (parâmetros ajustados no programa MATLAB).

## 3.1. *Separação em Duas Classes (Primeiro ensaio)*

Para este ensaio, foi usada no corpo de prova uma trinca interna no centro do mesmo com uso de uma retífica manual com disco de corte com raio igual a 12 mm. A geometria do defeito ficou com um formato semi-elíptico com 160 mm de comprimento, 1,1 mm de largura e 7,33 mm de profundidade.

Analisando o gráfico da figura 2 a seguir, para primeiramente uma situação de duas classes, os sinais foram separados na classe SP (Sem Propagação) até o tempo de 6868s (181 bar) e classe P (Propagação) entre 6869s e 12837s (233 bar). Resultando em 2207 sinais de SP e 7834 de P.



**Figura 2:** Crescimento do Defeito com Tempo e Pressão de ensaio.

Foram sorteados aleatoriamente 10 pares de conjunto de treinamento e teste (20% dos sinais pra teste).

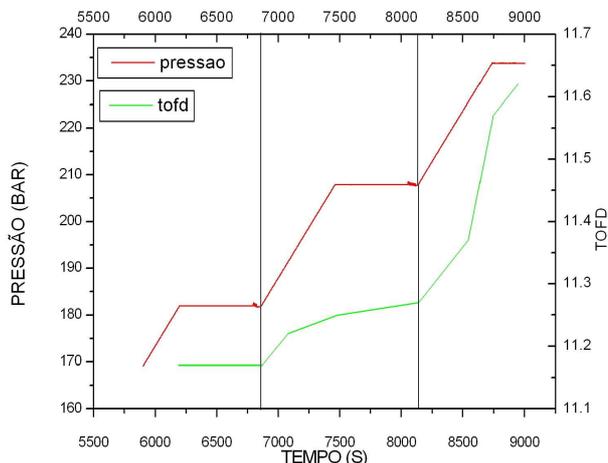
A tabela 1 a seguir apresenta os valores de média de acerto (acurácia de classificação) em quantidade e percentual referentes aos 10 conjuntos sorteados de treinamento e teste. Analisando esta tabela, os valores de acerto de treinamento são compatíveis com valores já encontrados nos projetos anteriores para discriminação com duas classes [6, 11], o mesmo ocorrendo com os sinais usados para testar os classificadores. A pouca diferença entre a média de acerto de treinamento e teste comprova a generalização do classificador, sem provável supertreinamento.

**Tabela 1:** Resultados da média de acerto para os 10 conjuntos de treinamento e teste (duas classes).

Acertos (Conjuntos de treinamento)			Acertos (Conjuntos de teste)		
Quantidade/Percentual			Quantidade/Percentual		
	SP	P		SP	P
SP	920/52,17%	843/47,83%	SP	261/58,91%	182/41,09%
P	235/3,74%	6035/96,26%	P	147/9,41%	1417/90,59%
<b>Média total de acerto</b>	6955/86,58%		1678/83,60%		

### 3.2. Separação em Três Classes Sem Reclassificação (Primeiro ensaio)

Para situação de classificação com três classes, analisando a figura 3, os sinais foram separados na classe SP (Sem Propagação) até o tempo de 6868s (181 bar), na classe PE (Propagação Estável) entre 6869 e 8143 s (208 bar) e na classe PI (Propagação Instável) entre 8144s e 12837s (233 bar). Resultando em 2207 sinais de SP, 1394 sinais de PE e 6439 sinais de PI.



**Figura 3:** Crescimento do Defeito com Tempo e Pressão de ensaio.

Inicialmente, foram feitos testes com o sistema de classificação considerando apenas o único valor positivo na saída dos neurônios, isto é, o que se denomina **Sem Reclassificação** (mais conservador) [7].

Pela tabela 2 de confusão a seguir, a acurácia de acerto com três classes **Sem Reclassificação** atinge 74% para os conjuntos de treinamento e 71% com os conjuntos de teste, comprovando a generalização dos classificadores não lineares. Há de se destacar que a configuração da rede neural foi a mesma em todas as situações, conforme explanado anteriormente.

Analisando-se separadamente os índices médios de acerto pra cada uma das três classes agora estudadas, a classe PI é a que tem a melhor acurácia de classificação (95%), o que era esperado, pois fenomenologicamente é quando há o crescimento instável do defeito e os eventos de emissão acústica se tornam mais perceptíveis no sistema de aquisição. A classe PE confunde bastante com SP e também com PI, o que prova que constatar o exato momento de transição do estado de não propagação do defeito para o estado de uma propagação elástica, estável, assim como a transição do regime elástico para o plástico é consideravelmente mais complexa. Os valores de Não Classificação (mais de uma saída positiva ou todas negativas) estão dentro do esperado no que normalmente acontece em reconhecimento de padrão.

**Tabela 2:** Resultados da média de acerto para os 10 conjuntos de treinamento e teste (três classes sem reclassificação).

Acertos (Conjuntos de treinamento)				Acertos (Conjuntos de teste)					
Quantidade/Percentual				Quantidade/Percentual					
	SP	PE	PI	NC*		SP	PE	PI	NC
<b>SP</b>	921/68,90%	54/4,02%	362/27,08%	1057 /13 %	<b>SP</b>	204/51,13%	21/5,17%	174/43,70%	157/8%
<b>PE</b>	89/13,82%	289/45,20%	262/40,97%		<b>PE</b>	28/12,66%	41/18,56%	150/68,76%	
<b>PI</b>	144/2,89%	107/2,14%	4737/94,97%		<b>PI</b>	33/2,67%	17/1,38%	1187/95,94%	
<b>Média total de acerto</b>	5947/74,14%					1431/71,18%			

NC – Não classificação.

### 3.3. Separação em Três Classes Com Reclassificação (Primeiro ensaio)

O próximo passo nos testes foi avaliar a classificação dos mesmos pares de conjuntos formados no item anterior no sistema de **Reclassificação**. Nesta metodologia, lembrando, o neurônio que indica a classe é o de maior valor [7], apontando a maior probabilidade de que um sinal pertença a essa classe.

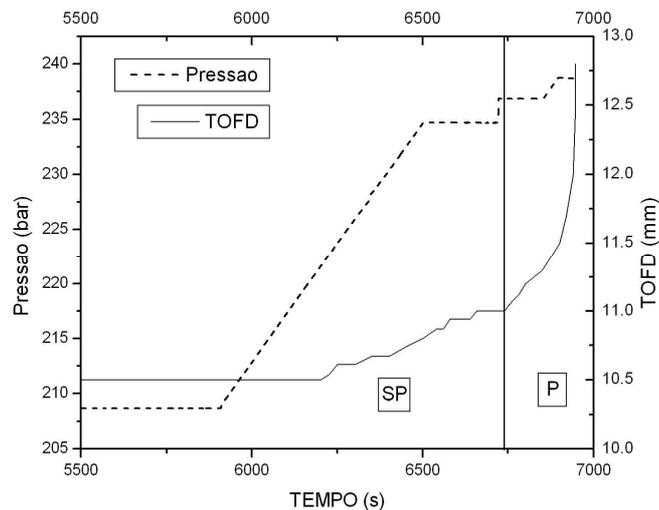
A tabela 3 de confusão apresenta os resultados obtidos nesta classificação. As acurácias de treinamento e teste aumentaram em relação à situação anterior, como era de se esperar. Em treinamento a média chegou a quase 83%, e nos testes, 73,54%, 2,5% a mais que para **Sem Reclassificação**. Esta tabela de confusão também indica que as classes que mais se confundem são PE com SP e PI, ratificando os resultados do item anterior.

**Tabela 3:** Resultados da média de acerto para os 10 conjuntos de treinamento e teste (três classes com reclassificação).

	Acertos (Conjuntos de treinamento)				Acertos (Conjuntos de teste)		
	Quantidade/Percentual				Quantidade/Percentual		
	SP	PE	PI		SP	PE	PI
SP	1149/65,54%	281/16,03%	323/18,43%	SP	219/48,34%	23/5,08%	211/45,58%
PE	144/12,98%	739/66,64%	226/20,38%	PE	43/15,09%	47/16,49%	195/68,42%
PI	206/3,99%	205/3,97%	4758/92,05%	PI	42/3,29%	19/1,49%	1215/95,22%
Média total de acerto	6646/82,75%				1481/73,54%		

### 3.4. Separação em Duas Classes (Segundo ensaio)

A geometria e dimensões do corpo de prova e da trinca neste ensaio foram similares ao do ensaio anterior. Analisando o gráfico da figura 4 a seguir, para primeiramente uma situação de duas classes, os sinais foram separados na classe SP (Sem Propagação) até o tempo de 6740s e classe P (Propagação) a partir de 6741s, resultando em 18908 sinais de SP e 810 de P. Foram sorteados aleatoriamente 10 pares de conjunto de treinamento e teste (20% pra teste).



**Figura 4:** Crescimento do Defeito com Tempo e Pressão de ensaio.

A tabela 4 a seguir apresenta os valores de média de acerto em quantidade e percentual referentes aos 10 conjuntos sorteados de treinamento e teste.

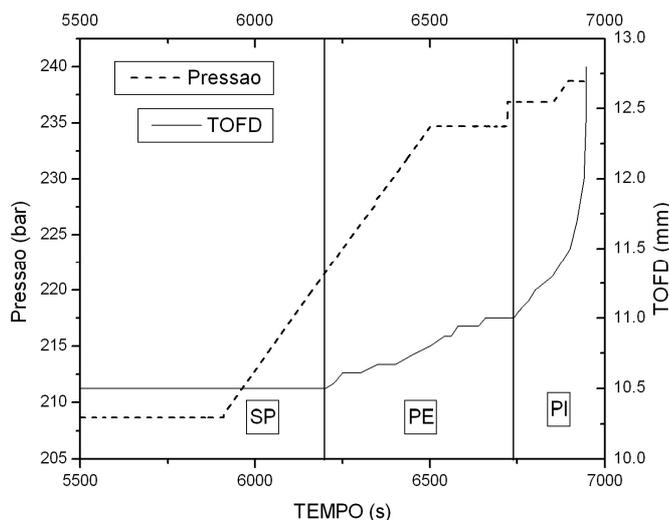
Na tabela 4, constam-se excelentes resultados de acurácia de classificação para os sinais de treinamento e teste com valores praticamente iguais, fato que comprova a generalização do classificador não linear. Esses números são similares aos obtidos em publicações anteriores [6, 11] desenvolvido para uma situação em que se utilizaram todos os parâmetros relacionados, e também quando houve rompimento do corpo de prova. Certamente a provável causa pra estes resultados está no fato dos sinais de EA serem evidenciados no crescimento rápido da trinca até o rompimento (vazamento). Ressalta-se, também, que em relação ao ensaio anterior, a separação das classes SP e P foi realizada se somando os sinais de SP e PE, com PI representando P. Ao contrário, anteriormente os sinais de PE foram somados aos sinais de PI, o que também pode ter corroborado para o índice maior de acerto na atual situação.

**Tabela 4:** Resultados da média de acerto para os 10 conjuntos de treinamento e teste (duas classes).

Acertos (Conjuntos de treinamento)			Acertos (Conjuntos de teste)		
Quantidade/Percentual			Quantidade/Percentual		
	SP	P		SP	P
SP	14909/98,53%	222/1,47%	SP	3721/98,54%	55/1,46%
P	17/2,64%	628/97,36%	P	5/3,19%	161/96,81%
Média total de acerto	15536/98,49%		3883/98,47%		

### 3.5. Separação em Três Classes Sem Reclassificação (Segundo ensaio)

Para situação de classificação com três classes, analisando a figura 5, os sinais foram separados na classe SP (Sem Propagação) até o tempo de 6200s, na classe PE (Propagação Estável) entre 6201 até 6740s e na classe PI (Propagação Instável) a partir de 6741s, resultando em 16072 sinais de SP, 2836 sinais de PE e 810 sinais de PI.



**Figura 5:** Crescimento do Defeito com Tempo e Pressão de ensaio.

Pela tabela 5 de confusão a seguir, a acurácia de acerto com três classes **Sem Reclassificação** atinge cerca de 86% para os conjuntos de treinamento e teste, comprovando a generalização dos classificadores não lineares. Há de se destacar que a configuração da rede neural foi a mesma em todas as situações, conforme explanado anteriormente. Estes valores, comparados aos encontrados no teste anterior, na mesma condição, chegam a ter 15% acima de acurácia. Uma provável explicação para índice maior de acerto está no fato de ter acontecido um crescimento do defeito de forma rápida até o vazamento do corpo de prova, aumentando claramente o acerto da classe PI. Além disso, as classes SP e PI apresentaram médias de acerto bem maiores que no ensaio anterior, ao contrário de PE que teve uma redução significativa, havendo muita confusão dessa classe com SP, porém, a proporção de sinais desta classe é bem inferior a SP e PI. A quantidade de sinais não classificados é muito pequena para treinamento, apenas 39, e um pouco maior para teste, 175.

**Tabela 5:** Resultados da média de acerto para os 10 conjuntos de treinamento e teste (três classes sem reclassificação). NC – não classificado.

	Acertos (Conjuntos de treinamento)					Acertos (Conjuntos de teste)			
	Quantidade/Percentual					Quantidade/Percentual			
	SP	PE	PI	NC*		SP	PE	PI	NC
<b>SP</b>	12815/99,86%	17/0,14%	1/0,01%	39/0,25%	<b>SP</b>	3208/99,71%	9/0,28%	0/0,01%	175/8,73%
<b>PE</b>	1864/82,63%	135/5,99%	257/11,38%		<b>PE</b>	452/81,50%	37/6,65%	66/11,86%	
<b>PI</b>	0/0%	13/1,93%	636/98,07%		<b>PI</b>	0/0%	3/1,68%	158/98,32%	
<b>Média total de acerto</b>	13586/86,12%					3403/86,31%			

### 3.6. Separação em Três Classes Com Reclassificação (Segundo ensaio)

O próximo passo nos testes foi avaliar a classificação dos mesmos pares de conjuntos formados no item anterior no sistema de **Reclassificação**.

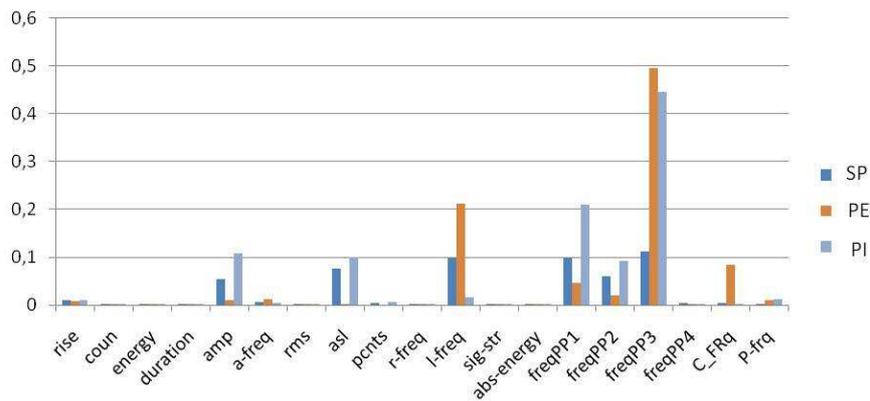
A tabela 6 de confusão apresenta os resultados obtidos nesta classificação. As acurácias de treinamento e teste aumentaram em relação à situação anterior, porém, de forma insignificante, menos de 1%. Obtiveram-se valores idênticos entre o resultado de treinamento e teste (86,45%), provando a generalização do processo de classificação.

**Tabela 6:** Resultados da média de acerto para os 10 conjuntos de treinamento e teste (três classes com reclassificação).

	Acertos (Conjuntos de treinamento)				Acertos (Conjuntos de teste)		
	Quantidade/Percentual				Quantidade/Percentual		
	SP	PE	PI		SP	PE	PI
SP	12824/99,80%	24/0,19%	1/0,01%	SP	3211/99,63%	12/0,36%	0/0,01%
PE	1871/82,52%	146/6,43%	250/11,05%	PE	454/81,08%	40/7,08%	66/11,84%
PI	0/0,02%	13/2,03%	637/97,95%	PI	0/0%	3/1,74%	158/98,26%
Média total de acerto	13607/86,45%				3409/86,45%		

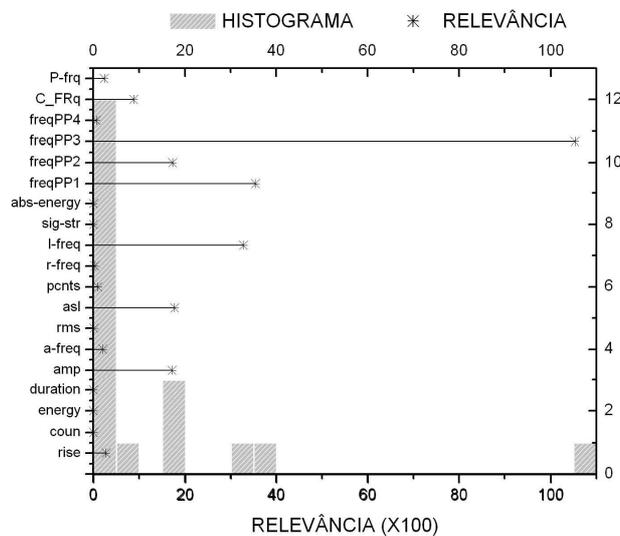
### 3.7. Relevância de Parâmetros

Em relação às investigações da relevância dos parâmetros para discriminação das classes de sinais de EA, o gráfico da figura 6 mostra que AMP e ASL influenciam apenas na classificação de SP e PI, enquanto que o I-Freq e o C-Freq são fundamentais para a discriminação de PE, assim como Freq-PP3. O parâmetro I-Freq contribuiu para a identificação de SP e PE, enquanto que Freq-PP1 e Freq-PP2 para as três classes. Os demais parâmetros contribuem pouco para a discriminação entre as classes.



**Figura 6:** Gráfico da relevância de cada parâmetro para cada uma das três classes.

O gráfico da figura 7 (valores de relevância multiplicados por 100 para facilitar visualização) mostra que o parâmetro de maior relevância é o Freq - PP3, em seguida os parâmetros Freq-PP1 e I-Freq têm alta relevância, em torno de 30. Os AMP, ASL e o Freq-PP2 apresentam relevância um pouco abaixo de 20 e o C-Freq entre 5 e 10. O demais parâmetros apresentaram valores abaixo de 5, indicando pouca ou nenhuma influência na classificação.

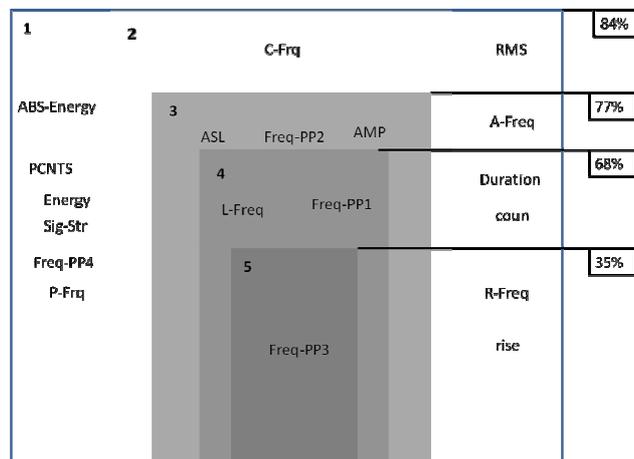


**Figura 7:** Em cinza o histograma das relevâncias para as três classes juntas. As estrelas indicam a relevância de cada parâmetro para as três classes juntas.

Para confirmar a influência de cada parâmetro na discriminação das classes, criaram-se cinco conjuntos com os pares de entrada e saída, conforme figura 8. Quanto mais no interior do gráfico, maior a relevância.

Os conjuntos de entrada foram formados da seguinte forma: o valor do parâmetro contido no conjunto foi mantido inalterado e os não contidos no conjunto foram substituídos pelo seu valor médio. Por exemplo, no conjunto 5, os valores de Freq-PP3 foram mantidos, enquanto que os demais parâmetros foram substituídos pela média. Depois de formado, cada conjunto foi testado no classificador.

A figura 8 indica que a taxa de acerto entre o conjunto 1 e o conjunto 2 é praticamente igual, confirmando que os parâmetros com relevância inferior a 5 não influenciam na classificação. A eliminação de C-Freq, reduziu o acerto em 7%. O conjunto 4 alcançou quase de 70%, usando apenas 3 parâmetros, e o conjunto 5, 35%, com apenas 1 parâmetro. Este resultado confirma o indicado pela figura 7, que os parâmetros com relevância menor que 5 não influenciam significativamente na classificação.



**Figura 8:** Separação de conjuntos pela relevância. À direita o percentual de acerto na classificação de cada conjunto.

Com objetivo de corroborar os resultados apresentados, uma nova rede foi treinada utilizando os mesmos pares de entrada e saída já utilizados neste item. Contudo, a entrada contém apenas os parâmetros do conjunto 2 da figura 8, isto é, apenas os sete mais relevantes. A configuração da rede foi a mesma utilizada nos testes anteriores.

As tabelas 7 e 8 apresentam os resultados obtidos na classificação com a rede treinada com todos os parâmetros e a classificação com a rede treinada com os sete parâmetros mais relevantes (C-Freq, ASL, AMP, I-Freq, Freq-PP1, Freq-PP2, Freq-PP3), respectivamente.

**Tabela 7:** Tabela confusão da rede treinada com todos os 19 parâmetros de entrada.

	Conjuntos de treinamento Quantidade/Percentual				Conjuntos de teste Quantidade/Percentual		
	SP	PE	PI		SP	PE	PI
SP	1331/75,24%	210/11,87%	228/12,89%	SP	333/76,03%	56/12,79%	49/11,19%
PE	203/18,27%	817/73,54%	91/8,19%	PE	40/14,13%	217/76,68%	26/9,19%
PI	279/5,42%	235/4,56%	4638/90,02%	PI	71/5,52%	52/4,04%	1164/90,44%
ACERTOS	6786/84,49%				1714/85,36%		

**Tabela 8:** Tabela confusão da rede treinada com os 7 parâmetros mais relevantes(C-Freq, ASL, AMP, I-Freq,Freq-PP1, Freq-PP2, Freq-PP3).

	Conjuntos de treinamento Quantidade/Percentual				Conjuntos de teste Quantidade/Percentual		
	SP	PE	PI		SP	PE	PI
SP	979/55,34%	418/23,63%	372/21,03%	SP	301/68,72%	63/14,38%	74/16,89%
PE	122/10,98%	818/73,63%	171/15,39%	PE	44/15,55%	190/67,14%	49/17,31%
PI	219/4,25%	185/3,59%	4748/92,16%	PI	48/3,73%	42/3,26%	1197/93,01%
ACERTOS	6545/81,49%				1688/84,06%		

A rede treinada com os sete parâmetros mais relevantes alcançou um desempenho muito próximo da rede treinada com todos os parâmetros, apresentando uma redução de 4% na classificação correta no conjunto de treinamento e de apenas 1% no conjunto de teste. Destaca-se que nestes testes os valores de acerto foram maiores do que de treinamento, o que normalmente não acontece em classificação de padrão, porém, há possibilidade de que isso ocorra com alguns conjuntos de dados.

#### 4. Conclusões

O presente projeto almejava realizar uma série de investigações de separação de classes de sinais de Emissão Acústica para monitoramento de dutos rígidos, dando continuidade aos trabalhos anteriores [referências]. Inovadoramente, os estudos agora foram focados principalmente na

tentativa de discriminar as classes Propagação Estável (PE) da classe Propagação Instável (PI). Levando-se em consideração que houve também a realização de testes com duas classes e estudo de relevância de parâmetros, as principais conclusões deste trabalho são:

- 1) Havendo propagação da trinca até o rompimento do corpo de prova, atinge-se quase de 100% de acerto na separação das classes SP e P, quando o conjunto de sinais contém todos os parâmetros relevantes. Isso reforça estatisticamente os resultados obtidos nos trabalhos anteriores [6, 11].
- 2) Em relação à relevância dos parâmetros estudados (19 neste trabalho, máximo possível no aparelho de EA empregado), os parâmetros que se mostraram mais eficientes são FRQ PP3, FRQ PP1, I-FRQ, FRQ PP2, ASL, AMP e C-FRQ.
- 3) Em relação às classificações com três classes, inovação neste projeto, atinge-se cerca de 86% de acerto total de classificação quando há propagação até rompimento do corpo de prova, índice considerado significativo em função dos poucos parâmetros empregados. Entretanto, a separação entre SP e PE é bem mais complexa que SP e PI e vice-versa, assim como entre PE e PI. Este resultado pode encontrar explicações na pouca diferença que há em termos de fenômeno de Emissão Acústica entre o momento de uma deformação elástica e início de uma deformação plástica. Há de se destacar, porém, que os resultados logrados neste trabalho são bastante relevantes quando comparados aos anteriores, permitindo um desenvolvimento significativo no embasamento necessário de conhecimento para construção de um sistema artificialmente inteligente de detecção de propagação de defeitos em dutos rígidos.
- 4) Os testes com o sistema de Reclassificação, recorrendo a uma forma menos conservadora de classificação de padrões, permitem aumentar os índices de acerto.

## **5. Trabalhos Futuros**

Uma sugestão de continuidade de estudo será estudar e viabilizar a formação de novos parâmetros característicos dos sinais, seja por combinação dos atuais em alguma forma de cálculo, ou através da análise da forma de onda dos sinais, que foram adquiridas nos últimos ensaios deste projeto pela equipe do Laboratório de Metalurgia Física da UFRGS.

Há também a possibilidade de utilização de técnicas de processamento de sinais, como Análise dos Componentes Principais (PCA) para separar os sinais referentes à propagação do defeito dos demais sinais de outras fontes existentes no corpo de prova durante o ensaio hidrostático.

## **6. Agradecimentos**

Os autores gostariam de agradecer ao CNPQ, a CAPES e FAPERJ, pelo suporte financeiro, ao Laboratório de Processamento de Sinais da COPPE (LPS) pela utilização de seus computadores e programas.

## Referências

- [1] Silva R. R, Calôba L. P, Siqueira M. H. S., Rebello J. M. A. (2004): Pattern recognition of weld defects detected by radiographic test. *NDT&E Int*, 37(6):461–70.
- [2] Liao TW, Ni J. An automated radiographic NDT system for weld inspection: part I—weld extraction. *NDT&E Int* 1996;29(3):157–62.
- [3] Liao TW, Li Y. An automated radiographic ndt system for weld inspection: part II—flaw detection. *NDT&E Int* 1998;31(3):183–92.
- [4] Silva RR, Calôba LP, Siqueira MHS, Rebello JMA. Pattern recognition of weld defects detected by radiographic test. *NDT&E Int* 2004;37(6):461–70.
- [5] Carvalho, A. A. Silva, R. R. Silva, Rebello, J.M.A., Sagrilo, L. V. S. Pattern Recognition Techniques Applied to the Detection and Classification of Welding Defects by Magnetic Testing. *Research in Nondestructive Evaluation*, 21 (2): 91 — 111
- [6] Silva, R.R., Soares, S.D., Calôba, L.P., Siqueira, M.H.S., Rebello, J.M.A (2006). Detection of the propagation of defects in pressurized pipes by means of the acoustic emission technique using artificial neural networks. *Insight*, 48(1): 45-51.
- [7] Silva, R. R.; Calôba, L. P.; Siqueira, M. H. S.; Sagrilo, L. V. S.; Rebello, J. M. A. (2002): Evaluation of the relevant characteristic parameters of welding defects and probability of correct classification using linear classifiers. *Insight*, 44 (10): 616-622.
- [8] Haykin S. (1994): *Neural Networks – A Comprehensive Foundation*. USA. Macmillan College Publishing. Inc.
- [9] Duda, R.O.; Hart, P.E., Stork, D.G. (2001): *Pattern Classification*. 2<sup>nd</sup> edition , U.S.A.,
- [10] Silva, R. R.; Siqueira, Marcio H.S.; Souza, M.P.V.; Rebello, João Marcos A ; Calôba, Luiz Pereira (2005) . Estimated accuracy of classification of defects detected in welded joints by radiographic tests. *NDT & E International*, 38: 335-343.
- [11] Silva, R. R. ; Mery, D. ; Soares, Sergio Damasceno . Evaluation of Acoustic Emission Signal Parameters for Identifying the Propagation of Defects in Pressurized Tubes. *Materials Evaluation*, v. 66, p. 493-500, 2008.

## New Approach in Automatic Detection of Defects Propagation in Pipelines

Carlos F. C. PINTO<sup>1</sup>, Romeu R. da SILVA<sup>2</sup>, Luiz P. CALÔBA<sup>3</sup>, Sergio D. SOARES<sup>4</sup>,  
Thomas CLARKE<sup>5</sup>

<sup>1</sup>Signal Processing Laboratory, Federal University of Rio de Janeiro; Rio de Janeiro, Brazil  
Phone: + 55 21 2562-8205, Fax: + 55 21 2562-8205; e-mail: carlos.fernando@lps.ufrj.br

<sup>2</sup>Signal Processing Laboratory, Federal University of Rio de Janeiro; Rio de Janeiro, Brazil; e-mail:  
romeu@romeu.eng.br

<sup>3</sup>Signal Processing Laboratory, Federal University of Rio de Janeiro; Rio de Janeiro, Brazil; e-mail:  
caloba@lps.ufrj.br

<sup>4</sup>Research Center Leopoldo Américo Miguez de Mello, PETROBRAS; Rio de Janeiro, Brazil; e-mail:  
sdama@petrobras.com.br

<sup>5</sup>Physics Metallurgy Laboratory, Federal University of Rio Grande do Sul; Rio Grande do Sul, Brazil; e-mail:  
thomas.grclarke@gmail.com

### Abstract

The interest in monitoring equipment in real time is increasing in nowadays, mainly aiming the greater security of its operations. The Acoustic Emission (AE) testing has been the subject of developments with the aim of application in various types of equipment, especially in the inspection of rigid and flexible pipes. This paper presents the methodologies and results of a study of applying the method of Acoustic Emission to detect propagation in defects in pressurized rigid pipes, being a pioneering work in this area of research. In this way, specimens were manufactured with defects artificially inserted. These specimens were submitted to hydrostatic testing and the defect propagation was monitor by AE. The ultrasound by Time of Flight Diffraction (TOFD) was the technique chosen to monitor the defect growth. The AE resulting signals were divided into the classes No Propagation (NP), Stable Propagation (SP) and Unstable Propagation (UP) and used as inputs set in the implementation of nonlinear classifiers by error back propagation. The correct classification results reached close to 91%, proving the efficiency of the method for the conditions tested in this job.

**Keyword:** Nondestructive testing (NDT), acoustic emission, non-linear pattern classifiers, neural network.

### 1. Introduction

In the modern world, there is undeniable importance of the use of Non Destructive Testing (NDT) to assess the structural integrity of equipment. In the past, there were few applicable tests basically restricted to the Visual Testing, Liquid Penetrant, Magnetic Particle, Radiography and Ultrasound. Among the current NDT, there is the method of Acoustic Emission (AE), which is based on the detection of sources of acoustic signals that are emitted during the propagation of discontinuities and sharp plastic deformation. Because it is a qualitative method, the AE test does not provide the dimensions of the discontinuities, which are provided by other NDT methods such as ultrasound. Since only provides indications of active discontinuities during loading of structures, one of the main goals of its application is the real-time monitoring of equipment.

Motivated by the importance of Acoustic Emission in the methods used in non-destructive inspection of equipment, and capability to implement non-linear classifiers by neural network techniques, this paper describes a work that was developed to implement non-linear pattern classifiers, aiming to detect the growth of defects in rigid pipes by taking the parameters of AE signals as input set [1]. The signals were divided into three classes: No Propagation, Stable Propagation and Unstable Propagation, which were defined by ultrasound monitoring growth defects, synchronized with the hydrostatic testing.

## 2. Analysis of Acoustic Emission Tests

### 2.1 Materials

The specimens were made of API XL Grade 60 steel, 20 inches in diameter and 14.5 mm in thickness. Elliptical cracks were created in the inner and outer surfaces of the pipe, whose dimensions were different in each test. Six hydrostatic tests were conducted in all in the project, however, this article presents only two tests by targeting more conclusive results of the project. For illustration, Figure 1 contains a typical schematic drawing of the section of pipe with the instrumentation used for monitoring of hydrostatic tests.

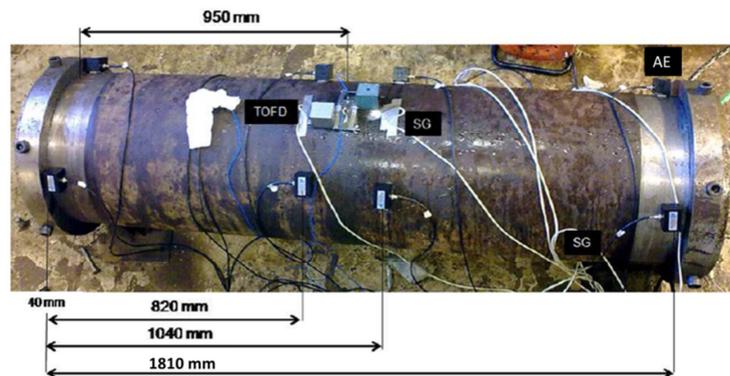


Figure 1. Schematic of positioning of the sensors closer to the region of presence of internal cracks in the surface of the specimens. Dimensions in mm. TOFD: ultrasound transducer; SG: strain gage sensor; AE: acoustic emission sensor.

For these testing was created in specimen's center an internal crack using a grinding with a cutting disk with radius of 12 mm. The geometry of the defect has been a semi-elliptical shape with 160 mm long, 1.1 mm wide and 7.33 mm deep.

### 2.2 Acquisition parameters of acoustic emission

Acoustic emission signals were acquired during the hydrostatic pressure tests, using the Disp 16 c equipment of PASA (Physical Acoustic South America). After the acquisition, the signals were processed in own equipment.

In the present work, the following features were obtained: Rise Time, Count, Energy, Duration, Amplitude, A-FRQ, RMS, ASL, PCNTS, R-FRQ, I-FRQ, Sig-Strength, ABS-Energy, FRQPP1, FRQPP2, FRQPP3, FRQPP4, C-FRQ, P-FRQ [2].

### 2.2 Synchronization of files of acoustic emission Signals

With the monitoring of the pressurization and the growth of artificial defects, in addition to the acoustic emission signals, which are always in separate files, was established a procedure for synchronizing them, because the acoustic emission activity is related to the charging and with the propagation of the defect. The AE signals resulting from tests were filtered just to separate by arrival time those who provided the sensors close to defects.

### ***2.3 Separation of signals***

After synchronization of files, the acoustic emission events were divided into the classes NP No Propagation (NP), Stable propagation (SP) and Unstable Propagation (UP)[2].

### ***2.4 The Neural Classifier***

Artificial neural networks were used to implement non-linear patterns classifiers [3, 4].

The classifiers were developed using the algorithm Backpropagation, a multilayer feedforward topology and performed as activation function the hyperbolic tangent. Some configurations of training parameters were studied to provide the best possible result in the distinction of classes and to ensure the generalization of classifiers [3, 4]. Several sets of data for training and testing were randomly selected without replacement of data with a view to estimate the accuracy of the identification signals No Propagation (NP), Stable Propagation (SP) and Unstable Propagation (UP) of defects, as well as two classes (NP and P).

After, several trainings had been conducted to assess what would be the best configuration of the classifier to be used with the inputs provided aiming at the best possible generalization (testing for three classes). We defined a good classifier with six neurons in the hidden layer and momentum of 0.9, variable learning rate with the initial value at 0.05, growth factor of 1.05 and decrease factor of 0.9 and set maximum at 0.2 (adjusted parameters in the program MATLAB). Set the best parameters to be used in network training, we decided to test with random selection without replacement of sets of training (80%) and test (20%) [5].

### ***2.5 Analysis of relevance of the features of acoustic emission***

This criterion measures the relevance of each input variable from the feature space, i.e., a measure of how this influences the performance of the neural network. The method is to seek significant changes in the response of the classifier, by substituting the values of each variable by the average value [6].

## **3. Discussion and Results**

### ***3.1 First Testing***

To sort the situation with three classes, examining Figure 2, the signals were separated in the NP class until the time of 6868s (181 bar), in SP class (Stable propagation) between 6869 and 8143 s (208 bar) and UP class between 8144s and 12837s (233 bar). Resulting in 2,207 samples from NP, 1,394 of SP and 6,439 of UP.

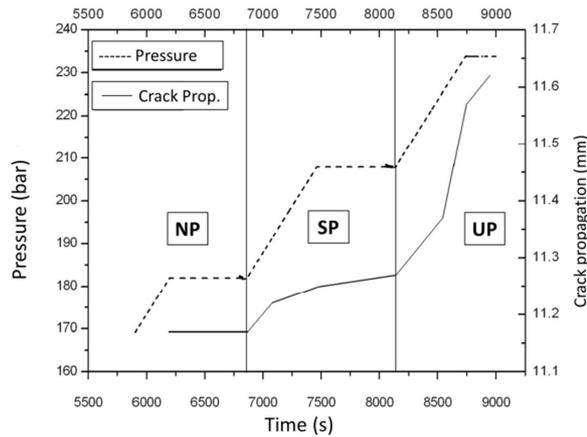


Figure 2. The dashed line represents the plot of Pressure vs. Time and the continuous line represents the Plot Crack propagation vs. Time.

Initially, tests were made with the classification system considering the single positive value at the network output layer, i.e., **Without Reclassification** [7].

From table 1 the performance on classification of three classes reaches 78% for training sets and 77% with the test sets, proving the generalization of nonlinear classifiers. It must be noted that the configuration of the neural network was the same in all situations, as explained above. Analyzing separately the average rates of success for each one of the three classes studied, UP is the class that has the best performance - 95%, which was expected, since when there is unstable propagation defect the acoustic emission events become more noticeable in the acquisition system. The SP class mixes with NP and also with UP, which proves that finds the exact moment of transition from not propagation of the defect to propagating elastic, and then the transition from elastic to plastic is considerably more complex. The Not Classified values (more than one output positive or all negative) were expected as usually happens in pattern recognition.

**Table 1. Results of the average accuracy for 10 training and test sets (three classes without reclassification).**

	Performance (training set)					Performance (test set)			
	NP	SP	UP	NC*		NP	SP	UP	NC
NP	83%	4%	13%	12%	NP	82%	4%	14%	12%
SP	16%	77%	7%		SP	15%	77%	8%	
UP	4%	4%	92%		UP	4%	4%	92%	
<b>Average total success</b>	78%					1553/77%			

NC – Not Classified.

### 3.2 Second Testing

To sort the situation with three classes, analyzing Figure 3, the signals were separated in the NP class the time between 4000 and 6000s, in SP class between 6000 and 8000s and UP class between 8000 and 13000s. Resulting in 2,053 samples from NP, 1,045 samples SP and 383 samples of UP.

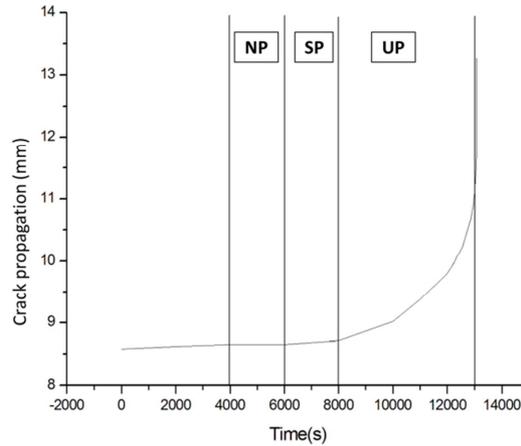


Figure 3. Plot of Crack propagation vs. Time.

From table 2, the performance on classification of three classes reaches 91% for both sets. Analyzing each individual class, noted that the trained neural network could discriminate correctly the three classes, including the SP class, which obtained an increase in around 10% of accuracy when compared with the results of the first test. The not classified values (more than one output positive or all negative) were insignificant, almost zero.

**Table 2- Results of the average accuracy for 10 training and test sets (three classes without reclassification).**

	Performance (training set)					Performance (test set)			
	NP	SP	NP	NC		NP	SP	UP	NC
NP	92.2%	6.4%	0.3%	0.3%	NP	93%	6.1%	0.3%	0.3%
SP	9.7%	86.7%	4.0%		SP	8.9%	84%	4.2%	
UP	0.7%	3.8%	95.4%		UP	1.4%	7.6%	91.4%	
<b>Average total success</b>	91%				91%				

### 3 Relevance of the features

The accuracy achieved by the classifier demonstrated that it is possible to separate the three classes of signals, however in pattern recognition a question always arises. Is that all features have the same importance in discriminating between classes? That is, all parameters have the same relevance in training the classifier. This chapter seeks to answer this question.

In relation to investigations of the relevance of the features for discrimination between classes of AE signals, the graph of Figure 4 shows that AMP and ASL influence only in the classification of NP and UP, while the I-Freq and C-Freq are fundamental to discrimination of SP, as well as Freq-PP3. The feature I-Freq also contributed to the identification of SP, while Freq-PP1, Freq-PP2 and Freq-PP3 for the three classes. Other features contribute little to the discrimination between the classes.

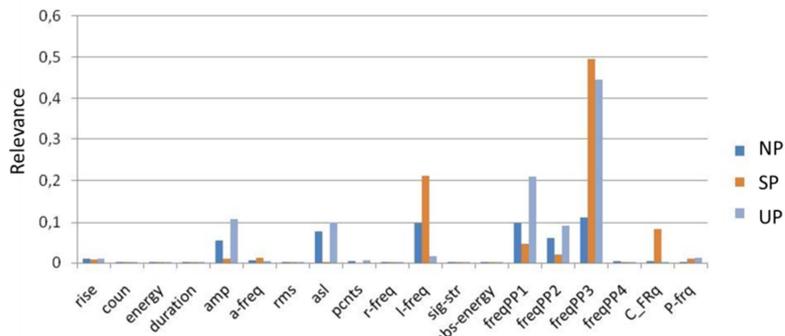


Figure 4: Graph of the relevance of each feature for each of the three classes.

The graph in Figure 5 (relevance values multiplied by 100 to facilitate visualization) shows that the most relevant feature is the Freq - PP3, then the features Freq-PP1 and I-Freq have high relevance, around 30. The features AMP, ASL and Freq-PP2 are relevant just below 20 and C-Freq between 5 and 10. The other features had values below 5, indicating little or no impact on the classification.

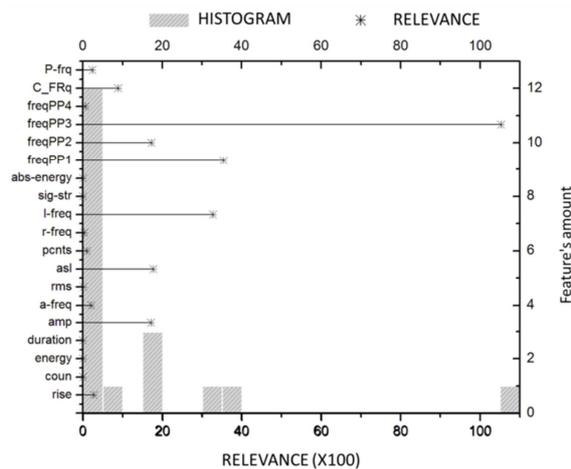


Figure 5: In the gray histogram of relevance to all three classes together. The stars indicate the relevance of each feature for all three classes together.

To confirm the influence of each feature in the discrimination of the classes created five sets with pairs of input and output, as shown in Figure 6. Each set overlaps, causing the relevance increase in internal direction of graph, i.e., how much more inside the chart larger relevance. The input sets were formed as follows: the value of the feature contained in the set was kept unchanged and the rest have been replaced by its mean value. For example, in set 5, the values of Freq-PP3 were kept, while the other features have been replaced by average. Once formed, each set was tested in the classifier.

Figure 6 indicates that the performance between the set 1 and the set 2 is almost equal. The elimination of C-Freq, reduced the accuracy by 7%. The set 4 reached almost 70%, using only three features, and the set 5, 35%, with only one feature. This confirms the result shown in Figure 5, the relevance features less than five do not significantly influence the classification.

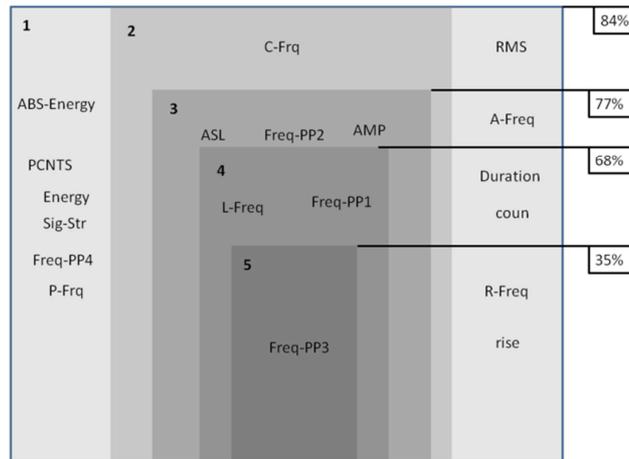


Figure 6: Separation of sets by relevance. At right, the percentage of correct classification of each set.

Aiming to corroborate the results, a new network was trained using the same input and output pairs already used on this item. However, the entry contains only the features from the set 2 of Figure 6, that is, only the seven most relevant. Your network configuration was the same used in previous tests.

Tables 3 and 4 present the results obtained in the classification with the network trained with all features and classification with the network trained with the seven most relevant features (C-Freq, ASL, AMP, I-Freq, Freq-PP1, Freq-PP2, Freq-PP3), respectively.

**Table 3: confusion matrix of network trained with all 19 input features.**

	Performance (training set)					Performance (test set)			
	NP	SP	NP	NC		NP	SP	UP	NC
NP	80.5%	6.2%	13.3%	11.7%	NP	81.6%	5.6%	12.8%	10.7%
SP	16.3%	77.0%	6.7%		SP	12.6%	77.7%	9.7%	
UP	4.6%	3.7%	91.7%		UP	4.1%	3.4%	92.5%	
Average total success	77.7%				79.3%				

**Table 4: Confusion matrix of network trained with the 7 most relevant features (C-Freq, ASL, AMP, I-Freq, Freq-PP1, Freq-PP2, Freq-PP3).**

	Performance (training set)					Performance (test set)			
	NP	SP	NP	NC		NP	SP	UP	NC
NP	60.4%	17.8%	21.8%	10.5%	NP	76.5%	3.6%	19.9%	14.5%
SP	10.5%	81.1%	8.3%		SP	12.1%	74.6%	13.3%	
UP	2.5%	3.6%	93.8%		UP	2.4%	3.1%	94.5%	
Average total success	76.8%				76.4%				

The network trained with the seven most relevant features reached a performance very close to the trained network with all features, a decrease of 1% in correct classification in the training set and only 3% in the test set. It is noteworthy that the values of these tests were higher accuracy than training, which usually does not happen in pattern classification, however, there is possibility of this happening with some data sets.

## 4 Conclusion

This project aimed to conduct a series of investigations of separation of classes of acoustic emission signals for monitoring of rigid ducts, building on previous work [1, 8]. Innovatively, studies have now been focused mainly in an attempt to discriminate the classes, Stable Propagation (SP) from Unstable Propagation (UP).

With regard to classifications with three classes, which was an innovation in this project, it was possible to reach approximately 91% at classification accuracy when there is crack propagation until total breaking of the specimen, a rate considered significant in terms of few features applied. However, the separation between NP and SP is far more complex than NP and UP and vice versa, and between SP and UP. This result can find explanations in the little difference that there is in terms of acoustic emission phenomena between the time an elastic deformation and the beginning of a plastic deformation.

With regard to the relevance of the features studied (nineteen in this work, as much as possible in the apparatus of AE applied), the features that are more efficient are Freq-PP3, Freq-PP1, I-Freq, Freq-PP2, ASL, AMP and C-Freq.

The results reached in this work are quite relevant when compared to previous [1,8], enabling a significant development in basement knowledge necessary for construction of an artificially intelligent system for detected propagating defects in rigid pipes.

## 5 Future Work

In a future work, some new relevant features of the AE signals will be add to the input sets of the classifiers, either by combination of the present features in some form of calculation, or by analyzing the waveform of the signals, which were acquired in recent trials of this project by staff of the Laboratory of Physical Metallurgy, UFRGS.

There is also the possibility of using signal processing techniques such as Principal Component Analysis (PCA) to separate the signals related to the propagation of the defect of the other signals from unknown sources in the specimen during the hydrostatic tests.

## Acknowledgments

The authors would like to express their gratitude to CNPq, CAPES and FAPERJ for financial support, the Signal Processing Laboratory at COPPE (LPS) by using their computers and softwares.

## References

1. R.R. Silva, S.D. Soares, L.P. Calôba, M.H.S. Siqueira and J.M.A Rebello. 'Detection of the propagation of defects in pressurized pipes by means of the acoustic emission technique using artificial neural networks'. *Insight*, 48(1), pp 45-51, 2006.
2. C.F.C Pinto, 'Monitoring of Defects of Rigid Pipes by Acoustic Emission and Neural Networks', M.Sc. Dissertation, COPPE/UFRJ, Rio de Janeiro, Brazil, 2011.
3. S. Haykin, 'Neural Networks – A Comprehensive Foundation'. USA. Macmillan College Publishing. Inc. ,1994.

4. R.O Duda, P.E. Hart and D.G. Stork, 'Pattern Classification', 2<sup>nd</sup> edition , USA,2001.
5. R.R. Silva, M.H.S. Siqueira, H.S. Marcio, M.P.V. Souza, J. M.A. Rebello, ; L. P. Calôba, 'Estimated accuracy of classification of defects detected in welded joints by radiographic tests'. NDT & E International, 38: 335-343, 2005.
6. J.M. Seixas, L.P. Calôba, I. Delpino, 'Relevance Criteria for Variance Selection in Classifier Designs'. In: International Conference on Engineering Applications of Neural Networks, pp.451-454, 1996.
7. R.R. Silva, L.P. Calôba, M.H.S. Siqueira, L.V.S. Sagrilo, J.M.A. Rebello, 'Evaluation of the relevant characteristic parameters of welding defects and probability of correct classification using linear classifiers', Insight, 44 (10): pp 616-622, 2002.
8. R.R. Silva, D. Mery, S.D. Soares, 'Evaluation of Acoustic Emission Signal Parameters for Identifying the Propagation of Defects in Pressurized Tubes', Materials Evaluation, v. 66, p. 493-500, 2008.