



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

Carlos Fernando Carlim Pinto

Tese 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.

VIII, 78 p.: il.: 29,7cm.

Orientadores: Luiz Pereira Calôba

Romeu Ricardo da Silva.

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

Referencias Bibliográficas: p. 83-86.

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 tudo que podiam e não podiam 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. Quando tudo estava perdido e eu desacreditado, ele foi o único que acreditou no meu potencial, confiando apenas na minha palavra. 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 equipamentos 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 Probabilidade de Propagação (PoP) que, ao nosso ver, representa uma significativa inovação neste campo de pesquisa.

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 equipment 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 probability of propagation (PoP), which are a significant innovation in this field of research.

Sumário

1	Introdução	16
2	Revisão Bibliográfica	18
2.1	Aprendizado Supervisionado	18
2.2	Aprendizado Não Supervisionado	20
2.3	Conclusão.....	22
3	Revisão Teórica	23
3.1	Emissão Acústica	23
3.1.1	Princípios e Teoria.....	23
3.1.2	Propagação do Sinal	24
3.1.3	Tipos de Sinais.....	25
3.1.4	Processamento dos Sinais.....	26
3.1.5	Parâmetros de EA	27
4	Metodologia.....	30
4.1	Análise dos Ensaios de Emissão Acústica	30
4.1.1	Materiais	30
4.1.2	Aquisição dos parâmetros de Emissão Acústica	31
4.2	O Classificador Neural.....	33
4.2.1	Definição das Classes	34
4.2.2	Acurácia dos Classificadores.....	35
4.2.3	Critério de Relevância	35

4.3	Curva de Probabilidade de Propagação (PoP)	37
4.4	Análise de Agrupamentos	45
4.4.1	<i>K-means</i>	46
4.4.2	Mapas Auto Organizacionais (SOM)	47
5	Discussão e Resultados.....	50
5.1	Classificador Neural.....	50
5.1.1	Ensaio 1	50
5.1.2	Ensaio 2	52
5.1.3	Estudo da Relevância das Entradas	53
5.2	Curva PoP	58
5.3	Análise de Agrupamentos dos Sinais de Emissão Acústica	69
5.3.1	Primeiro Passo	70
5.3.2	Segundo Passo	72
5.3.3	Terceiro Passo.....	78
6	Conclusões.....	84
7	Trabalhos Futuros	86
8	Referências Bibliográficas.....	87
	Apêndice.....	90

Índice de Ilustrações

Figura 1 – Diagrama de blocos do aprendizado supervisionado [6]	18
Figura 2 - Características da emissão acústica [15].....	25
Figura 3 - À esquerda um sinal transiente e à direita um sinal contínuo de EA [14]....	26
Figura 4 - Determinação do tempo de chegada [14]	27
Figura 5 - Parâmetros de um sinal transiente [14].....	28
Figura 6 - Esquema de posicionamento dos sensores perto da região da fissura na superfície interna do corpo de prova. Dimensões em mm. TOFD: transdutor de ultrassom; SG: sensor calibre de tensão; AE: sensor de emissão acústica [3].....	30
Figura 7 – A linha tracejada representa a parcela de pressão vs. tempo e a linha contínua representa a propagação da rachadura vs tempo.	34
Figura 8- A linha contínua cinza representa a probabilidade de SP, a probabilidade de linha preta contínua o PE e a linha de tracejada a probabilidade PI.....	38
Figura 9 - A curva com a linha contínua é a densidade estimada e as linhas tracejadas são as funções do Kernel para cada ponto indicado [24].....	40
Figura 10 - A linha contínua representa a densidade de probabilidade da “classe” e a linha tracejada a densidade da “não classe”. Dados hipotéticos.....	42
Figura 11 - Curva de probabilidade posteriori para a classe, gerada a partir da densidade de probabilidade.	43
Figura 12 – Gráfico da probabilidade em relação ao tempo.....	43
Figura 13 - Curvas de aproximação.....	44
Figura 14 - Algoritmo <i>K-means</i>	46
Figura 15 - Grade de neurônios de duas dimensões, com quatro entradas e nove neurônios, formando um mapa 3x3.....	48

Figura 16 – Algoritmo de formação do SOM.....	48
Figura 17 - A linha tracejada representa a parcela de pressão vs. tempo e a linha contínua representa a propagação da Trinca vs tempo.....	50
Figura 18 - Gráfico da propagação da trinca pelo tempo.	52
Figura 19 - Gráfico da relevância de cada parâmetro para cada uma das três classes ...	54
Figura 20 - Em cinza o histograma das relevâncias para as três classes juntas. As estrelas indicam a relevância de cada parâmetro para as três classes juntas.	55
Figura 21 - Separação de conjuntos pela relevância. À direita o percentual de acerto na classificação de cada conjunto.....	56
Figura 22 - Probabilidade da classe SP. Os pontos representam a probabilidade para cada valor de Z. A linha tracejada preta a curva gerada 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 com todos os sinais do ensaio 2. .	59
Figura 23 - Evolução do coeficiente “a” da equação de aproximação da probabilidade de SP.....	60
Figura 24 - Evolução do coeficiente "b" da equação de aproximação da probabilidade SP	60
Figura 25- Probabilidade da classe PE. Os pontos representam a probabilidade para cada valor de Z. A linha contínua preta representa a curva gerada 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 com todos os sinais do ensaio 2.....	61
Figura 26 - Evolução do coeficiente “a” da equação de aproximação da probabilidade de PE.....	62

Figura 27 - Evolução do coeficiente “b” da equação de aproximação da probabilidade de PE.....	62
Figura 28 - Evolução do coeficiente “c” da equação de aproximação da probabilidade de PE.....	63
Figura 29 - Evolução do coeficiente “d” da equação de aproximação da probabilidade de PE.....	63
Figura 30 - Probabilidade da classe PI. Os pontos representam a probabilidade para cada valor de Z. A linha tracejada cinza representa a curva gerada 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 com todos os sinais do ensaio 2.	64
Figura 31 - Evolução do coeficiente “a” da equação de aproximação da probabilidade de PI.....	65
Figura 32 - Evolução do coeficiente “b” da equação de aproximação da probabilidade de PI.....	65
Figura 33 - Curva PoP.	66
Figura 34 - Curva PoP – Destaque dos dados SP.	66
Figura 35 - Curva PoP – Destaque dos dados PE.....	67
Figura 36 - Curva PoP –Ensaio 1 – separação das classes.	68
Figura 37 - SOM resultante dos dados	71
Figura 38 - Mapa das ativações dos neurônios. (a) ativação da classe SP. (b) ativação para classe PE. (c) ativação para classe PI.	72
Figura 39 - Fluxograma da formação do novo conjunto de treinamento do classificador supervisionado.	74
Figura 40 - Fluxograma contendo o <i>K-means</i> aplicado ao Grupo 1.....	75

Figura 41 - Fluxograma. Algoritmo <i>K-means</i> aplicado ao grupo 4.	76
Figura 42 - Fluxograma de formação do Conjunto 2.	78
Figura 43 - Mapa das distâncias dos dados do Conjunto 2.	80
Figura 44 - Mapa das ativações dos neurônios. (a) ativação da classe SP. (b) ativação para classe PE. (c) ativação para classe PI	81
Figura 45 - gráfico de classes em relação ao tempo de ensaio. (a) todos os dados excluídos. (b) Conjunto 2.....	81
Figura 46 - - gráfico de classes em relação ao tempo de ensaio. Os quadrados representam os dados do Conjunto 2 e os pontos representam todos os dados excluídos.	82

Índice de Tabelas

Tabela 1 - Fatores de Influencia [15].....	29
Tabela 2 - Parâmetros de Emissão Acústica coletados. [14-16].....	32
Tabela 3- Definições da rede neural	39
Tabela 4 – Equações Z para as respectivas classes.	42
Tabela 5 – Modelo de aproximação da probabilidade de cada classe.	44
Tabela 6 - Resultados da precisão média de 10 conjuntos de treinamento e teste (três classes sem reclassificação).....	51
Tabela 7 - Resultados da precisão média de 10 conjuntos de treinamento e teste (três classes sem reclassificação).....	53
Tabela 8 - Tabela confusão da rede treinada com todos os 19 parâmetros de entrada...	57
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).....	57
Tabela 10 - Equações de regressão tangente hiperbólica.	58
Tabela 11 - Equações de regressão tangente hiperbólica de Ensaio 1.....	67
Tabela 12 - Tabela de erros de classificação percentual.	69
Tabela 13 - Parâmetros de construção do SOM. Os valores foram determinados empiricamente.	70
Tabela 14 - Parâmetros de treinamento algoritmo <i>K-means</i>	73
Tabela 15 - Tabela Confusão.....	73
Tabela 16 – Resultados da acurácia média para 10 conjuntos de treino e teste formados com os dados de Conjunto 1.....	74
Tabela 17 - Resultado da acurácia média para 10 conjuntos de treino e teste.	74
Tabela 18 - Tabela confusão para K=2.....	75

Tabela 19 - Tabela confusão para K=3.....	75
Tabela 20 - Tabela confusão para K=4.....	75
Tabela 21 - Tabela confusão para K=5.....	76
Tabela 22 - Tabela confusão para K=2.....	76
Tabela 23 - Tabela confusão para K=3.....	77
Tabela 24 - Tabela confusão para K=4.....	77
Tabela 25 – Tabela confusão para K=5.	77
Tabela 26 – Tabela confusão do fluxograma apresentado na figura 12. Em destaque os dados formadores do Conjunto 2.....	78
Tabela 27 - Resultados da acurácia média para 10 conjuntos de treino e teste formados com os dados de Conjunto 2.....	79
Tabela 28 – Tabela confusão dos dados de Ensaio 2 aplicados ao classificador treinado com os dados do Conjunto 2.....	79
Tabela 29 - Tabela confusão dos dados do Ensaio 2 com a transição da classe PE de 6000 para 5500 segundos	82

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 a medicina, na indústria existem os ensaios não-destrutivos (END), só que aplicados a materiais e equipamentos. Estes ensaios constituem uma das principais ferramentas do controle da qualidade, contribuindo para reduzir os custos, garantir a qualidade e aumentar a confiabilidade operacional dos equipamentos. Destaca-se que os métodos de END são largamente utilizados nos setores petrolífero, químico, aeronáutico, siderúrgico, naval, eletromecânico, entre outros.

Dentre os ensaios não destrutivos, destaca-se o método de inspeção por Emissão Acústica que está baseado na detecção de sinais acústicos que são emitidos durante a propagação de descontinuidades e deformações plásticas acentuadas. Contudo, este método não é capaz de fornecer as dimensões dos defeitos, uma vez que só fornece indicações de descontinuidades ativas durante o carregamento das estruturas. Sua principal aplicação é a monitoração em tempo real de equipamentos, sendo o dimensionamento realizado por outros métodos de ensaios não destrutivos como, por exemplo, o ultrassom.

As técnicas de reconhecimento de padrões e modelagem de sinais associadas a ensaios não destrutivos vêm se mostrando como ferramentas poderosas no desenvolvimento de sistemas automáticos ou semi-automáticos de inspeção de equipamentos [1-4].

Motivado pela importância da Emissão Acústica na inspeção de equipamentos e diante da potencialidade de se implementar classificadores não lineares pelas técnicas de

rede neurais, o presente trabalho tem como objetivo principal desenvolver classificadores de padrões, a partir dos parâmetros dos sinais de Emissão Acústica (EA) capazes de discriminar o crescimento dos defeitos de fratura em duto rígido em três classes de sinais: Sem Propagação (SP), Propagação Estável (PE) e Propagação Instável (PI). Os sinais de EA foram adquiridos em ensaios hidrostáticos de tubos contendo trincas superficiais monitoradas pela técnica ToFD (*Time of Flight Diffraction*) de ensaio ultrassônico.

Após o desenvolvimento do classificador, com os resultados obtidos e em conjunto com técnicas de probabilidade foi desenvolvida a base para a construção de curvas de Probabilidade de Propagação (PoP), as quais têm forma semelhante à conhecida curva de Probabilidade de Detecção (PoD), entretanto, são conceitualmente diferentes. Desta forma, apresenta-se o conceito de formação de curvas de PoP e os primeiros resultados obtidos que guiarão a estudos futuros.

Ressalta-se que os sinais utilizados neste trabalho são provenientes dos ensaios realizados em um projeto de P&D entre a PETROBRAS/CENPES/TEMEC 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/TEMEC e a UFRJ/COPPE/LPS.

2 Revisão Bibliográfica

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. Neste capítulo, descreve-se o resultado de uma revisão bibliográfica sobre o tema estudado.

2.1 Aprendizado Supervisionado

No aprendizado supervisionado, um “professor” fornece categorias ou classes para cada padrão em um conjunto de treinamento [5]. 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 [6]. A figura 1 apresenta o diagrama de blocos deste tipo de aprendizado.

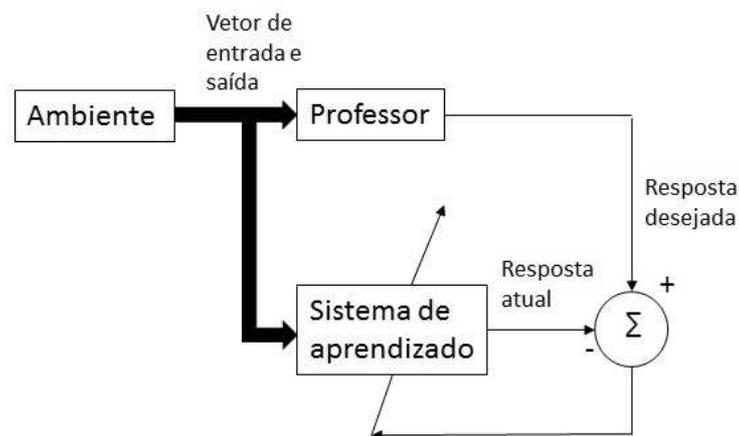


Figura 1 – Diagrama de blocos do aprendizado supervisionado [6]

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. [6]

Da Silva et al. [7] utiliza técnicas de reconhecimento de padrões para classificar defeitos de soldagem. Em seu trabalho ele utiliza características geométricas extraídas de radiografias de juntas soldadas para treinar redes neurais artificiais. Ele afirma que o desempenho do classificador está diretamente relacionado a qualidade das características utilizadas e que a acurácia estimada foi da ordem de 80%.

Yuki et al. [8] demonstra que redes neurais artificiais podem ser treinadas utilizando formas de ondas de EA simuladas por sensor piezoelétrico 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. [9] 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.

Da Silva et al. [1] 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 classificar o crescimento da trinca em duas classes distintas, Sem Propagação (SP) e Propagação (P). Em seu trabalho, o desempenho do classificador treinado alcança 92% de acertos na classificação dos sinais.

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 [6].

De acordo com Duda [5], 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.

Godin et al. [10] 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 à 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. [11] 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. [12] 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.

Marec et al. [13] em seu trabalho propõe identificar e caracterizar danos locais em concreto polímero. De acordo com a autora este material é um composto complexo em que as técnicas apresentadas por outros autores [10,11] não são eficientes na classificação das falhas. E com objetivo de melhorar o processo de classificação deste tipo de material é aplicado o algoritmo de classificação não supervisionada *fuzzy C-means* associado com análise de componentes principais.

2.3 Conclusão

As bibliografias apresentadas demonstram que as técnicas de reconhecimento de padrões são vastamente aplicadas no reconhecimento de padrões de sinais de EA. Em diversos casos ocorre a combinação de mais de uma técnica para a caracterização adequada dos eventos. Contudo os estudos dos sinais de EA gerados em dutos de aço pressurizados combinados com tais técnicas ainda é pouco explorado como linha de pesquisa.

Esta tese aplica diversas técnicas de aprendizado supervisionado e não supervisionado com o objetivo principal de classificar os eventos em Sem Propagação (SP), Propagação Estável (PE) e Propagação Instável (PI).

3 Revisão Teórica

3.1 Emissão Acústica

3.1.1 Princípios e Teoria

Em 1950, Joseph Kaiser publicou em sua tese de PhD o primeiro estudo abrangente sobre o tema, 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 emissão acústica (EA) é o único método de ensaio não destrutivo (END), que o material inspecionado gera o próprio sinal ao apresentar falha [14]. 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 às 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 [15].

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 de materiais metálicos. A

monitoração pode ser feita a partir de fontes remotas e 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. [15]

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 contínuo com baixa amplitude e pouca distância de propagação, sendo considerado ruído. [16]

3.1.2 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 que convertem os movimentos da superfície do material em sinais elétricos. Estes sinais são processados para indicar e localizar as fontes de emissão acústica [15]. A Figura 2 detalha o princípio da EA.

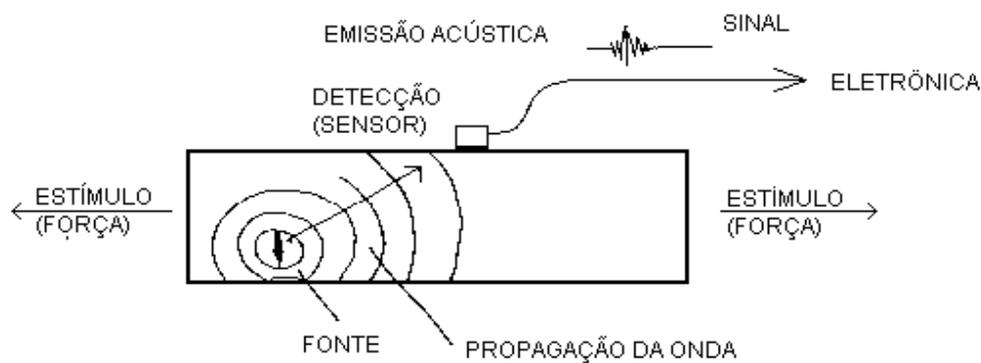


Figura 2 - Características da emissão acústica [15]

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 [16].

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 [15].

3.1.3 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.

(b) Emissão contínua: caracterizado 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.

A Figura 3 ilustra os dois tipos de emissão.

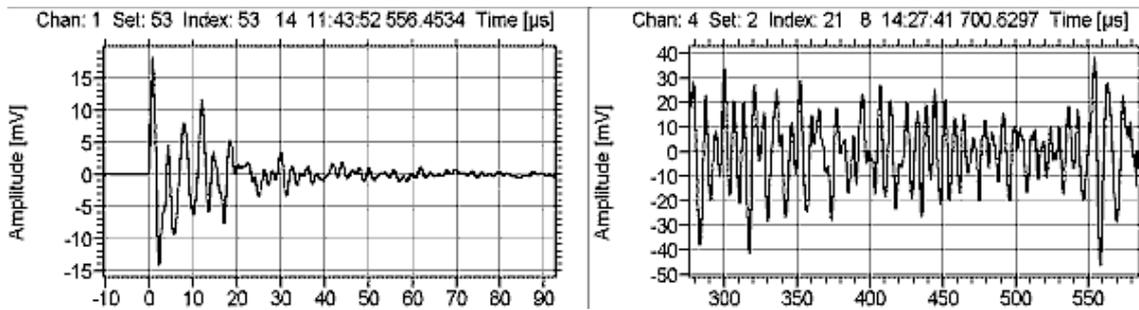


Figura 3 - À esquerda um sinal transiente e à direita um sinal contínuo de EA [14]

No caso que estudamos, 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 [14].

3.1.4 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 e é fundamental para o cálculo da localização da trinca. A Figura 4 apresenta um exemplo de forma de onda com os limites positivo e negativo, assim como o tempo de chegada.

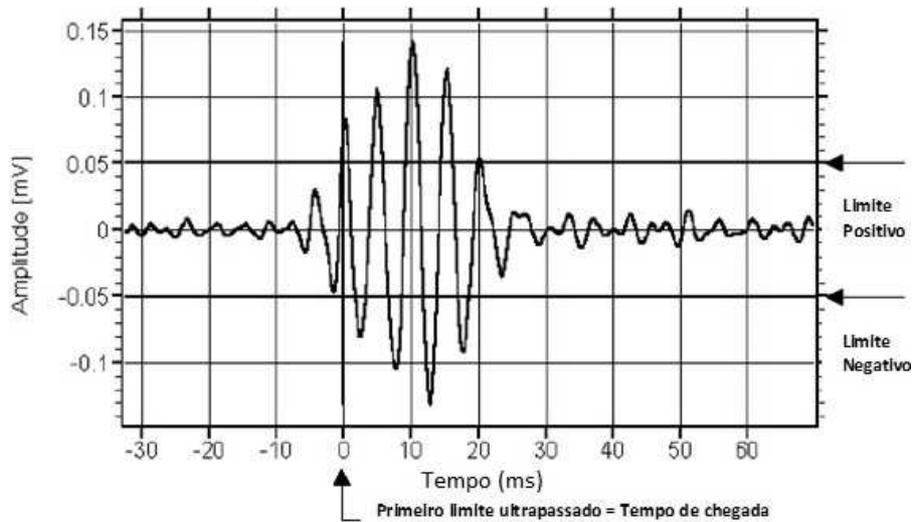


Figura 4 - Determinação do tempo de chegada [14]

No processamento, o sinal de EA é amostrado a cada $100 \mu\text{s}$. No gráfico da Figura 4 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.

3.1.5 Parâmetros de EA

Os sistemas de EA permitem a captação de diversos parâmetros durante um ensaio, contudo os mais usados são: tempo de chegada (momento em que o sinal ultrapassa um dos limites pela primeira vez), amplitude máxima, tempo de subida (tempo que o sinal leva para alcançar a máxima amplitude), duração do sinal (intervalo de tempo entre a primeira e a última ultrapassagem do limite), energia (integral da amplitude

quadrada sobre o tempo de duração do sinal) e valor RMS (raiz média quadrada do ruído contínuo de fundo). (Figura 5)

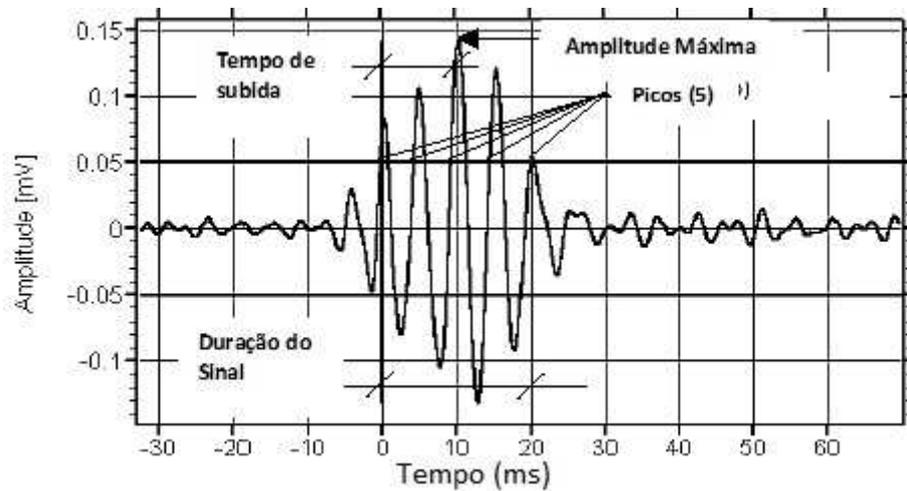


Figura 5 - Parâmetros de um sinal transiente [14].

A máxima amplitude é um dos parâmetros mais importantes, 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.

Os principais fatores de influência na amplitude do sinal estão definidos na Tabela 1.

Tabela 1 - Fatores de Influencia [15]

Características da estrutura e material	Principais fatores favorecendo sinais de grande amplitude	Principais fatores favorecendo sinais de baixa amplitude
Propriedades mecânicas	Alta resistência mecânica	Baixa resistência mecânica
Estrutura	Anisotropia	Isotropia
	Heterogeneidade	Homogeneidade
	Presença de descontinuidades	Material sem descontinuidades
	Tendência para forma maclas.	Muito baixa tendência para maclação
	Transformação martensítica	Transformação de fase por difusão
	Estrutura como fundido	
	Estrutura como soldado	Estrutura relaxada
	Estrutura de grão grosso	Estrutura de grão fino
Modo de ruptura	Crescimento de trinca	Escoamento uniforme
	Ruptura por clivagem	Deformação transversal
Modo de carregamento	Alta taxa de deformação	Baixa taxa de deformação
Geometria	Grandes espessuras	
Ambiente	Baixa temperatura	Alta temperatura

4 Metodologia

4.1 Análise dos Ensaios de Emissão Acústica

4.1.1 Materiais

Os corpos de prova foram feitos de aço API XL série 60, 20 cm de diâmetro e 14,5 mm de espessura. Uma única fissura elíptica (trinca) localizada exatamente no transdutor de TOFD (transdutor de ultrassom) (Figura 6) foi usinada nas superfícies internas e externas do duto, com dimensões diferentes para cada ensaio. Para ilustrar, a Figura 6 contém um típico desenho esquemático de uma seção de tubulação com a instrumentação necessária para monitorar o teste hidrostático.

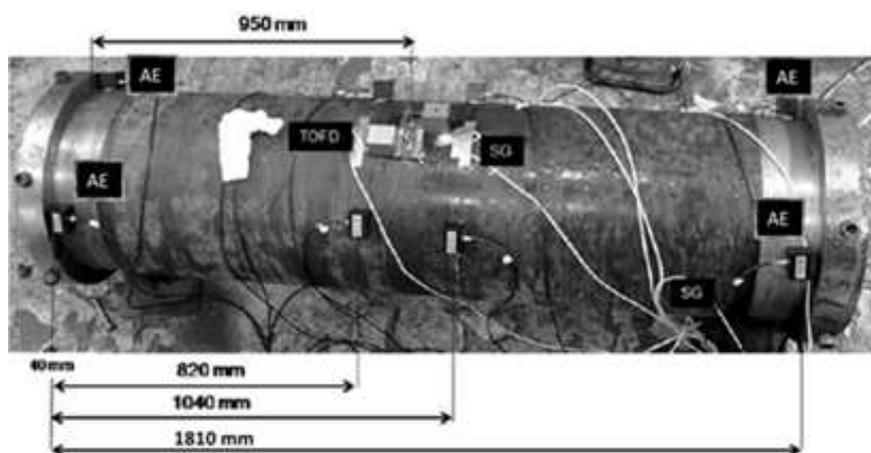


Figura 6 - Esquema de posicionamento dos sensores perto da região da fissura na superfície interna do corpo de prova. Dimensões em mm. TOFD: transdutor de ultrassom; SG: sensor calibre de tensão; AE: sensor de emissão acústica.

A trinca na superfície interna da amostra foi usinada com uma esmerilhadeira angular usando um disco de corte com raio de 12 mm, com forma semielíptica de 160 mm de comprimento, 1,1 mm de largura e 7,33 mm de profundidade.

4.1.2 Aquisição dos parâmetros de Emissão Acústica

Os sinais de EA utilizados neste trabalho se referem à realização de dois ensaios (de um total de seis) 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 ultra-sônico causada pelas extremidades superiores e inferiores de um refletor, neste trabalho a descontinuidade inserida no duto [15].

Os sinais foram adquiridos usando um aparelho da marca PAC, modelo Disp 16C com a utilização de 8 canais (sensores R15I-AST da PAC). A partir dos ensaios foram adquiridos um total de 19 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, Freq-PP1, Freq-PP2, Freq-PP3, Freq-PP4, C-Freq e P-Freq [14 – 16].

A Tabela 2 apresenta a descrição de todos os parâmetros utilizados nos ensaios.

Tabela 2 - Parâmetros de Emissão Acústica coletados. [14-16]

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 $\text{sen}(\pi/4)$.
<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.

4.2 O 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* [6]. 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, neste trabalho, três neurônios.

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 (α) fixo e sem momento; α fixo e com momento; α variável e sem momento; e α 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 uma tabela de índice de acerto em função da variação do número de neurônios na camada intermediária [3].

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 este (20%) [17,18]. 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].

4.2.1 Definição das Classes

A partir da curva de Pressão de ensaio hidrostático e Ultrassom (ToFD) por Tempo, os sinais foram separados em três classes.

Sem Propagação (SP) – Enquanto a profundidade da trinca se mantém constante.

Propagação Estável ou Elástica (PE) – Crescimento lento da trinca por um longo intervalo de tempo. Não há deformação permanente.

Propagação Instável ou Plástica (PI) – Crescimento acentuado da trinca por um curto intervalo de tempo até o rompimento. Há deformação plástica (permanente).

Após a determinação dos intervalos de cada classe os sinais foram sincronizados com o tempo de pressurização e do crescimento da trinca, como exemplificado na figura

7.

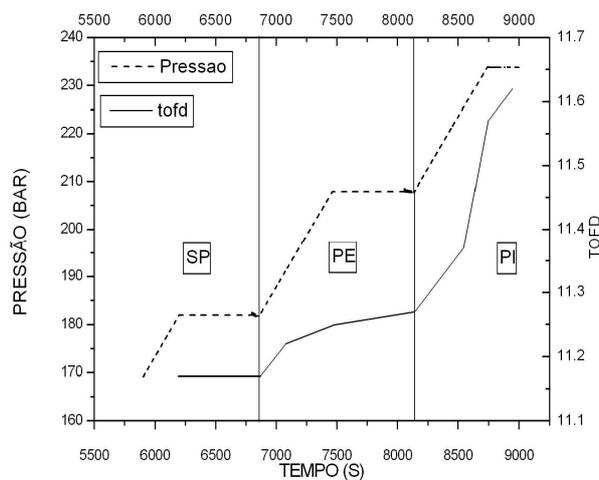


Figura 7 – A linha tracejada representa a parcela de pressão vs. tempo e a linha contínua representa a propagação da rachadura vs tempo.

4.2.2 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 [19], 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 a grande quantidade de entradas disponíveis não justifica o uso dos outros métodos [6]. 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 [3].

4.2.3 Critério de Relevância

Neste trabalho, utilizou-se este método para avaliar a importância dos atributos de entrada acrescidos no 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. [20]

A relevância $R(X_i)$ da componente X_i do vetor X pode ser calculada pela equação 1:

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

$R(X_i)$: 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 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} .

4.3 Curva de Probabilidade de Propagação (PoP)

Nesta seção, o objetivo não é apenas a classificação final da entrada do sinal de Emissão Acústica em uma das três classes apresentadas (Sem Propagação, Propagação Estável e Propagação Instável), mas sem recorrer aos valores de saída de cada neurônio da camada de saída do classificador, desenvolvido na seção 4.2, para o cálculo da probabilidade de classificação.

Para explicar a metodologia, pode-se analisar a figura 8, definindo a classe SP como estágio 1 de propagação, a PE como estágio 2 e a PI como estágio 3, supondo-se que a probabilidade em relação ao tempo da classe SP esteja próxima de um, enquanto que as demais próximas de zero no limiar de definição desta classe; ao passar para o segundo estágio, a probabilidade da classe PE deve estar próxima de um e as demais próximas à zero; no terceiro e último estágio, a probabilidade da classe PI deve estar próxima de um e as demais próximas de zero. Ao plotar as três probabilidades em um único gráfico em relação ao tempo, é gerada a curva de Probabilidade de Propagação (PoP).

Numa situação ideal, 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 8, de 0 até 50 segundos a probabilidade do sinal ser SP é igual a um e as demais igual a zero, entre 50 e 100 a probabilidade de PE é igual a 1 e as demais igual a zero, a partir de 100 segundos até o final do ensaio a probabilidade 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.

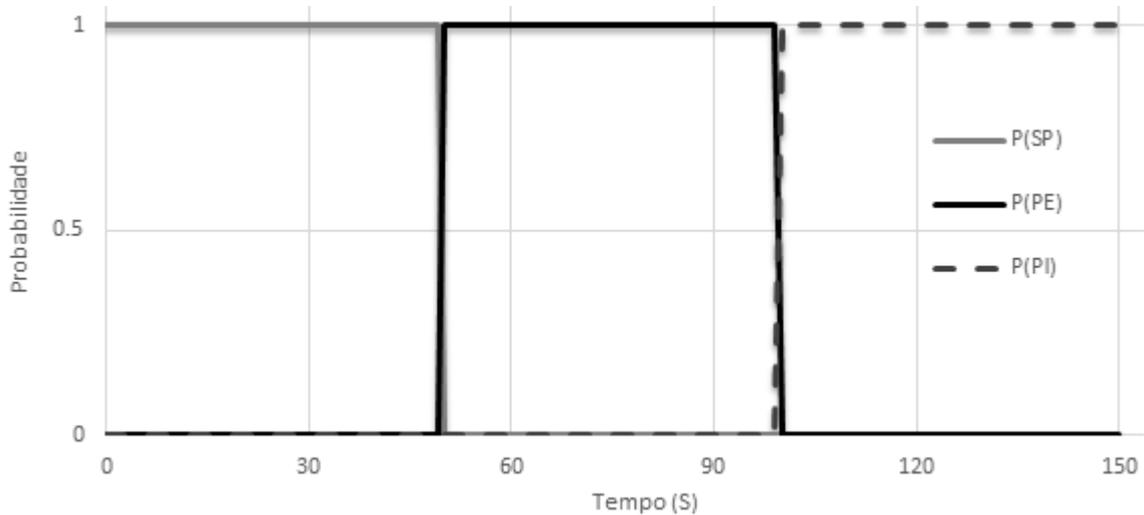


Figura 8- A linha contínua cinza representa a probabilidade de SP, a probabilidade de linha preta contínua o PE e a linha de tracejada a probabilidade PI.

Foi escolhido este tempo de ensaio como referência, porque uma vez que exista a trinca e o sinal de EA seja capitado, 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. 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 [21].

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 [21]. Na segunda e última etapa, é realizada a classificação utilizando o teorema de Bayes [22].

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 3 apresenta os valores das saídas definidos para cada classe, em notação maximamente esparsa.

Tabela 3- 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 [23], 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 2.

$$U_n = \tanh^{-1}(Y_n) \quad (2)$$

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. Contudo, o objetivo não é a precisão da função estimada, e sim usar as curvas para modelar o classificador [20,21].

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 $\int K(X)dX = 1$ [20,22] pode ser interpretado como uma soma ponderada do valor da função $K(\cdot)$ em cada valor de X , como exemplificado na figura 9 [24].

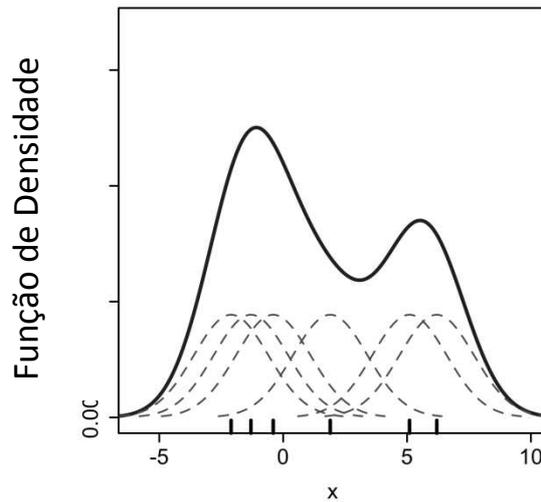


Figura 9 - A curva com a linha contínua é a densidade estimada e as linhas tracejadas são as funções do Kernel para cada ponto indicado [24].

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 3 [20]. Isto é, dada uma entrada X a probabilidade de esta pertencer à classe é calculada.

$$\widehat{Pr}(G = j|X = x_0) = \frac{\hat{\pi}_j \hat{f}_j(x_0)}{\sum_{k=1}^J \hat{\pi}_k \hat{f}_k(x_0)} \quad (3)$$

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

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

J – quantidade de classes.

Ajustando a equação 2 para o cálculo de cada classe, SP, PE e PI se têm a equação 4.

$$\widehat{Pr}(G = Classe|X = x_0) = \frac{\hat{\pi}_{Classe}\hat{f}_{Classe}(x_0)}{\hat{\pi}_{Classe}\hat{f}_{Classe}(x_0) + \hat{\pi}_{\text{nãoClasse}}\hat{f}_{\text{nãoClasse}}(x_0)} \quad (4)$$

Como é conhecido o conjunto de cada classe e não classe, a fim de eliminar qualquer influência de desbalanceamento dos conjuntos. A probabilidade a priori dada uma entrada x qualquer será $\hat{\pi}_{Classe} = 0,5$ e $\hat{\pi}_{\text{nãoClasse}} = 0,5$, desta forma a probabilidade a posteriori será apenas resultado das funções densidades de probabilidade estimadas.

De acordo com a equação 4 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 5.

$$Z = U_l - \max(U_m, U_n) \quad (5)$$

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 4.2, 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 4 apresenta a equação utilizada em cada classe, uma abordagem semelhante é apresentada em Silva [2].

Tabela 4 – Equações Z para as respectivas classes.

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

De acordo com Hastie [20], quando duas curvas de densidade de probabilidade seguem a forma apresentada na figura 10, geradas a partir de dados hipotéticos, o gráfico da probabilidade posteriori calculada com a equação 4 terá a forma suave apresentada na figura 11.

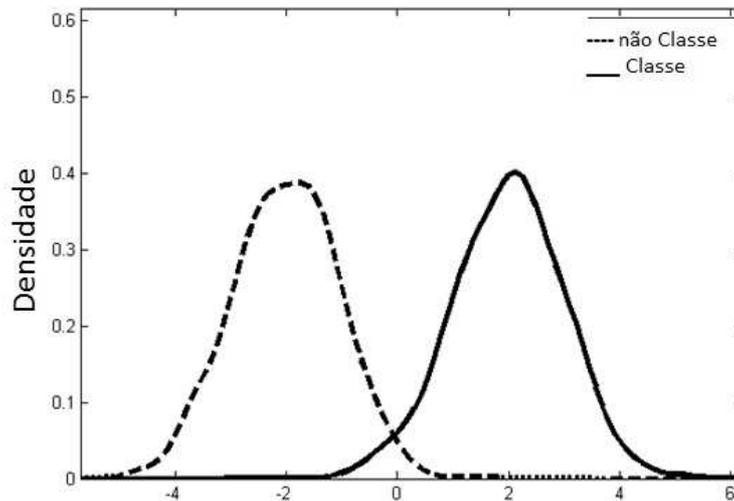


Figura 10 - A linha contínua representa a densidade de probabilidade da “classe” e a linha tracejada a densidade da “não classe”. Dados hipotéticos.

Observando a curva da figura 11, se percebe grande semelhança com o formato de curvas geradas a partir de tangentes hiperbólicas, então para as probabilidades posteriori encontradas é realizada a regressão utilizando esta função. A partir deste ponto a probabilidade da classe pode ser escrita em função do tempo e de Z, de acordo com a equação 6.

$$P_{\text{Class}}(t) = a \times \tanh(b \times Z_n(t) - c) + d \quad (6)$$

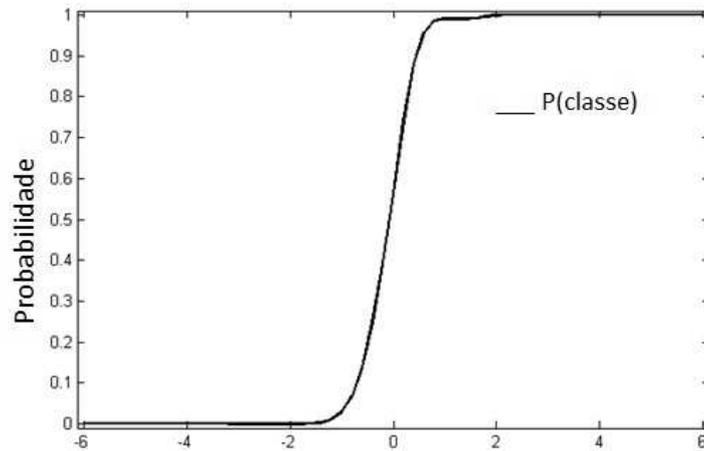


Figura 11 - Curva de probabilidade posteriori para a classe, gerada a partir da densidade de probabilidade.

A figura 12 apresenta um exemplo da probabilidade plotada a partir da equação

6. Cada ponto representa a probabilidade do sinal de EA para a classe em específico.

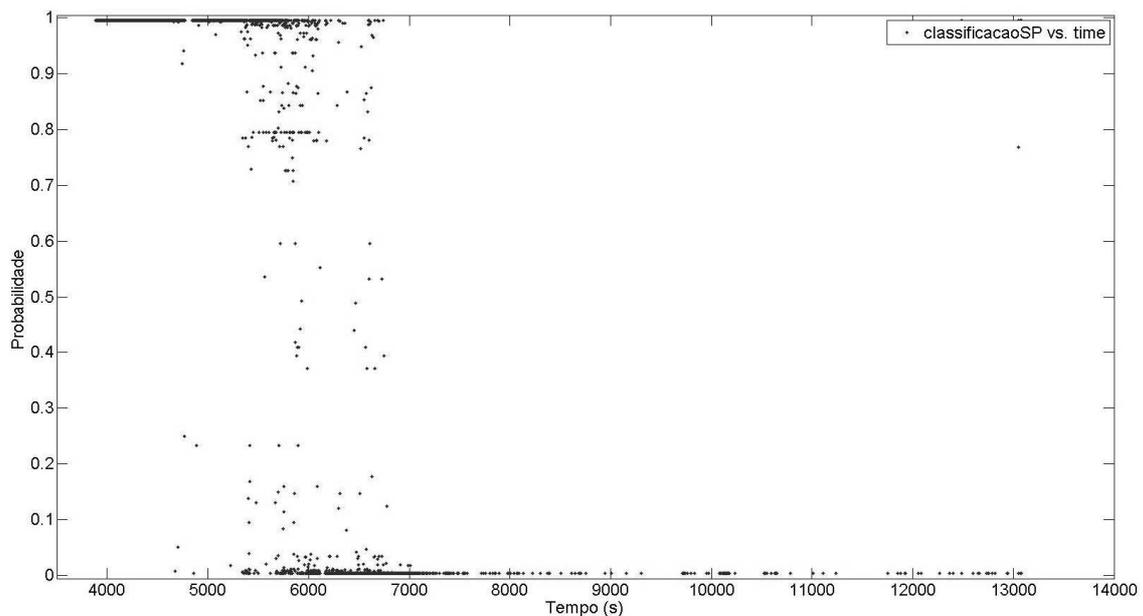


Figura 12 – Gráfico da probabilidade em relação ao tempo.

A curva PoP será gerada a partir da aproximação de cada ponto do gráfico para uma função tangente hiperbólica, conforme as equações 7, 8 e 9 da tabela 5, de acordo com o algoritmo minimização do erro médio quadrático, descrito a seguir.

Tabela 5 – Modelo de aproximação da probabilidade de cada classe.

PoP	Modelo	
SP	$PoP_{SP}(t) = \frac{\tanh(-at + b) + 1}{2}$	(7)
PE	$PoP_{PE}(t) = \frac{\tanh(at + b) + 1}{2} - \frac{\tanh(-ct + d) + 1}{2}$	(8)
PI	$PoP_{PI}(t) = \frac{\tanh(-at + b) + 1}{2}$	(9)

Início do Algoritmo

- 1 – Inicialização dos coeficientes próximo de zero
- 2 – Gerar curva para os atuais coeficientes
- 3 – Aplicar o algoritmo *Trust-region* [25] para encontrar os coeficientes “ótimos”
- 4 – Retornar ao passo 2 se não ocorreu a convergência

Fim do Algoritmo

A figura 13 apresenta exemplos da curva de aproximação encontrada para diferentes intervalos de tempo.

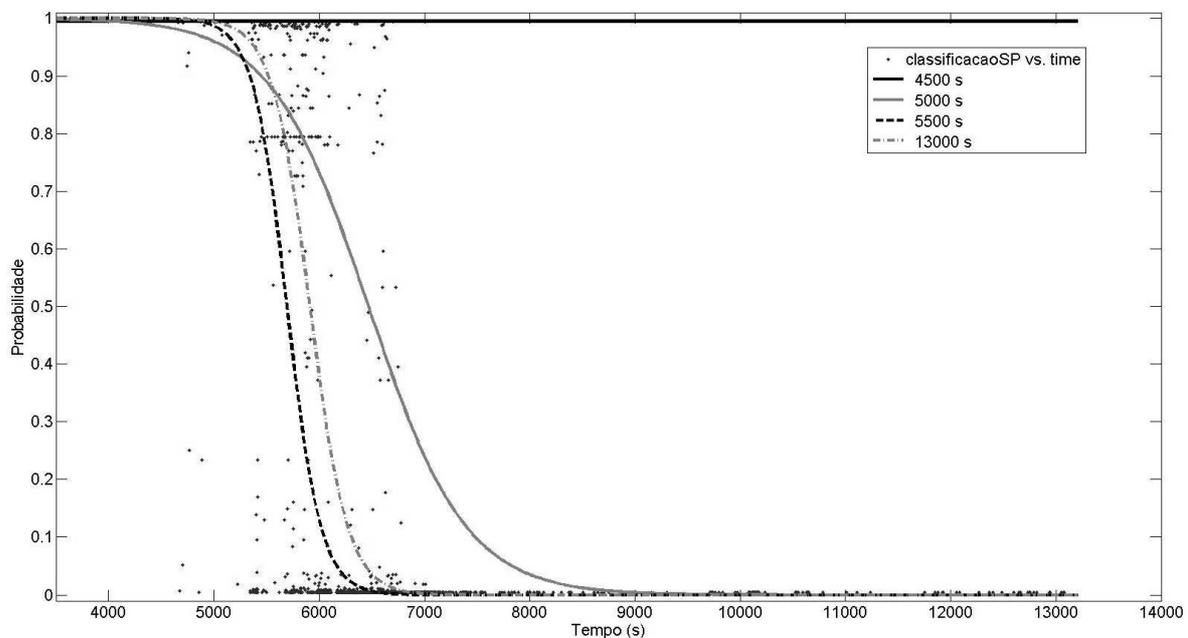


Figura 13 - Curvas de aproximação.

4.4 Análise de Agrupamentos

De acordo com Hastie et al. [24], a análise de agrupamento está relacionado 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 et al. [26] 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 [6] 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[5], 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 [5] 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.

O presente trabalho propõe realizar a análise de agrupamento dos dados de emissão acústica do Ensaio 2 e a partir dos agrupamentos formados determinar em que classe cada sinal de EA melhor se encaixa no conjunto de treinamento do classificador desenvolvido.

4.4.1 *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 [22].

De acordo com Rajaraman et al. [26], o valor de K pode ser determinado por tentativa e erro e o objetivo principal do algoritmo está em atribuir iterativamente cada ponto, diferente dos K selecionados, ao grupo mais próximo, onde “próximo” significa próximo ao centro do agrupamento.

O Diagrama da figura 14 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.

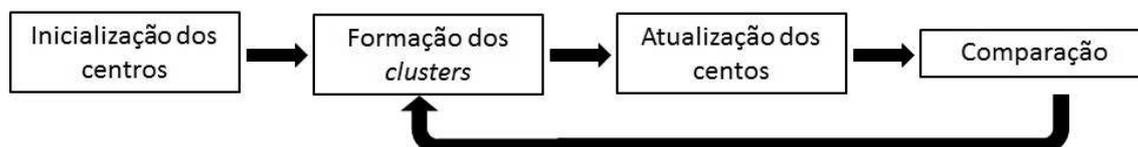


Figura 14 - Algoritmo *K-means*.

4.4.2 Mapas Auto Organizacionais (SOM)

De acordo com Hastie et al. [22], 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 [5] 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 SOM é o método é 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 [22].

Conclui-se que um SOM pode ser interpretado como uma rede neural *feedforward* [6] 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 15.

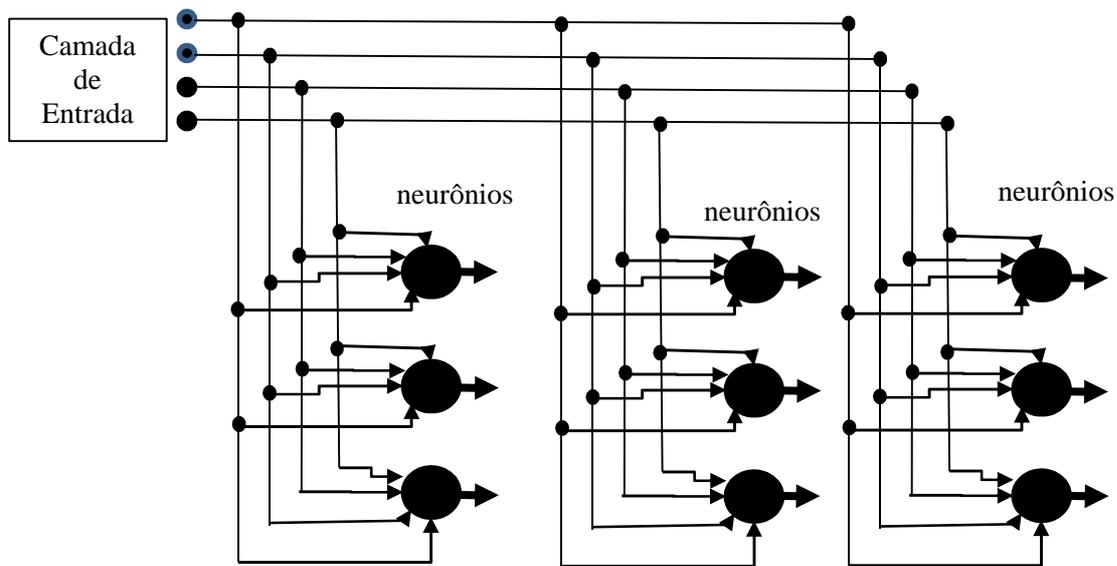


Figura 15 - Grade de neurônios de duas dimensões, com quatro entradas e nove neurônios, formando um mapa 3x3.

O algoritmo responsável pela formação do SOM pode ser descrito de acordo com o diagrama representado na figura 16.

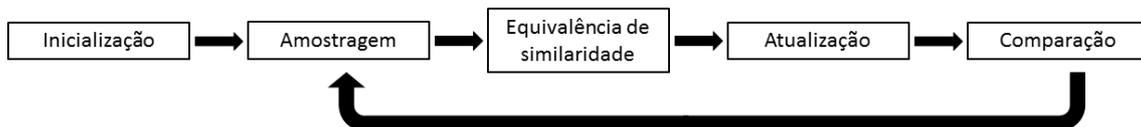


Figura 16 – Algoritmo de formação do SOM.

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 10 determina a melhor equivalência.

$$i(x) = \arg \min_j \|x(n) - w_j\|, \quad j = 1, 2, \dots, k \quad (10)[6]$$

Após a determinação do neurônio vencedor, é realizada a atualização dos pesos sinápticos de acordo com a equação 11.

$$w_j(n+1) = w_j(n) + \eta(n)h_{j,i(x)}(n)(x(n) - w_j(n)) \quad (11)[6]$$

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 [6].

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

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

$$\sigma_0 \approx \frac{\max_dim_grade}{5} = 0.2\sqrt{P^2 + Q^2} \quad \text{para_mapa_bidimensional} \quad \tau_h = \frac{1000}{\ln \sigma_0}$$

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.

5 Discussão e Resultados

5.1 Classificador Neural

5.1.1 Ensaio 1

De acordo com o gráfico apresentado na figura 17, os dados do Ensaio 1 foram separados em três classes, como descrito na seção 4.2.1.

A classe SP é composta pelos dados do início do ensaio até o tempo de 6868 segundos (181 bar), a classe PE compreende os dados entre 6869 e 8143 segundos (208 bar) e a classe PI entre 8144 e 12837 segundos (233 bar). Resultando em amostras de 2207 de SP, 1394 de PE e 6439 de PI. Foi constatado empiricamente que o desequilíbrio dos dados entre as classes não afetam o desempenho da rede treinada.

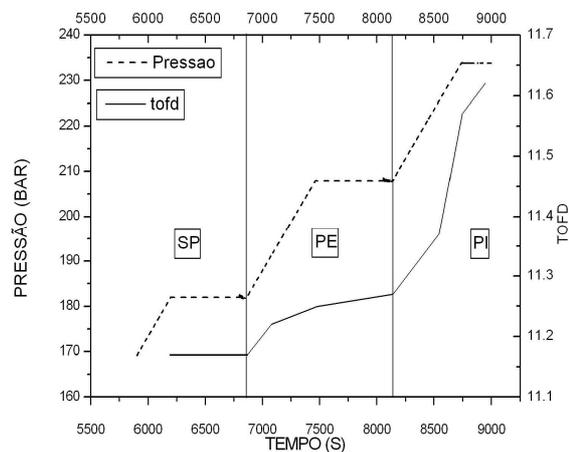


Figura 17 - A linha tracejada representa a parcela de pressão vs. tempo e a linha contínua representa a propagação da Trinca vs tempo.

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) [18].

Pela tabela 6 de confusão a seguir, a acurácia de acerto com três classes Sem Reclassificação atinge 78% para os conjuntos de treinamento e 77% 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 (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 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 6 - Resultados da precisão média de 10 conjuntos de treinamento e teste (três classes sem reclassificação).

	Desempenho (conjunto de treino)					Desempenho (conjunto de teste)			
	SP	PE	PI	NC		SP	PE	PI	NC
SP	83,0%	4,0%	13,0%	12,0 %	SP	82,0%	4,0%	14,0%	12,0 %
PE	16,0%	77,0%	7,0%		PE	15,0%	77,0%	8,0%	
PI	4,0%	4,0%	92,0%		PI	4,0%	4,0%	92,0%	
Média total de acertos	78,0%				77,0%				

NC – não classificado.

5.1.2 Ensaio 2

De acordo com o tempo do Ensaio 2 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 17. Resultando em um total de 2053 amostras de SP, 1045 de PE e 383 de PI. Assim como no Ensaio 1, o desequilíbrio dos dados não afetou o desempenho da rede neural treinada.

Neste ensaio, não foi possível obter dados da pressão no duto ao longo do teste.

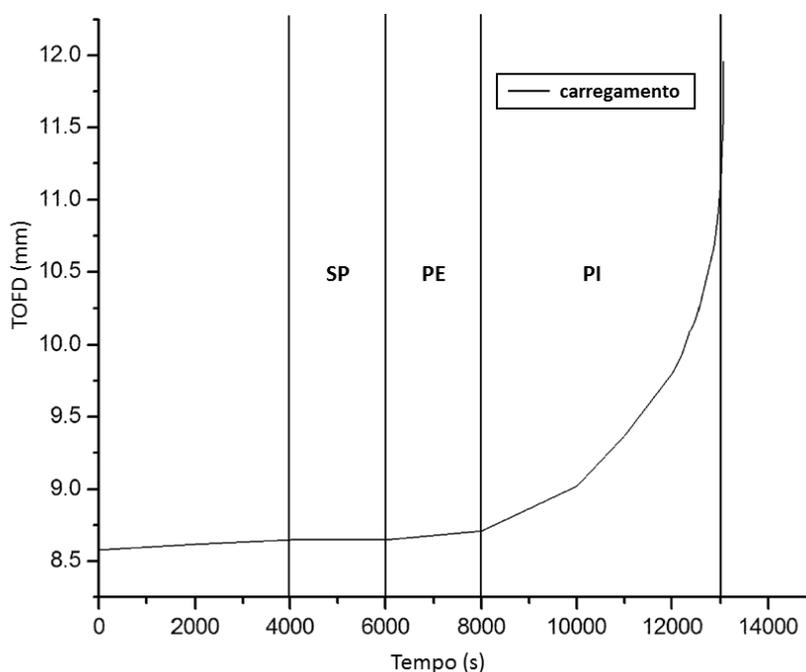


Figura 18 - Gráfico da propagação da trinca pelo tempo.

A tabela 7 apresenta o resultado obtido na classificação do sinal, o classificador alcançou 91% de acerto no conjunto de treino e no de teste. 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 1. Os valores não classificados (mais de uma saída positiva ou todas negativas) foram próximos de zero.

Tabela 7 - Resultados da precisão média de 10 conjuntos de treinamento e teste (três classes sem reclassificação).

	Desempenho (conjunto de treino)			NC		Desempenho (conjunto de teste)			NC
	SP	PE	PI			SP	PE	PI	
SP	92,2%	6,4%	0,3%	0,3%	SP	93,0%	6,1%	0,3%	0,3%
PE	9,7%	86,7%	4,0%		PE	8,9%	84,%	4,2%	
PI	0,7%	3,8%	95,4%		PI	1,4%	7,6%	91,4%	
Média total de acertos	91,0%				91,0%				

NC – não classificado

5.1.3 Estudo da Relevância das Entradas

O aumento dos índices de acerto na classificação comprovou que os parâmetros acrescidos são fundamentais para o bom desempenho do classificador, contudo uma investigação mais detalhada de cada parâmetro se faz necessária. Para isso, se utilizou o quarto conjunto de pares de entrada e saída de treinamento sorteados dos sinais do Ensaio 1 e a rede já treinada a partir destes pares.

O gráfico da Figura 19 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.

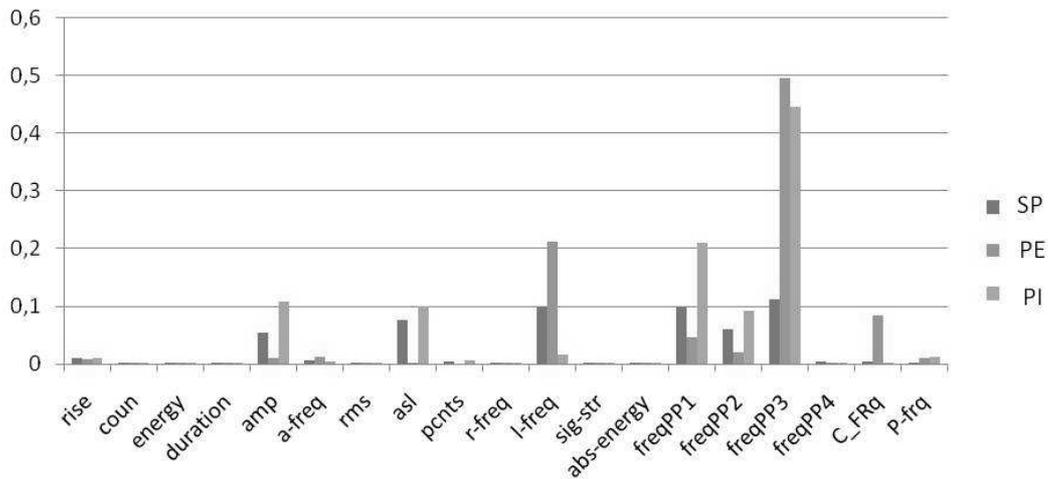


Figura 19 - Gráfico da relevância de cada parâmetro para cada uma das três classes

O gráfico da Figura 20, mostra que 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. O demais parâmetros apresentaram valores abaixo de 5, indicando pouca ou nenhuma influência na classificação.

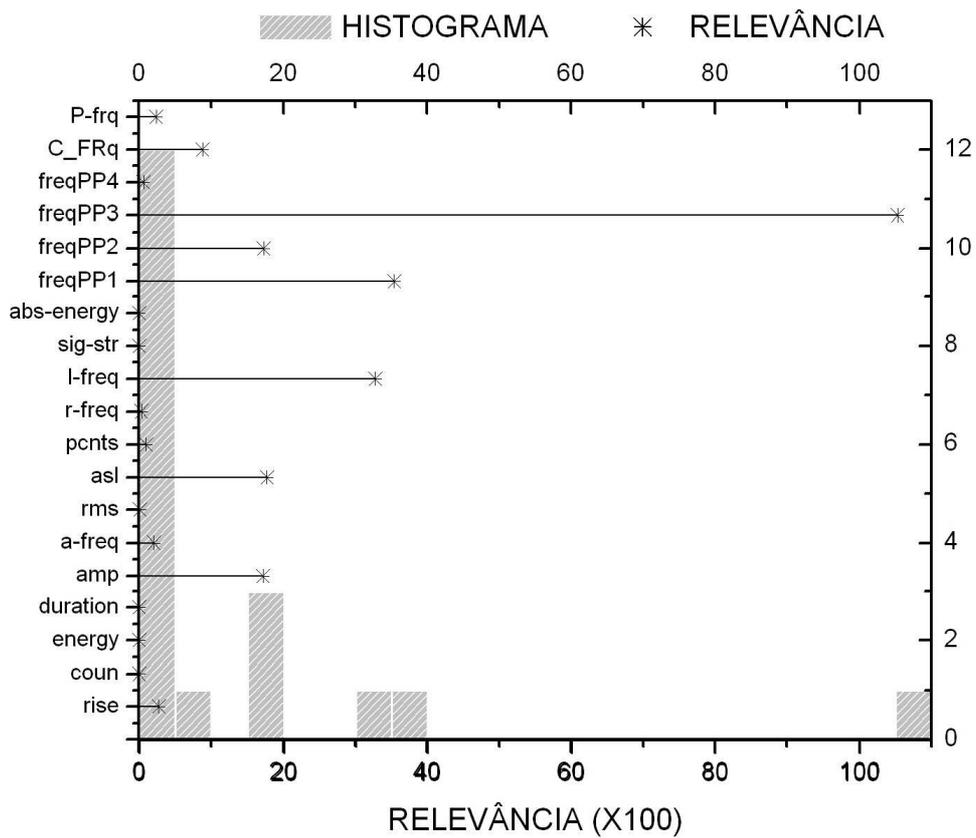


Figura 20 - Em cinza o histograma das relevâncias para as três classes juntas. As estrelas indicam a relevância de cada parâmetro para as três classes juntas.

Para confirmar a influência de cada parâmetro na discriminação das classes, a partir da Figura 20, criaram-se cinco conjuntos com os pares de entrada e saída. Quanto mais no interior, maior a relevância, conforme descrito na Figura 21.

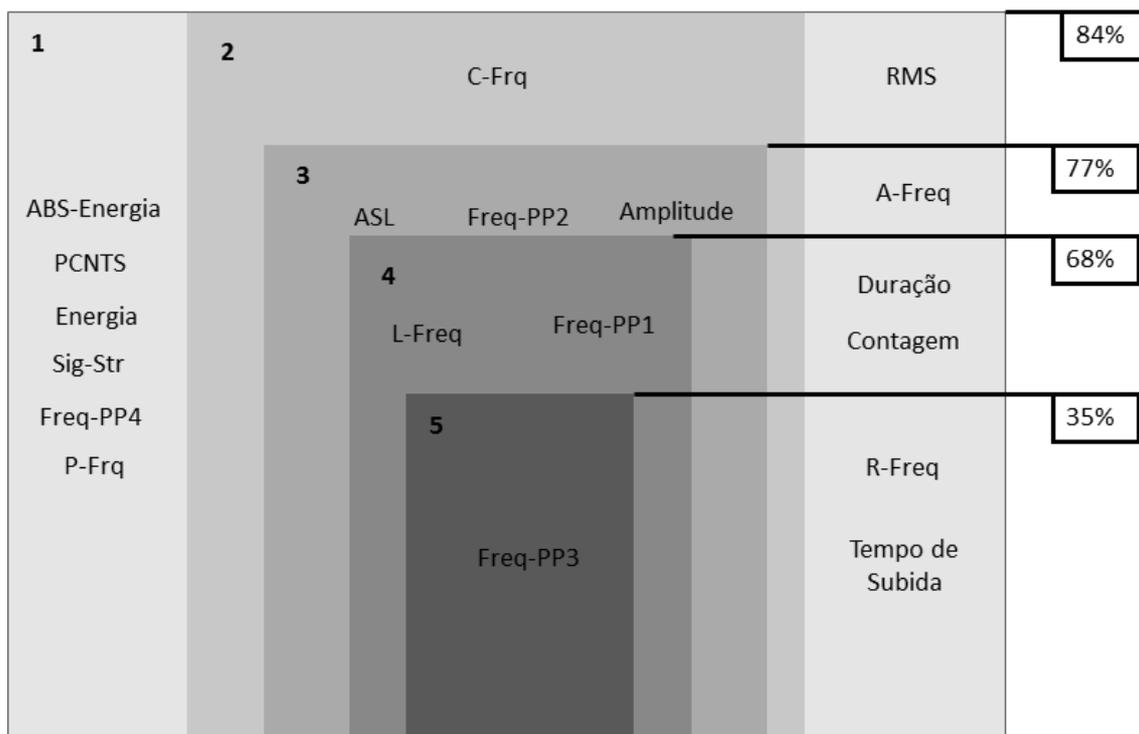


Figura 21 - Separação de conjuntos pela relevância. À direita o percentual de acerto na classificação de cada conjunto.

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 21 indica que a taxa de acerto entre o conjunto 1 e o conjunto 2 é 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% de acerto, usando apenas 3 parâmetros, e o conjunto 5, 35%, com apenas 1 parâmetro. Este resultado confirma, o indicado pela Figura 20, 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 neste item. Contudo a entrada contém apenas os parâmetros do conjunto 2 da Figura 21, isto é, apenas os sete mais relevantes. A configuração da rede foi a mesma utilizada no ensaio 1.

As Tabelas 8 e 9 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-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.

	Conjuntos de treinamento				Conjuntos de teste		
	SP	PE	PI		SP	PE	PI
SP	75,0%	12,0%	13,0%	SP	76,0%	13,0%	11,0%
PE	18,0%	74,0%	8,0%	PE	14,0%	77,0%	9,0%
PI	5,0%	5,0%	90,0%	PI	6,0%	4,0%	90,0%
ACERTOS	84,0%				85,0%		

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).

	Conjuntos de treinamento				Conjuntos de teste		
	SP	PE	PI		SP	PE	PI
SP	55,0%	24,0%	21,0%	SP	69,0%	14,0%	17,0%
PE	11,0%	74,0%	15,0%	PE	16,0%	67,0%	17,0%
PI	4,0%	4,0%	92,0%	PI	4,0%	3,0%	93,0%
ACERTOS	81,0%				84,0%		

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. Entretanto, como não há custos relevantes de tempo de processamento

computacional, trabalho de aquisição e financeiro na utilização de todos os dezenove parâmetros, há de se mantê-los nos conjuntos de sinais para treinamento e teste dos classificadores. Pois, não compensa a diminuição da taxa de acerto, embora que pequena.

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 2 e a segunda a partir dos dados do ensaio 1.

A tabela 10 apresenta a função de regressão calculadas a partir da equação 6 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 10 - Equações de regressão tangente hiperbólica.

Classe	Equação	
SP	$P_{SP}(t) = 0.4951 \times \tanh(3.507 \times Z_{SP}(t) - 1.372) + 0.4999$	(12)
PE	$P_{PE}(t) = 0.4951 \times \tanh(0.7004 \times Z_{PE}(t) + 0.4588) + 0.4940$	(13)
PI	$P_{PI}(t) = 0.4745 \times \tanh(1.811 \times Z_{PI}(t) + 3.114) + 0.4925$	(14)

A figura 22 apresenta a probabilidade da classe SP em função do tempo, cada ponto representa a probabilidade para cada valor de Z , encontrada através do emprego da equação 12. 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. O gráfico apresenta a curva de aproximação para diferentes intervalos de tempo, de acordo com o aumento do tempo de ensaio a curva se aproxima da convergência.

As figuras 23 e 24 apresentam a convergência dos coeficientes “a” e “b” da equação 7, respectivamente, a 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 22 a sobreposição das curvas de até 7000 segundos e com todos os sinais.

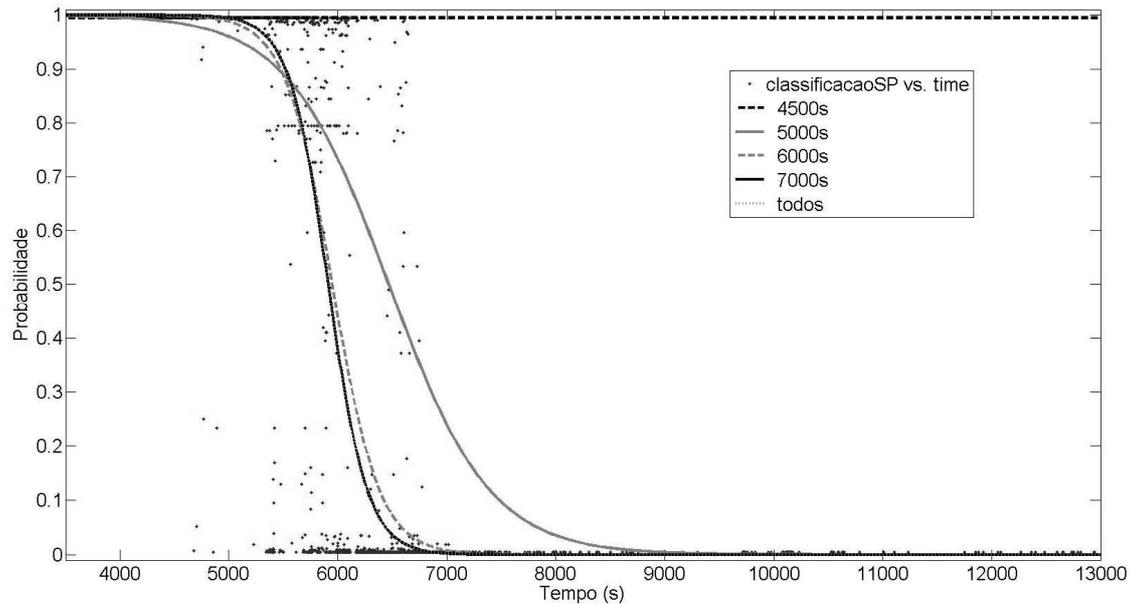


Figura 22 - Probabilidade da classe SP. Os pontos representam a probabilidade para cada valor de Z. A linha tracejada preta a curva gerada até 4500 segundos, a linha contínua cinza a curva até 5000s, a linha tracejada cinza a curva até 6000s, a linha contínua preta a curva até 7000s e a linha pontilhada cinza a curva com todos os sinais do ensaio 2.

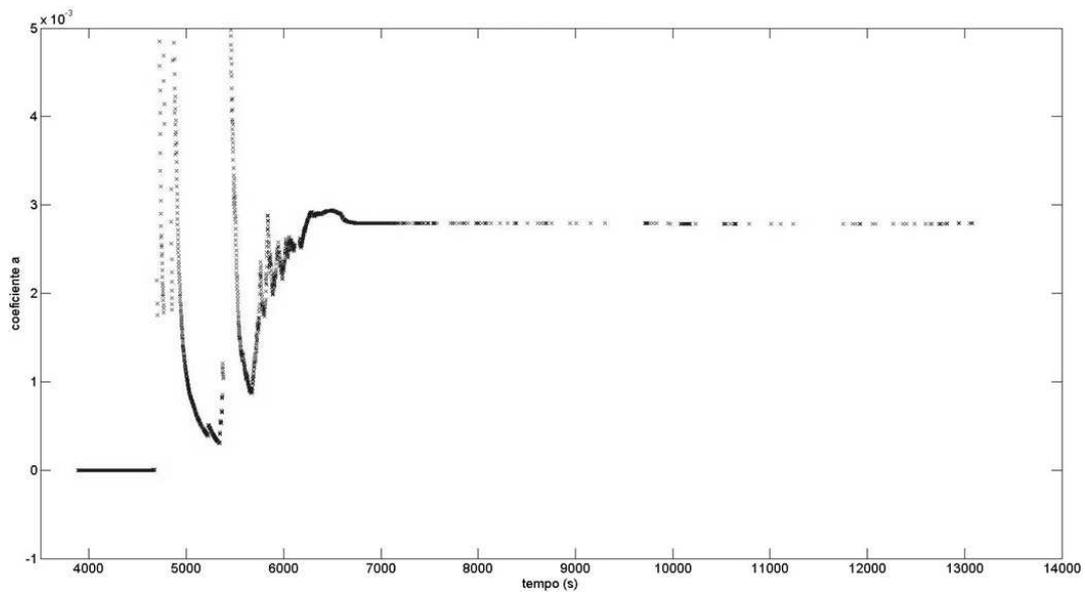


Figura 23 - Evolução do coeficiente "a" da equação de aproximação da probabilidade de SP

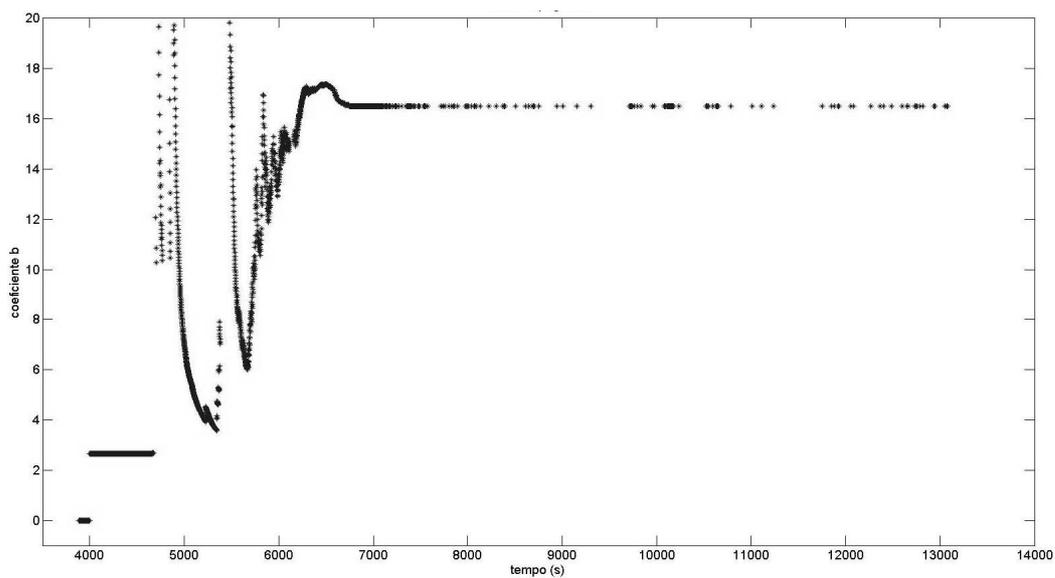


Figura 24 - Evolução do coeficiente "b" da equação de aproximação da probabilidade de SP

A curva de probabilidade de PE, figura 25, inicialmente apresentou 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.

As figuras 26, 27, 28 e 29 apresentam a convergência dos coeficientes “a”, “b”, “c” e “d” da equação 8, respectivamente. Pode ser observado que próximo a 9000 segundos ocorre a convergência de ambos os coeficientes, tal fato pode ser comprovado observando na figura 25 a sobreposição das curvas de até 9000 segundos e com todos os sinais.

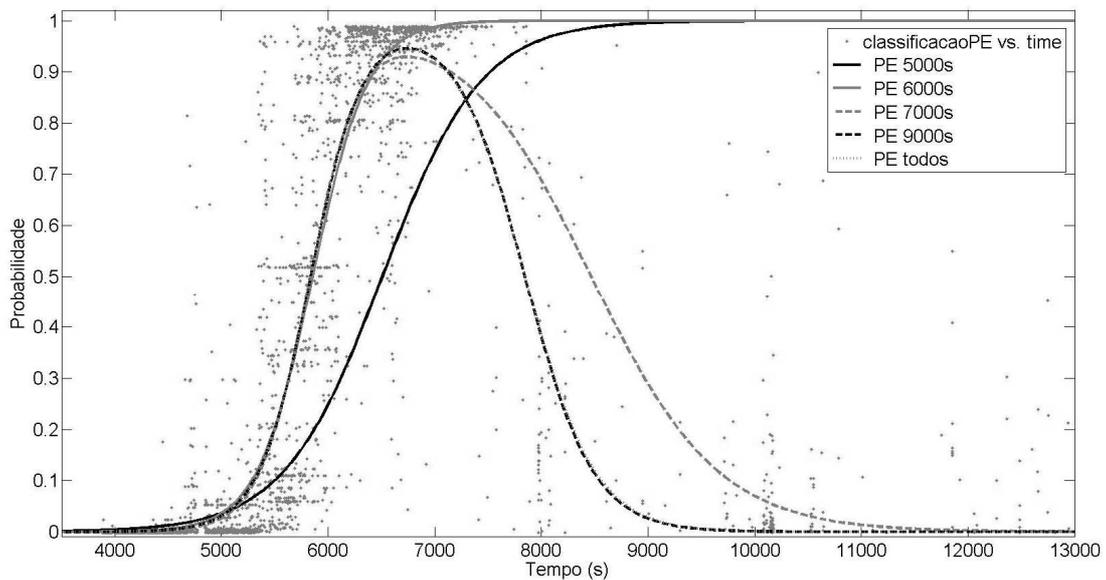


Figura 25- Probabilidade da classe PE. Os pontos representam a probabilidade para cada valor de Z. A linha contínua preta representa a curva gerada até 5000 segundos, a linha contínua cinza a curva até 6000s, a linha tracejada cinza a curva até 7000s, a linha tracejada preta a curva até 9000s e a linha pontilhada cinza a curva com todos os sinais do ensaio 2.

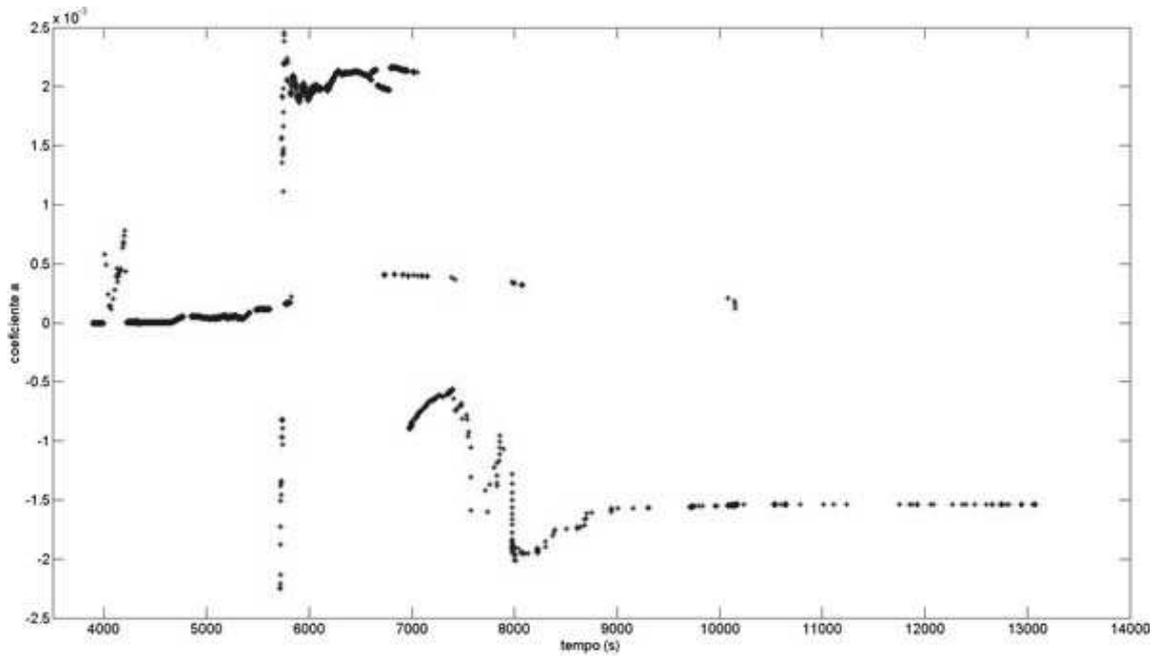


Figura 26 - Evolução do coeficiente “a” da equação de aproximação da probabilidade de PE

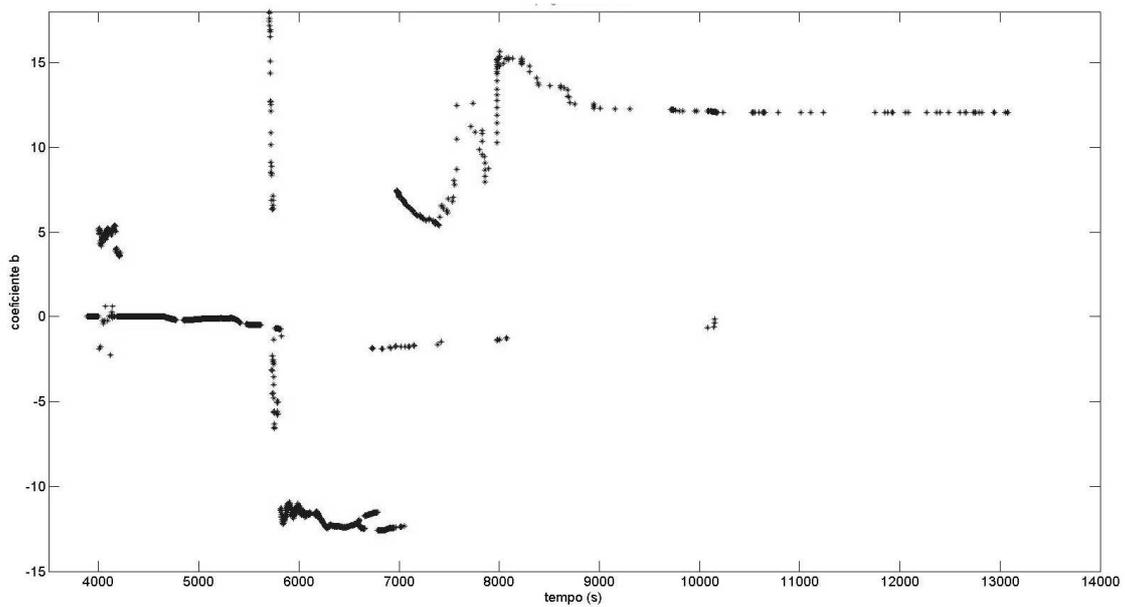


Figura 27 - Evolução do coeficiente “b” da equação de aproximação da probabilidade de PE

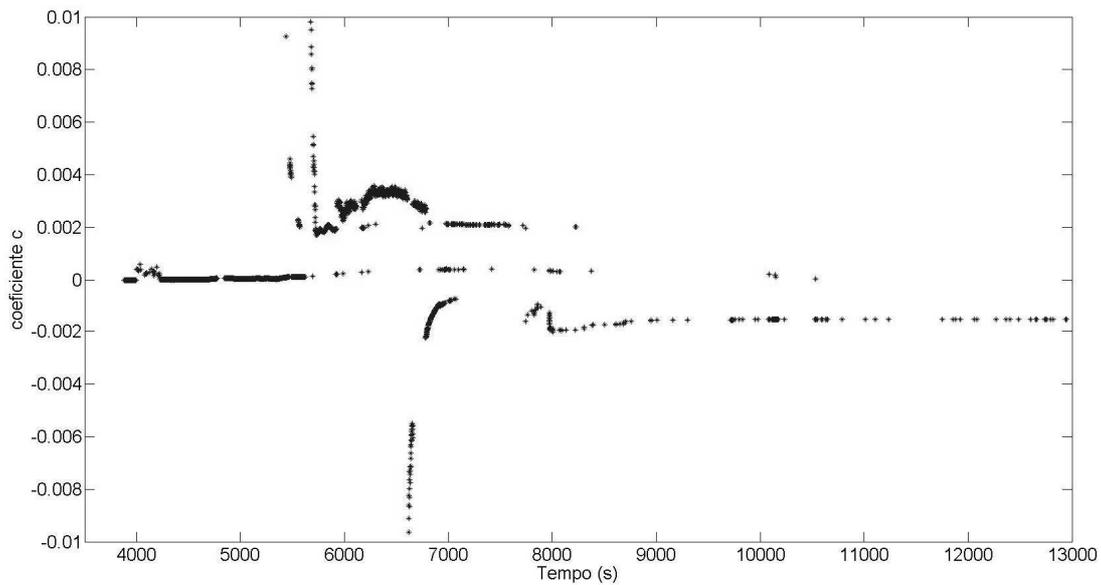


Figura 28 - Evolução do coeficiente “c” da equação de aproximação da probabilidade de PE

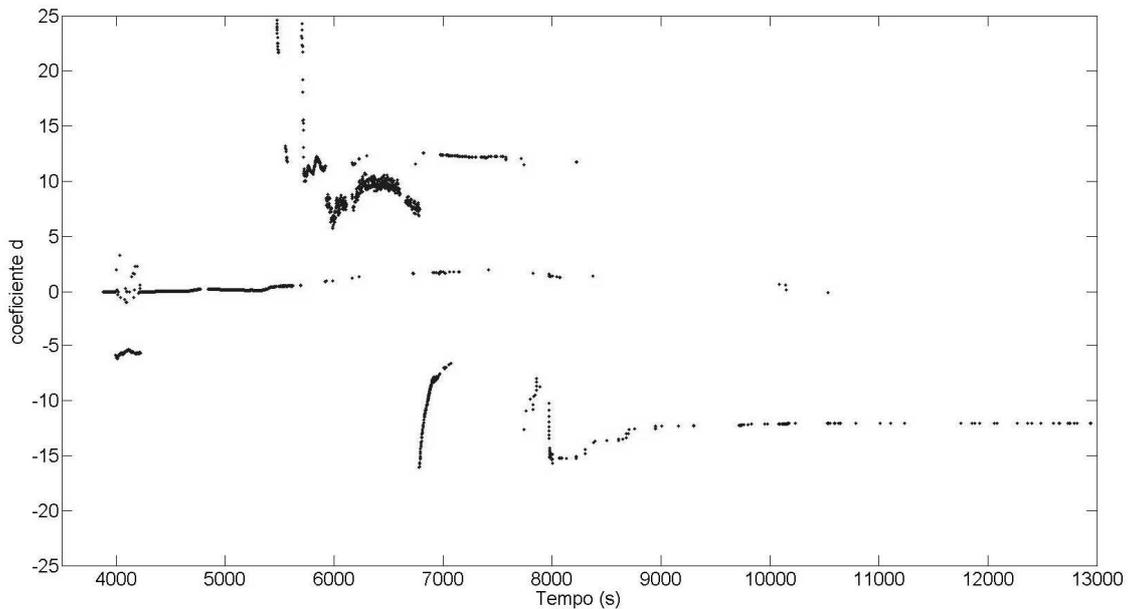


Figura 29 - Evolução do coeficiente “d” da equação de aproximação da probabilidade de PE

No gráfico da figura 30, é apresentada a probabilidade de PI, novamente como esperado inicialmente a maior concentração de valores iniciais está próxima de zero. 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 para diferentes intervalos de tempo, de acordo com o aumento do tempo de ensaio a curva se aproxima da convergência.

As figuras 31 e 32 apresentam a convergência dos coeficientes “a” e “b” da equação 9, respectivamente. Pode ser observado que próximo a 8000 segundos ocorre a convergência de ambos os coeficientes, tal fato pode ser comprovado observando na figura 30 a sobreposição das curvas de até 8000 segundos e com todos os sinais.

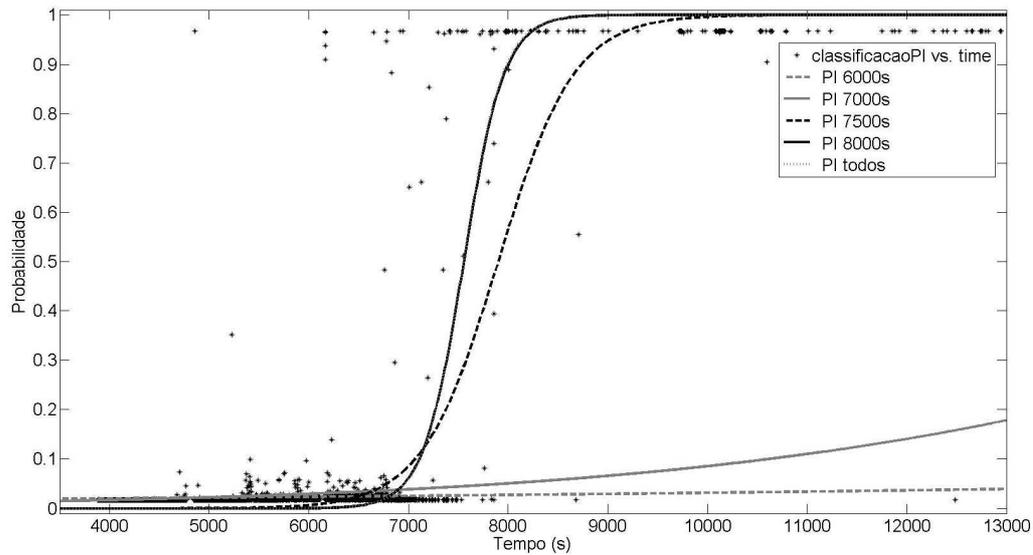


Figura 30 - Probabilidade da classe PI. Os pontos representam a probabilidade para cada valor de Z. A linha tracejada cinza representa a curva gerada até 6000 segundos, a linha contínua cinza a curva até 7000s, a linha tracejada preta a curva até 7500s, a linha contínua preta a curva até 8000s e a linha pontilhada cinza a curva com todos os sinais do ensaio 2.

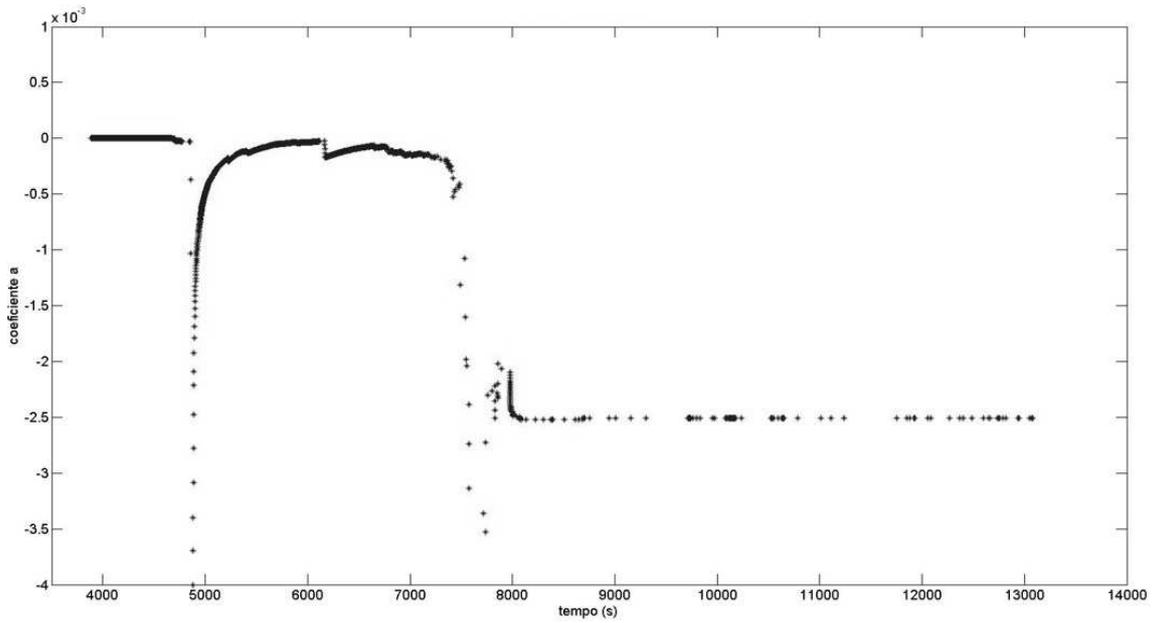


Figura 31 - Evolução do coeficiente “a” da equação de aproximação da probabilidade de PI.

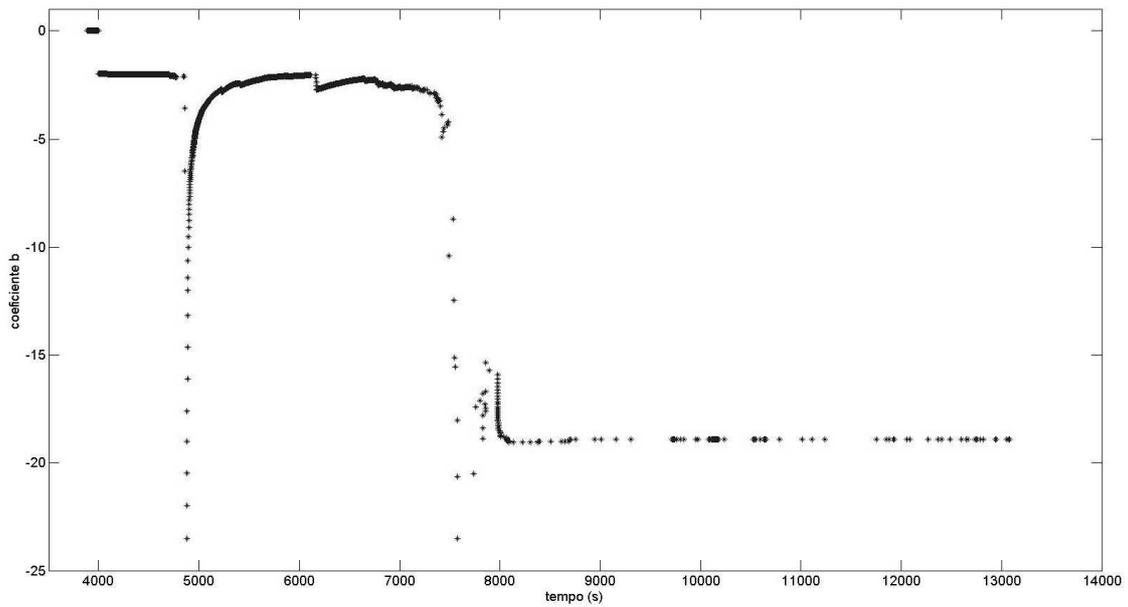


Figura 32 - Evolução do coeficiente “b” da equação de aproximação da probabilidade de PI.

Finalmente, plotando as três curvas de regressão das probabilidades em um mesmo gráfico se pôde determinar a curva PoP, figura 33.

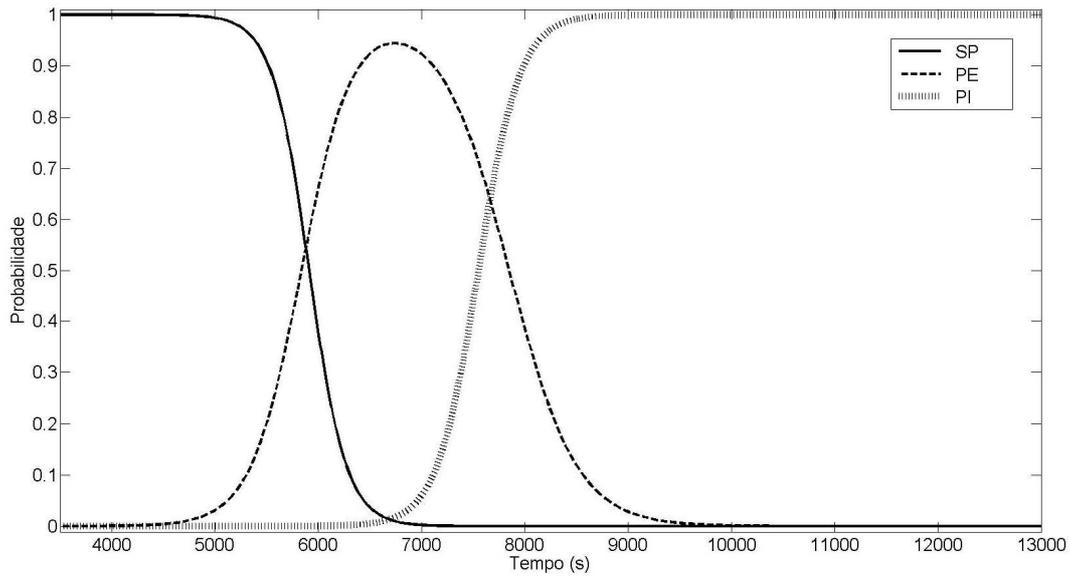


Figura 33 - Curva PoP.

Como a curva foi montada a partir do conjunto de dados do ensaio 2, 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 até 6000 segundos, figura 34, como era esperado até aproximadamente 6000 segundos o sinal de entrada possui maior probabilidade de ser classificado como SP. Quando chega em 5875 segundos, a probabilidade de ele ser classificado como PE ultrapassa a probabilidade de SP.

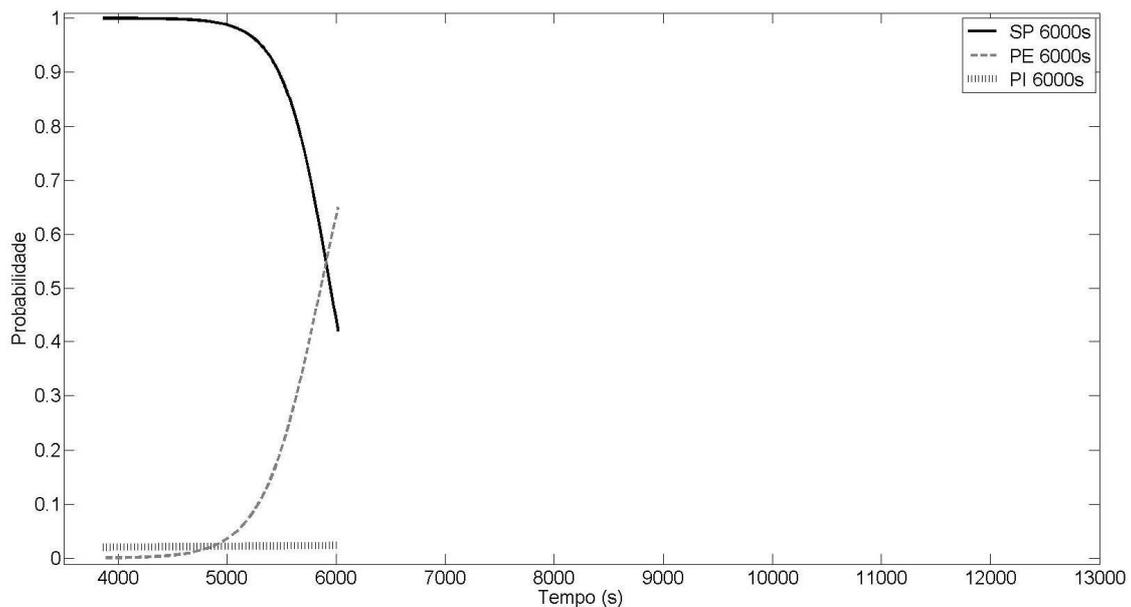


Figura 34 - Curva PoP – Destaque dos dados SP.

A figura 35 apresenta a curva PoP realizada com os sinais até 8000 segundos. Em 6000 segundos, a probabilidade de o sinal ser classificado como PE é a maior dentre as três classes. A partir de 6850 segundos, a probabilidade de PE começa a diminuir e a de PI começa a crescer, em 7640 segundos a probabilidade de PI ultrapassa PE.

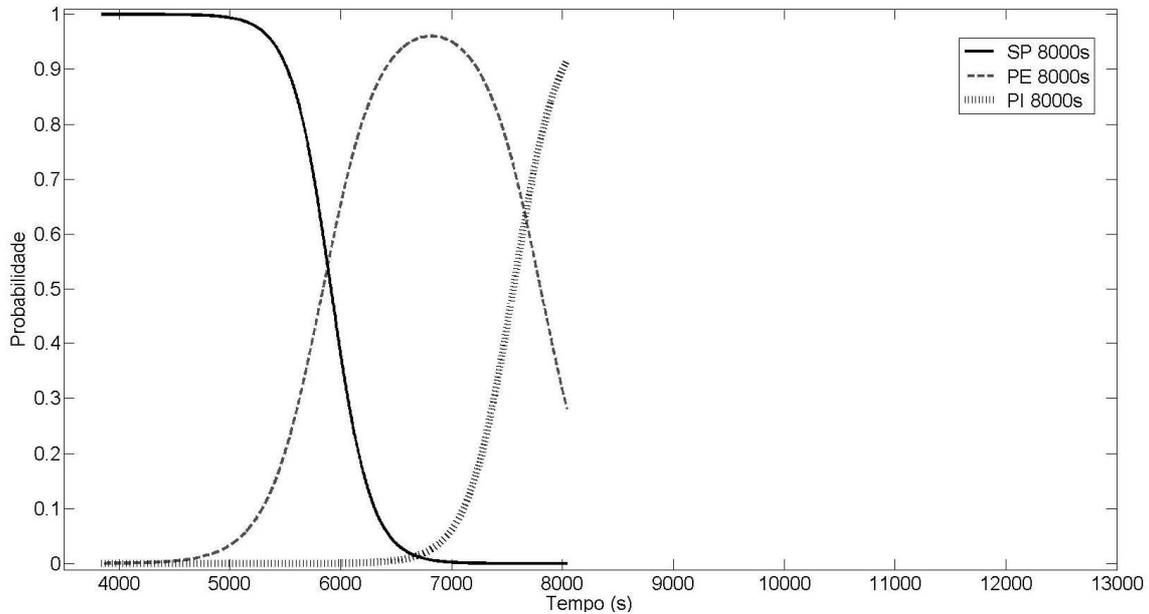


Figura 35 - Curva PoP – Destaque dos dados PE.

Quando o tempo de ensaio chega a 8000 segundos a probabilidade da entrada ser classificada como PI é de mais de 90%, enquanto de ser PE é aproximadamente 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 1.

Tabela 11 - Equações de regressão tangente hiperbólica de Ensaio 1.

Classe	Equação	
SP	$P_{SP}(t) = 0.4764 \times \tanh(0.9566 \times Z_{SP}(t) + 0.788) + 0.4984$	(15)
PE	$P_{PE}(t) = 0.4541 \times \tanh(0.6761 \times Z_{PE}(t) + 0.6295) + 0.5584$	(16)
PI	$P_{PI}(t) = 0.4657 \times \tanh(0.653 \times Z_{PI}(t) - 0.5569) + 0.5229$	(17)

A tabela 11 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 36.

De acordo com o descrito na seção 5.1.1, 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.

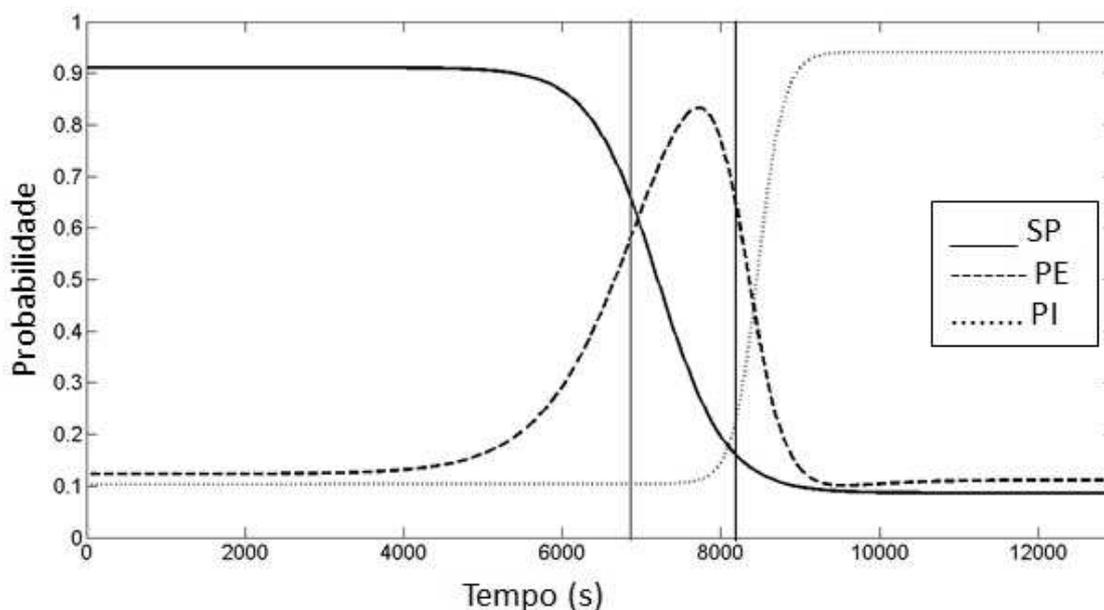


Figura 36 - Curva PoP –Ensaio 1 – separação das classes.

Analisando a figura 36, observa-se como esperado a classe SP possui maior valor de probabilidade no início do ensaio, sendo este ultrapassado pelo valor da probabilidade de SP 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 chance de o sinal pertencer à classe PE ainda é maior, mas já está em declínio enquanto a probabilidade do sinal PI está em ascendência. A probabilidade de PI ultrapassa o valor de PE em 8414 segundos, isto é, com um atraso de 270s.

Definindo os atrasos como erro de classificação, se tem $ERRO_{SP/PE}$ como sendo o erro a razão do tempo de atraso da transição de SP para PE pelo tempo total do ensaio e $ERRO_{PE/PI}$ como sendo o erro a razão do tempo de atraso da transição de PE para PI pelo

tempo total do ensaio, de acordo com a tabela 12. Os erros apresentados demonstram que a transição de classes apresentada pela curva PoP está muito próxima da transição real conhecida.

Tabela 12 - Tabela de erros de classificação percentual.

ERRO _{SP/PE}	2.1%
ERRO _{PE/PI}	0.68%

Como discussão final, destaca-se que o momento crucial de propagação está situado no limite entre as classes PE e PI, uma vez que o desejável é prever com o mínimo de antecedência a entrada no regime de propagação instável do defeito (ou propagação plástica, como é costumeiramente denominada em mecânica da fratura). Pelas curvas PoP até agora obtidas, fica evidenciado que essa técnica é promissora nessa previsão, sendo possível transformar os classificadores de padrões das redes neurais em base para o desenvolvimento de um sistema automático de monitoramento de propagação de trincas nestes equipamentos.

5.3 Análise de Agrupamentos dos Sinais de Emissão Acústica

O capítulo a seguir 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 2.

Os resultados apresentados a seguir foram alcançados 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 e 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. No último passo, um novo classificador supervisionado é treinado e sua acurácia é comparada com os resultados obtidos dos dados originais.

5.3.1 Primeiro Passo

A tabela 13 apresenta os parâmetros utilizados no treinamento da rede SOM.

Tabela 13 - Parâmetros de construção do SOM. Os valores foram determinados empiricamente.

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

A figura 37 apresenta o mapa de distâncias, os hexágonos representam os neurônios, as linhas as conexões com os neurônios vizinhos e as cores entre os neurônios as distâncias entre si. A escala de cor varia de preto ao branco em escala de cinza, onde preto significa maior e branco a menor distância, respectivamente.

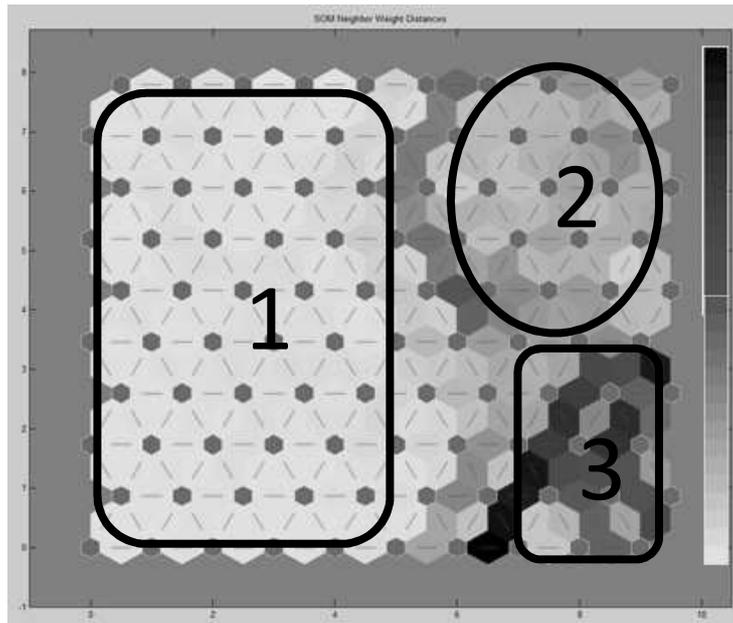


Figura 37 - SOM resultante dos dados

Analisando o SOM, é possível distinguir três regiões. A região 1 em cinza 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.

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 38. Nesta, cada hexágono representa um neurônio e o tamanho deste está diretamente relacionado com o a quantidade de ativações recebidas.

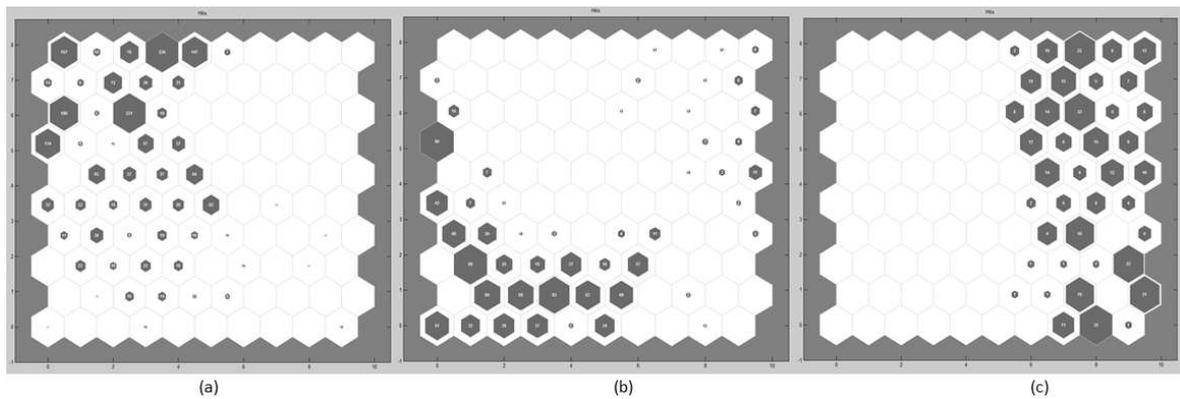


Figura 38 - Mapa das ativações dos neurônios. (a) ativação da classe SP. (b) ativação para classe PE. (c) ativação para classe PI.

Ao analisar a figura 38 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 a mesma. Objetivando eliminá-los, foi realizado o agrupamento por meio do algoritmo *K-means*. Os parâmetros ajustados são apresentados na tabela 14. 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 14 - Parâmetros de treinamento algoritmo *K-means*.

Medida de distância	Euclidiana
Número de inicializações aleatórias dos centros	100
Número de centros	3

A tabela de confusão é apresentada a seguir (tabela 15). As colunas indicam o agrupamento formado pelo algoritmo e as linhas são as classes previamente conhecidas.

Tabela 15 - Tabela Confusão.

	Grupo 1	Grupo 2	Grupo 3
Classe SP	2048	4	0
Classe PE	987	3	55
Classe PI	43	101	239

A tabela 15 confirma o resultado observado na seção 5.3.1, onde em um mesmo agrupamento estão os elementos da classe SP e PE e a classe PI está separada em dois agrupamentos diferentes. Pelo exposto, um novo conjunto de dados para a criação de um classificador supervisionado foi proposto, os elementos em destaque na tabela 15 compõem este novo conjunto, o qual foi denominado “Conjunto 1”. A figura 39 apresenta um esquema detalhado do procedimento descrito.



Figura 39 - Fluxograma da formação do novo conjunto de treinamento do classificador supervisionado.

As tabelas 16 e 17 apresentam os resultados obtidos do classificador treinado com os dados de Conjunto 1 e com os dados originais do Ensaio 2.

Tabela 16 – Resultados da acurácia média para 10 conjuntos de treino e teste formados com os dados de Conjunto 1.

	Conjunto de Treino					Conjunto de Teste			
	SP	PE	PI	NC		SP	PE	PI	NC
SP	94,0%	6,0%	-	0,0%	SP	94,0%	6,0%	-	0,0%
PE	10,0%	90,0%	-		PE	8,0%	92,0%	-	
PI	-	-	100,0%		PI	-	-	100,0%	
Média Total de acertos	93,0%				94,0%				

NC – Não Classificado.

Tabela 17 - Resultado da acurácia média para 10 conjuntos de treino e teste.

	Conjunto de Treino					Conjunto de Teste			
	SP	PE	PI	NC		SP	PE	PI	NC
SP	92,2%	6,4%	0,3%	0,3%	SP	93,0%	6,1%	0,3%	0,3%
PE	9,7%	86,7%	4,0%		PE	8,9%	84,0%	4,2%	
PI	0,7%	3,8%	95,4%		PI	1,4%	7,6%	91,4%	
Média Total de acertos	91,0%				91,0%				

NC – Não Classificado

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 2 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 15. Posteriormente, o algoritmo *K-means* foi novamente aplicado, mas desta vez apenas nestes dados. A figura 40 ilustra este novo passo.

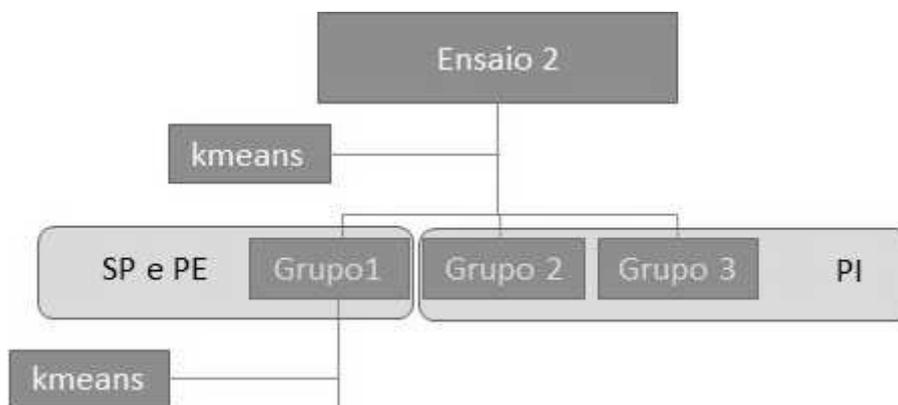


Figura 40 - Fluxograma contendo o *K-means* aplicado ao Grupo 1.

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 18, 19, 20 e 21, respectivamente.

Tabela 18 - Tabela confusão para *K*=2.

	Grupo 1	Grupo 2
Classe SP	1401	647
Classe PE	1	986

Tabela 19 - Tabela confusão para *K*=3.

	Grupo 1	Grupo 2	Grupo 3
Classe SP	18	629	1401
Classe PE	569	418	0

Tabela 20 - Tabela confusão para *K*=4.

	Grupo 1	Grupo 2	Grupo 3	Grupo 4
Classe SP	1	1401	25	621
Classe PE	15	0	597	375

Tabela 21 - Tabela confusão para K=5.

	Grupo 1	Grupo 2	Grupo 3	Grupo 4	Grupo 5
Classe SP	784	621	1	617	25
Classe PE	1	375	15	0	596

Os resultados apresentados não apontam evolução do agrupamento com K=4 para K=5, como a quantidade agrupamentos deve ser a menor possível[26], escolheu-se K=4. O Grupo 4 da tabela 20 apresenta grande concentração de elementos de ambas as classes, objetivando a separação destes, o algoritmo de *K-means* foi novamente aplicado aos dados em destaque. A figura 41 apresenta o esquema desta nova separação.

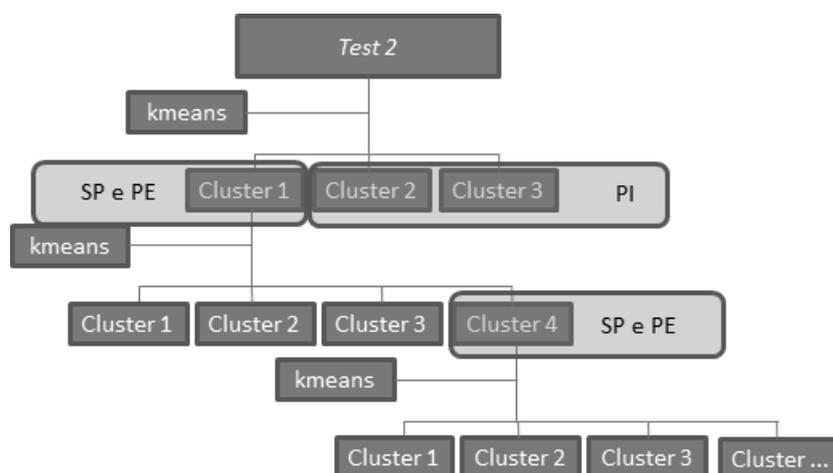


Figura 41 - Fluxograma. Algoritmo *K-means* aplicado ao grupo 4.

Novamente, são realizados agrupamentos para valores de K de 2 a 5, os resultados são apresentados nas tabelas 22, 23, 24 e 25.

Tabela 22 - Tabela confusão para K=2.

	Grupo 1	Grupo 2
Classe SP	135	486
Classe PE	110	265

Tabela 23 - Tabela confusão para K=3.

	Grupo 1	Grupo 2	Grupo 3
Classe SP	180	311	130
Classe PE	187	78	110

Tabela 24 - Tabela confusão para K=4.

	Grupo 1	Grupo 2	Grupo 3	Grupo 4
Classe SP	20	173	129	299
Classe PE	0	187	110	78

Tabela 25 – Tabela confusão para K=5.

	Grupo 1	Grupo 2	Grupo 3	Grupo 4	Grupo 5
Classe SP	180	1	8	306	126
Classe PE	187	0	20	78	90

Os resultados apresentados demonstraram que os dados do grupo 4 da tabela 20 não são passíveis de separação e, desta forma, os mesmos foram eliminados no novo conjunto formado.

O esquema da figura 42 apresenta o processo de formação do novo conjunto de dados denominado Conjunto 2. A tabela 26 detalha este conjunto.

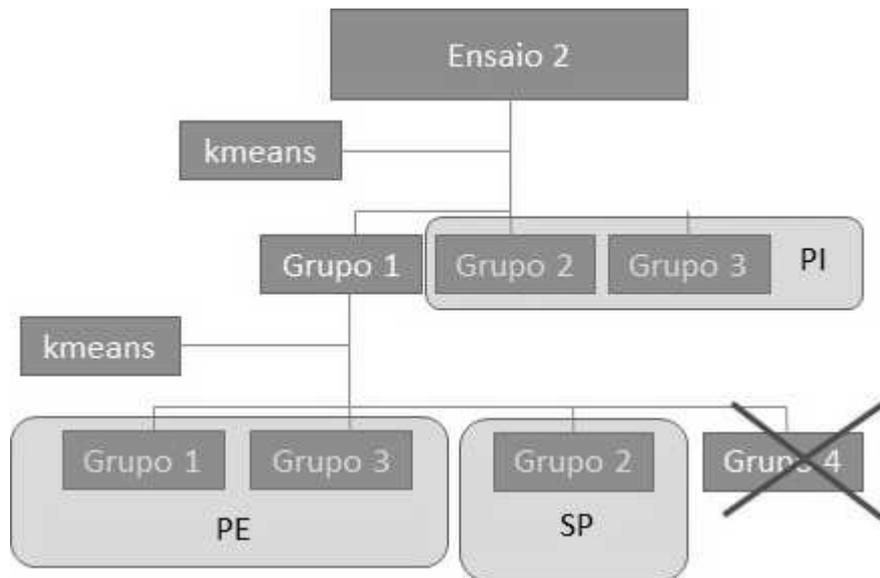


Figura 42 - Fluxograma de formação do Conjunto 2.

Tabela 26 – Tabela confusão do fluxograma apresentado na figura 12. Em destaque os dados formadores do Conjunto 2.

	Grupo 1				Grupo 2	Grupo 3
	Grupo 1	Grupo 2	Grupo 3	Grupo 4		
Classe SP	1	1401	25	621	0	4
Classe PE	15	0	597	375	55	3
Classe PI	43				239	101

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 e seus resultados são apresentados na tabela 27.

Tabela 27 - Resultados da acurácia média para 10 conjuntos de treino e teste formados com os dados de Conjunto 2.

	Conjunto de Treino					Conjunto de Teste			
	SP	PE	PI	NC		SP	PE	PI	NC
SP	1121	-	-	-	SP	280	-	-	-
PE	-	490	-		PE	-	120	2	
PI	-	-	272		PI	-	-	68	
Media Total acertos	100%				Media Total acertos	99.57%			

NC – Não Classificado.

Os resultados demonstram uma evolução de acerto de aproximadamente 9%, quando comparado com os resultados da tabela 7. Conclui-se que os dados eliminados estavam prejudicando o treinamento do classificador.

A tabela 28 apresenta os resultados obtidos quando todo o conjunto do Ensaio 2 foi aplicado ao classificador treinado com os dados do Conjunto 2.

Tabela 28 – Tabela confusão dos dados de Ensaio 2 aplicados ao classificador treinado com os dados do Conjunto 2.

	Performance			NC
	SP	PE	PI	
SP	68,6%	30,6%	0,7%	0%
PE	0%	94,5%	5,3%	
PI	0,5%	4,2%	95,3%	
Média Total de acertos	79%			

NC – Não Classificado

Neste resultado, fica evidente que os dados eliminados confundem o classificador, já que o mesmo não é capaz de diferencia-los, principalmente SP e PE. Conclui-se que os sinais excluídos foram colocados em classes erradas ou não pertencem a nenhuma delas.

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 43 apresenta o mapa das distancias entre os neurônios.

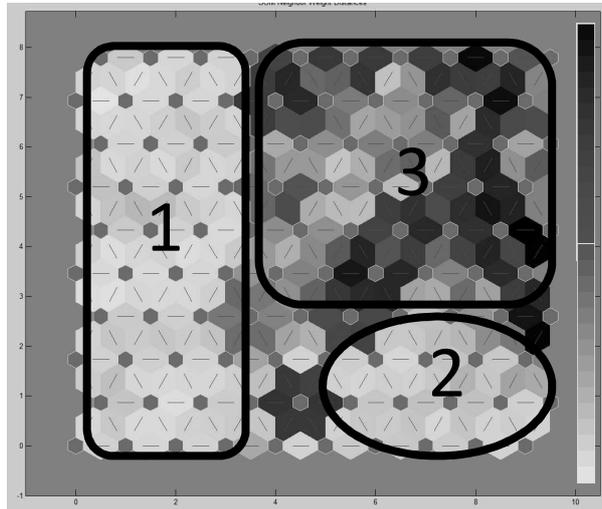


Figura 43 - Mapa das distâncias dos dados do Conjunto 2.

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 formados 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 44.

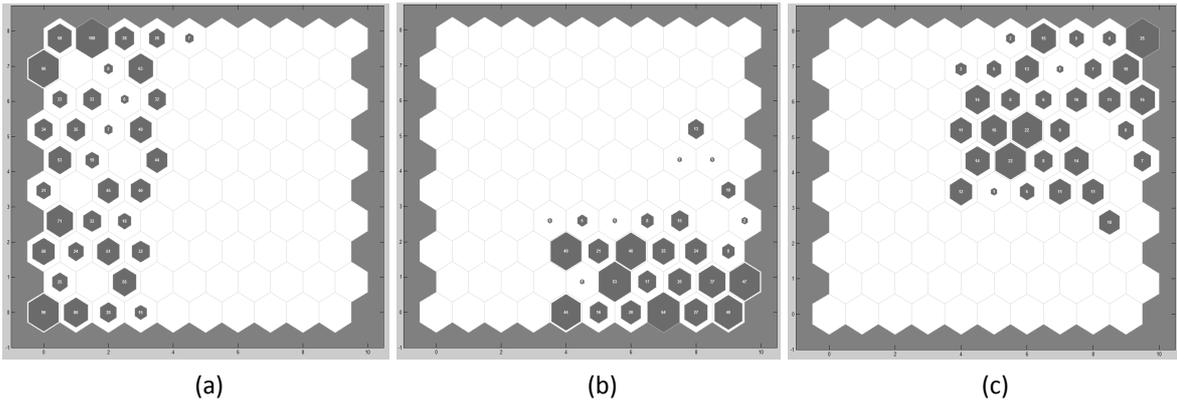


Figura 44 - Mapa das ativações dos neurônios. (a) ativação da classe SP. (b) ativação para classe PE. (c) ativação para classe PI

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.

A figura 45 apresenta o conjunto de todos os dados excluídos e os dados do Conjunto 2, plotados em relação ao tempo de ensaio, respectivamente.

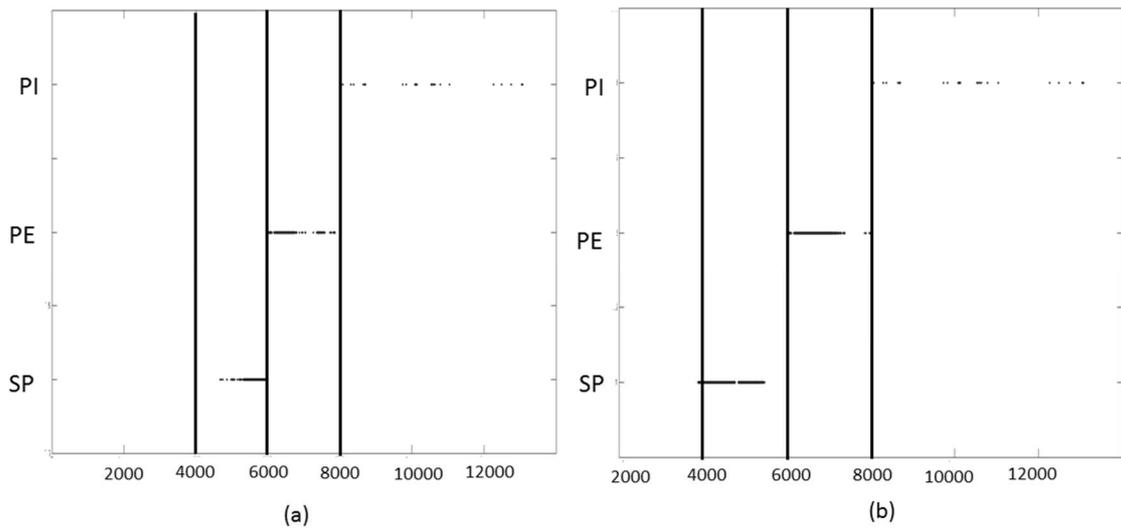


Figura 45 - gráfico de classes em relação ao tempo de ensaio. (a) todos os dados excluídos. (b) Conjunto 2.

A figura 46 apresenta o gráfico da sobreposição dos dados excluídos e do Conjunto 2. Os pontos representam os dados excluídos e os quadrados os dados de Conjunto 2.

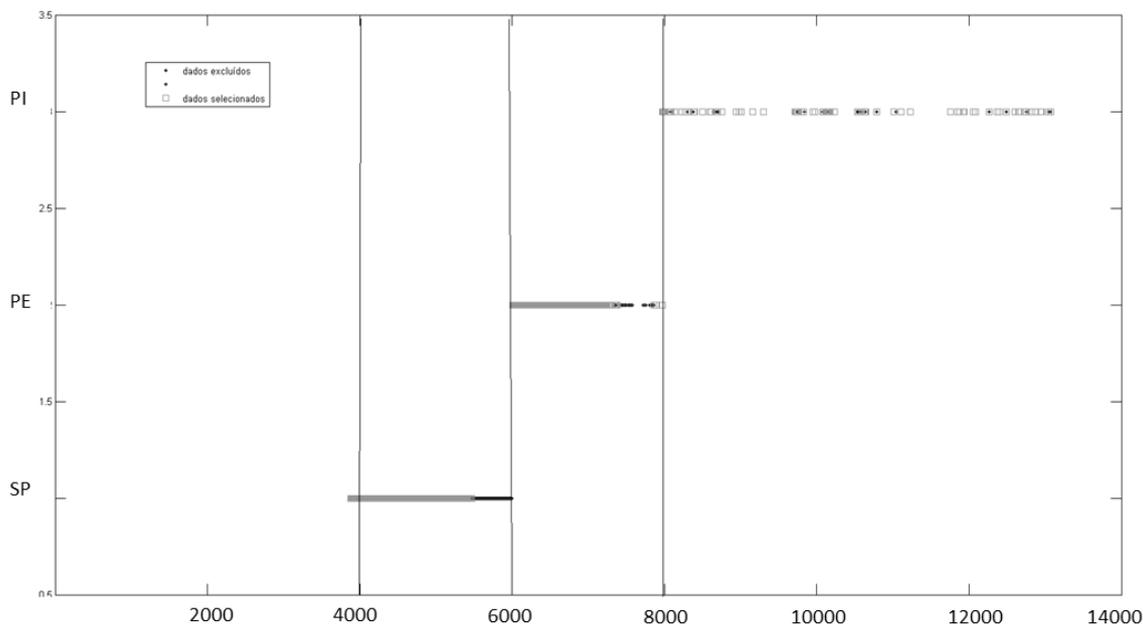


Figura 46 - - gráfico de classes em relação ao tempo de ensaio. Os quadrados representam os dados do Conjunto 2 e os pontos representam todos os dados excluídos.

Os resultados apresentados nas figuras 45 e 46, demonstram 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 29 apresenta os resultados da nova rede treinada.

Tabela 29 - 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	84,4%	15,3%	0,3%	0,5%	SP	83,9%	15,9%	0,3%	0,4%
PE	14,6%	81,5%	3,9%		PE	14,7%	83,3%	2,0%	
PI	3,0%	5,3%	91,8%		PI	5,3%	1,3%	93,4%	
Media Total acertos	83,8%				84,3%				

Os resultados da tabela 29 demonstram que o desempenho da rede diminuiu quando comparado com os resultados da tabela 7, tais resultados indicam que a hipótese da transição entre as classes SP e PE terem sido escolhidas de maneira incorreta, não é verdadeira

6 Conclusões

O presente trabalho apresentou uma metodologia inovadora voltada para identificar de forma automática a transição de 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 [1, 12]. 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 à metodologia proposta para a construção da curva PoP, esta se mostrou ser eficiente, pois em ambos os ensaios estudados obteve-se comportamento parecido e forma próxima à curva teórica proposta.

Com relação à acurácia do método de construção da curva, os resultados obtidos são bastante promissores, pois apesar dos limites de transição entre as classes não ter coincido com os pontos de interseções das curvas, situação ideal, ambos ficaram bem próximos, apresentando um erro irrelevante quando comparado com o tempo total de ensaio.

Com relação a análise de agrupamentos, os resultados demonstraram que nas classes pré-divididas existem elementos que não pertencem de fato as mesmas e, desta forma, geram erro no treinamento do classificador. A metodologia proposta mostrou-se bastante eficiente no que diz respeito a pré-seleção dos dados para o treinamento do classificador supervisionado, chegando a atingir 100% de acertos em treino e teste na classificação dos sinais de EA, resultado não alcançado nos estudos anteriores [1,3,4].

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 as demais classes evidenciando a característica peculiar do evento.

Ainda que iniciais, havendo muito desenvolvimento a ser feito, tais resultados demonstram a capacidade de se classificar probabilisticamente a propagação das trincas em dutos rígidos, sendo pioneiros, não possuindo nenhuma outra referência com resultados diretamente ligados às metodologias apresentadas para que os mesmos sejam comparados.

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.

Quanto aos agrupamentos com classes SP e PE misturados, aplicar metodologias mais robustas que as utilizadas neste trabalho com o objetivo de realizar a separação entre as 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

- [1] 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.
- [2] DA SILVA ,R.R, CALÔBA, L.P., SIQUEIRA, M.H.S., SAGRILO, L.V.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.
- [3] PINTO, C.F.C., **Monitoração de defeitos em dutos rígidos por emissão acústica**, Dissertação de M.Sc., COPPE/UFRJ, Rio de Janeiro, Brasil,2011.
- [4] Pinto, C. F. C.; 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.
- [5] Duda, R.O.; Hart, P.E., Stork, D.G. (2001): Pattern Classification. 2nd edition , U.S.A.,
- [6] Haykin, S., 1931 – **Neural networks: a comprehensive foundation** – 2nd ed – Prentice-Hall, 1999.
- [7] 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
- [8] H. Yuki, K. Homma. “Estimation of acoustic emission source waveform of fracture using a neural network.” **NDT & E International**, Vol. 29, Issue 1, February 1996, pp. 21–25.

- [9] Z. Kral, W. Horn, J. Steck. “Crack Propagation Analysis Using Acoustic Emission Sensors for Structural Health Monitoring Systems”. **The Scientific World Journal**, Vol. 2013, Article ID 823603, 13 pages.
- [10] N. Godin, S. Huguet, R. Gaertner, L. Salmon. “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.
- [11] N. Godin, S. Huguet, R. Gaertner, L. Salmon. “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.
- [12] 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
- [13] Marec, A.; Berbaoui, R.; Tomas, J.; El Mahi, A.; El Guerjouma, 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
- [14] MIX, P.E., “Introduction to nondestructive testing: a training guide”, 2nd ed., John & Sons, Inc., 2005.
- [15] SOARES, S.D., 2008, **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.
- [16] SOARES, S.D., “Emissão Acústica”, Anotações Técnicas

- [17] 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.
- [18] R.R. Silva, Reconhecimento de Padrões de Defeitos de Soldagem em Radiografias Industriais, D.Sc. Tese , Universidade Federal do Rio de Janeiro, Rio de Janeiro, Brasil, 2003.
- [19] DIAMANTIDIS, N.A., KARLIS, D., GIAKOUMAKIS, E.A., "Unsupervised Stratification of Cross-Validation for Accuracy Estimation", *Artificial Intelligence*, v.116, pp. 1-16, 2000.
- [20] 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.
- [21] K. Fukunaga, 'Introduction to Statistical Pattern Recognition', 2nd edition, USA, 1990.
- [22] T. Hastie, R. Tibshirani, J. Friedman, 'The Elements of Statistical Learning – Data Mining, Inference, and Prediction', 2nd edition, USA, 2008.
- [23] D. F. Specht, Probabilistic Neural Network, *Neural Network*, Vol. 3, pp. 109 – 118, 1990.
- [24] Drleft, 'Comparison of a histogram and a kernel density estimate.', 2010, site: http://en.wikipedia.org/wiki/File:Comparison_of_1D_histogram_and_KDE.png, em 23/04/2012.
- [25] J. Nocedal, S.J. Wright, 'Numerical Optimization', 2^a ed., USA, Springer Science, 2006.
- [26] Rajaraman, A., Ullman, J.D. (2011): *Mining of Massive Datasets*. Palo Alto, CA.

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 - CALÔBA, L. P. ; SILVA, R. R. ; SOARES, S. D. ; PINTO, C. F. C. . 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. ; Luiz P. CALÔBA ; Sergio D. SOARES4 . 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. . USO DE REDES NEURAIAS ARTIFICIAIS NA DETECÇÃO DE PROPAGAÇÃO DE DEFEITOS EM DUTOS RÍGIDOS. In: 11ª Conferência sobre Tecnologia de Equipamentos, 2011, Porto de Galinhas, PE. 11ª COTEQ 2011, 2011.

2 - PINTO, C. F. C. ; SILVA, R. R. ; Luiz P. CALÔBA ; Sergio D. SOARES4 ; 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^[1]. 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^[2].

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^[2], the correct classification of AE signals into one of the three proposed classes requires nineteen features, which are described in Table 1.

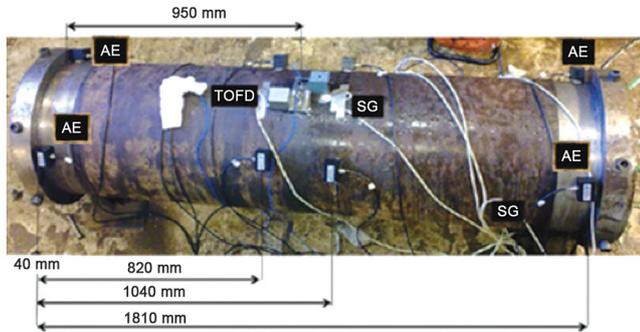


Figure 1. Schematic of positioning of the sensors close to the region of the crack on the inner surface of the specimens. Dimensions in mm. TOFD: ultrasound transducer; SG: strain gauge sensor; AE: acoustic emission sensor

Table 1. Acoustic emission features collected^[2]

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)^[2].

2.5 The neural classifier

Artificial neural networks were used to implement non-linear pattern classifiers^[3,4].

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^[3,4]. 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%)^[5]. More details can be obtained in Silva *et al*^[6].

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

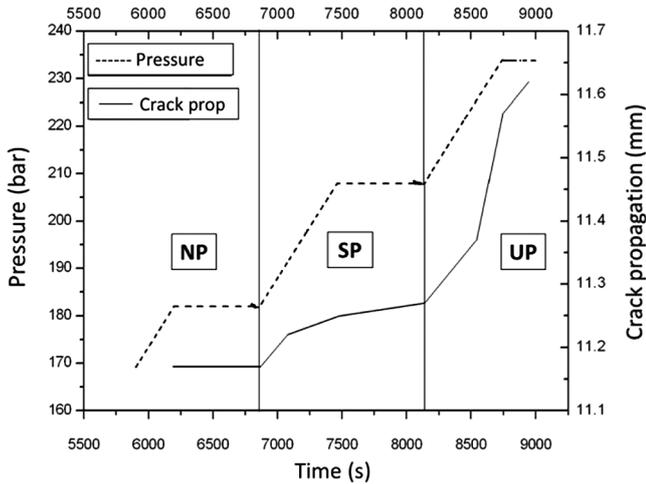


Figure 2. The dashed line represents the plot of pressure versus time and the continuous line represents the plot of crack propagation versus time

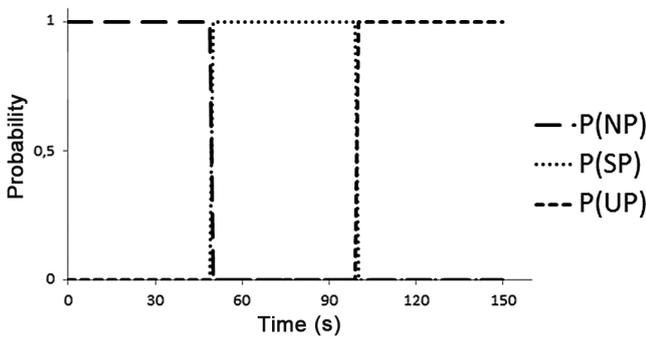


Figure 3. The long-dashed line represents the NP probability, the dotted line the SP probability and the short-dashed line the UP probability

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^[7].

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^[7]. In the second and last stage, the classification is done using Bayes theorem^[8].

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^[9], 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^[7,8].

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

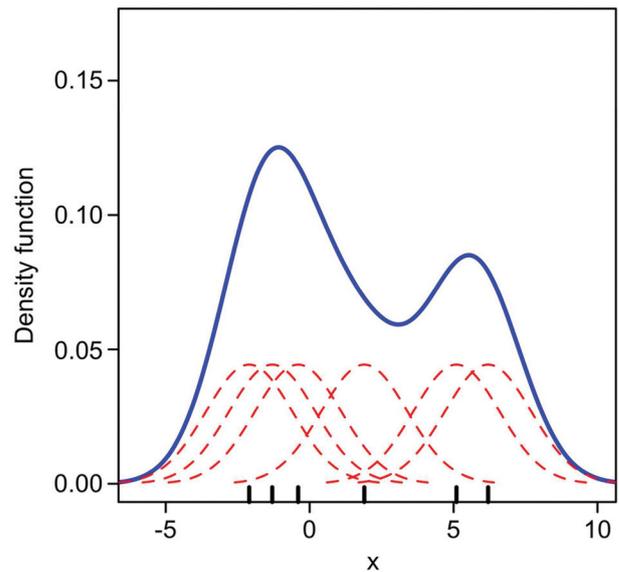


Figure 4. The curve with the continuous line is the estimated density and the dashed lines are the Kernel functions for each indicated point^[10]

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)^[8]. 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^[11].

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^[8], 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):

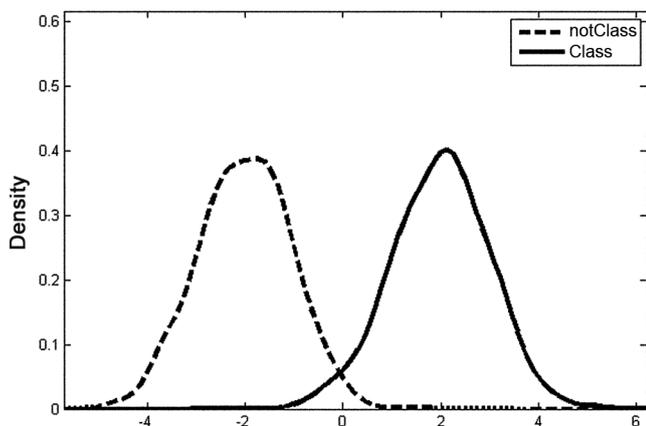


Figure 5. The continuous line represents the class probability density and the dashed line the density of the not-class. Hypothetical data

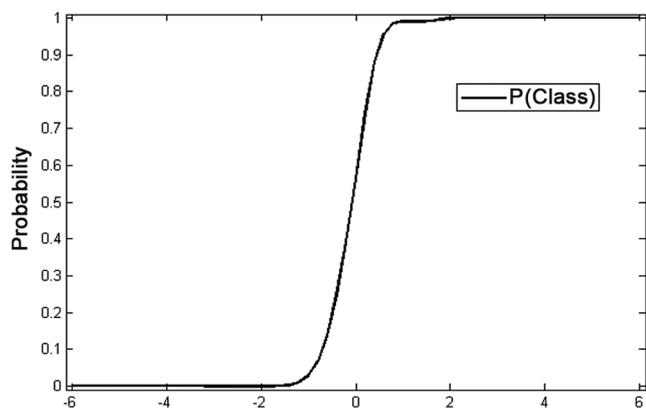


Figure 6. Posteriori probability curve for the class, generated from the probability density

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

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^[2], the unbalance of data between the classes does not affect the performance of the trained network.

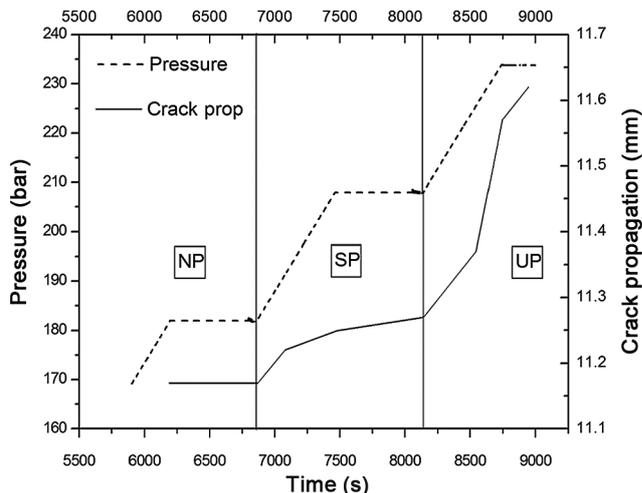


Figure 7. The dashed line represents the plot of pressure versus time and the continuous line represents the plot of crack propagation versus time

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*^[11].

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^[11]) 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.

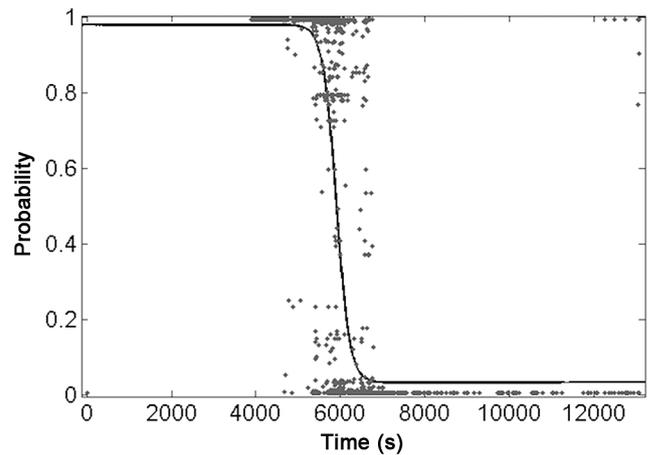


Figure 8. Probability of the NP class. The dots represent the probability for each value of Z and the continuous line is the regression function of these dots

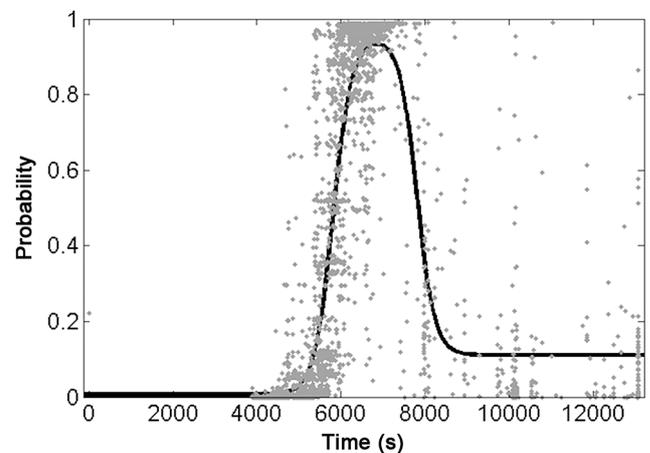


Figure 9. Probability of the SP class. The dots represent the probability for each value of Z and the continuous line is the regression function of these dots

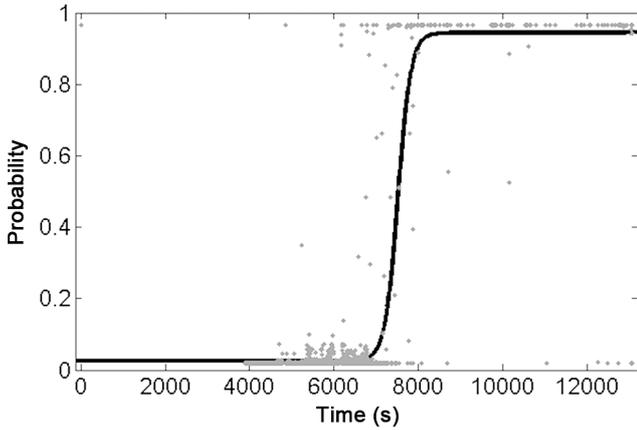


Figure 10. Probability for the UP class. The dots represent the probability for each value of Z and the continuous line is the regression function of these dots

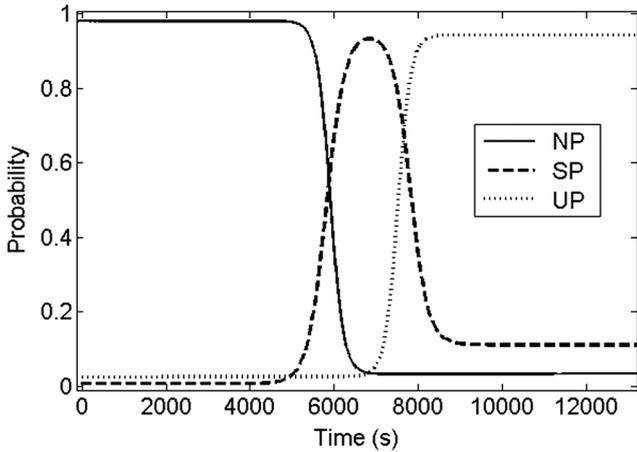


Figure 11. POP curve

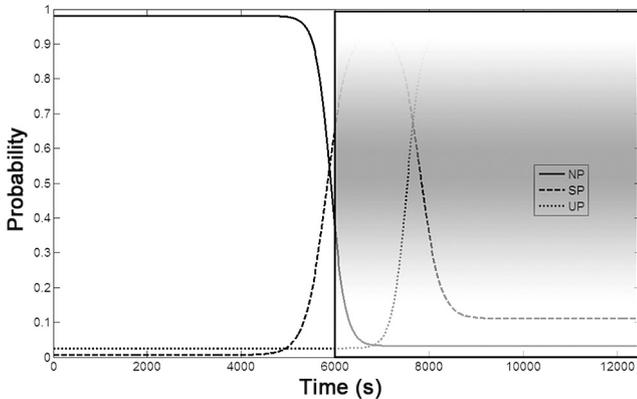


Figure 12. POP curve - highlighting NP data

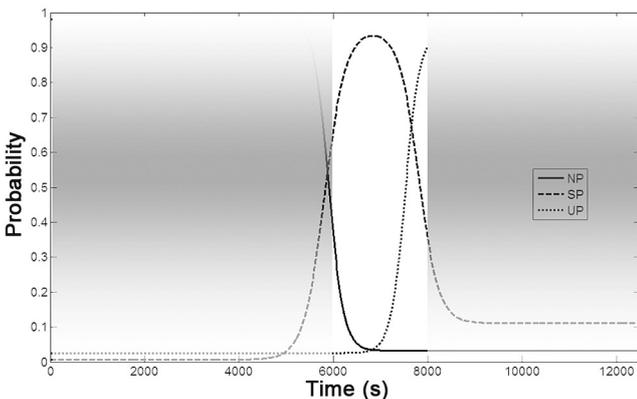


Figure 13. POP curve - highlighting SP data

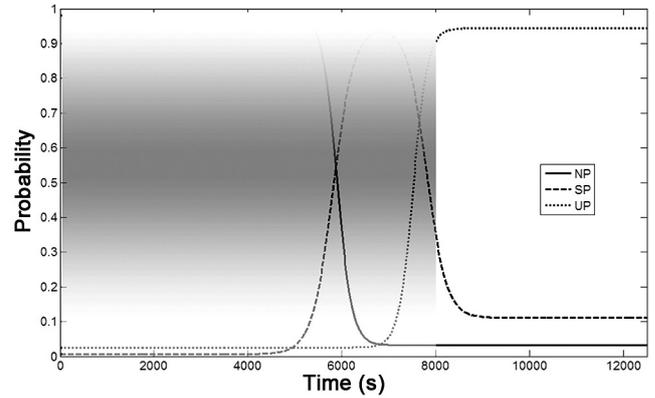


Figure 14. POP curve - highlighting UP data

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)

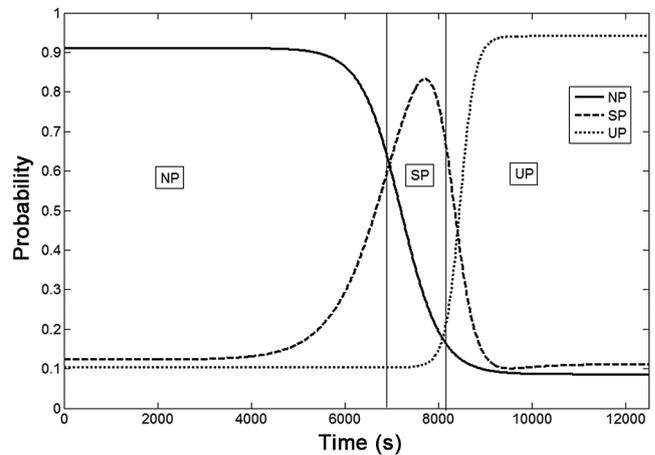


Figure 15. POP curve for test 1 - separated classes

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^[1,12]. 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, 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.