

UNIVERSIDADE FEDERAL DO RIO DE JANEIRO – UFRJ
INSTITUTO ALBERTO LUIZ COIMBRA DE PÓS-GRADUAÇÃO
E PESQUISA DE ENGENHARIA – COPPE
PROGRAMA DE ENGENHARIA ELÉTRICA – PEE

MONITORAMENTO DA PROPAGAÇÃO DE DEFEITOS
EM DUTOS RÍGIDOS POR REDES NEURAIS:
ESTUDO DA EMISSÃO ACÚSTICA BASEADO NA FORMA DE ONDA

ORLANDO GÉA

RIO DE JANEIRO, RJ
DEZEMBRO DE 2015

MONITORAMENTO DA PROPAGAÇÃO DE DEFEITOS
EM DUTOS RÍGIDOS POR REDES NEURAIAS:
ESTUDO DA EMISSÃO ACÚSTICA BASEADO NA FORMA DE ONDA

Orlando Géa

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

Orientadores: Luiz Pereira Calôba

Romeu Ricardo da Silva

Rio de Janeiro
Dezembro de 2015

MONITORAMENTO DA PROPAGAÇÃO DE DEFEITOS
EM DUTOS RÍGIDOS POR REDES NEURAIIS:
ESTUDO DA EMISSÃO ACÚSTICA BASEADO NA FORMA DE ONDA

Orlando Géa

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. José Gabriel Rodriguez Carneiro Gomes, Ph.D.

Eng. Romeu Ricardo da Silva, D.Sc.

Eng. Marcio Humberto Silva Siqueira, D.Sc.

Prof^a. Marley Maria Bernardes Rebuszi Vellasco, Ph.D.

Eng. Sergio Damasceno Soares, D.Sc.

RIO DE JANEIRO, RJ - BRASIL

DEZEMBRO DE 2015

Géa, Orlando

Monitoramento da propagação de defeitos em dutos rígidos por redes neurais: estudo da emissão acústica baseado na forma de onda / Orlando Géa – Rio de Janeiro: UFRJ/COPPE, 2015.

XV, 171 p.: il.; 29,7 cm.

Orientadores: Luiz Pereira Calôba

Romeu Ricardo da Silva

Tese (doutorado) – UFRJ/ COPPE/ Programa de Engenharia Elétrica, 2015.

Referências Bibliográficas: p. 145-149.

1. Emissão Acústica. 2. Redes Neurais. 3. Dutos Rígidos Pressurizados. 4. Modulação Analógica. I. Calôba, Luiz Pereira *et al.* II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Elétrica. III. Título.

DEDICATORIA

Dedico

aos meus pais, Valdete de Fátima Géa e Ronaldo Géa, e

aos meus irmãos, Cristiane Géa e Guilherme Géa,

por tudo que representam em minha vida.

AGRADECIMENTO

A Deus por prover todas as oportunidades em minha vida.

Agradeço aos meus pais, Valdete e Ronaldo, e irmãos, Cristiane e Guilherme, pelo apoio incondicional e por sempre acreditarem em mim.

Ao prof. Luiz Calôba pela compreensão das dificuldades passadas por mim durante o curso. Pelos inúmeros conselhos e preocupações nas orientações. Como também pelo convite para participar do projeto de pesquisa. Após esta jornada, entendo o verdadeiro significado da frase, “*ao mestre com carinho*”.

Ao Romeu Silva pela paciência de explicar metalurgia em seus exemplos práticos e pela atenção dada sempre que solicitada.

Ao Sergio Damasceno representando o Centro de Pesquisas e Desenvolvimento Leopoldo Américo Miguez de Mello (CENPES) da PETROBRAS pela viabilização do projeto de pesquisa (P&D), “*Monitoração de Defeitos em Dutos Rígidos por Redes Neurais*”, e pelas discussões importantes a respeito do assunto nas reuniões do projeto.

À equipe do Laboratório de Metalurgia Física (LAMEF) da UFRGS pelo apoio técnico e operacional nos ensaios hidrostáticos e pela convivência durante os períodos de ensaios experimentais ocorridos em Porto Alegre.

A todos que diretamente ou indiretamente participaram da minha trajetória no curso de doutorado até o presente momento. Dentre todos cito: Luciana Oliveira por sua força e seu otimismo incontestáveis durante os anos; seus pais, Marilza e Luiz Armando, pelo carinho; Angélica Ravagnani pelo apoio, discussões e dicas; professores da UFF, Tarcísio Dantas, Leni Matos e Julio Dal Bello, pelo incentivo acadêmico na graduação e no mestrado.

À Fundação Carlos Chagas Filho de Amparo à Pesquisa do Estado do Rio de Janeiro (FAPERJ) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelas bolsas de estudos.

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

MONITORAMENTO DA PROPAGAÇÃO DE DEFEITOS
EM DUTOS RÍGIDOS POR REDES NEURAIAS:
ESTUDO DA EMISSÃO ACÚSTICA BASEADO NA FORMA DE ONDA

Orlando Géa

Dezembro / 2015

Orientadores: Luiz Pereira Calôba

Romeu Ricardo da Silva

Programa: Engenharia Elétrica

Esta tese apresenta uma estrutura de rede híbrida – rede neural especializada – com topologia baseada no princípio da superposição das modulações analógicas – linear e não linear. A arquitetura da rede é modelada para avaliar as transições entre os sinais provenientes do ensaio não destrutivo de emissão acústica registrados durante o ensaio hidrostático em corpos de prova contendo defeitos tipo trinca. Por meio do processo de treinamento supervisionado, os parâmetros das portadoras são estimados nos pesos sinápticos com a aplicação do algoritmo *backpropagation* em todos os elementos internos da arquitetura da rede híbrida. Estes parâmetros ilustram a dinâmica entre os sinais pela comparação na forma temporal da onda do sinal via modulações e utilizados como entrada em classificadores não lineares – não supervisionados. As classes de propagação da trinca (Sem Propagação, Propagação Estável ou Propagação Instável) indicam a correlação entre a dinâmica dos sinais conforme a propagação da trinca e a pressão interna do duto pressurizado. A metodologia pode ser aplicada em qualquer conjunto de séries temporais para a rede híbrida estimar os parâmetros das portadoras analógicas que por superposição modulam um sinal em outro do conjunto e posteriormente classificados. Em suma, a tese propõe a classificação dos sinais a partir da decomposição destes em modulações analógicas por rede neural. O estudo apresentou resultados em torno de 91,2% a 94,3% de acerto na classificação não supervisionada a partir dos parâmetros das portadoras estimados pela rede híbrida nas classes de propagação.

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 DEFECT PROPAGATION
IN RIGID PIPES VIA NEURAL NETWORKS:
STUDY OF ACOUSTIC EMISSION BASED ON WAVEFORMS

Orlando Géa

December / 2015

Advisors: Luiz Pereira Calôba
Romeu Ricardo da Silva

Department: Electrical Engineering

This thesis presents a hybrid network structure (specialized neural network) with topology based on the principle of superposition of linear and non-linear analogue modulations. The network architecture is modeled to evaluate the transitions between the signals arising from non-destructive testing of acoustic emissions recorded during hydrostatic testing in specimens containing crack-like defects. Through the supervised training process, the carrier parameters are estimated in the synaptic weights, using the backpropagation algorithm in all the internal elements of the hybrid network architecture. These parameters illustrate the dynamics between the signals through temporal comparison of the signal's wave via modulations, and this is used as input in non-linear unsupervised classifiers. The propagation classes of the crack (No Propagation, Stable Propagation, or Unstable Propagation) indicate the correlation between the dynamics of the signals in accordance with the propagation of the crack and the internal pressure of the pressurized pipeline. The methodology can be applied to any set of temporal series for the hybrid network to estimate the parameters of the analogue carriers which (via superposition) modulate a signal into another of the set and then classify it. In summary, the thesis proposes classification of the signals based on their separation into analogue modulations by neural network. The study produced results with 91.2–94.3% accuracy in the unsupervised classification, based on the carrier parameters estimated by the hybrid network in the propagation classes.

SUMÁRIO

1	Introdução.....	1
1.1	Objetivo do Trabalho	4
1.2	Motivação do Estudo	5
1.3	Contribuições do Trabalho.....	6
2	Revisão da Literatura.....	8
2.1	O Fenômeno de Emissão Acústica	8
2.2	Aplicações da técnica de Emissão Acústica	10
2.3	Agentes influentes no processo de Emissão Acústica	19
2.4	A Fonte de Emissão Acústica	20
2.5	Processos inerentes ao Ensaio Hidrostático.....	23
2.6	Fundamentos para a Emissão Acústica.....	24
2.7	Características dos Sensores no Ensaio	25
2.8	A Forma de Onda de Emissão Acústica	27
2.9	Emissão Acústica e Inteligência Computacional.....	30
2.10	Elementos de Ensaio Hidrostático Controlado.....	35
2.11	Fundamentos da Ciência dos Materiais.....	38
2.11.1	Rigidez e Peso	39
2.11.2	Resistência e ductilidade	41
2.11.3	Mecânica da Fratura	45
2.11.4	Fadiga	49
2.12	Ondas Elásticas em Sólidos.....	51
2.13	Modulações Analógicas	52
2.13.1	Modulação em Amplitude	55
2.13.2	Modulação em Ângulo	60

2.14	Redes Neurais Artificiais	64
2.14.1	Rede Supervisionada	70
2.14.2	Rede Não Supervisionada.....	73
3	Metodologia.....	77
3.1	Princípios da Metodologia	77
3.2	Modelo Matemático da Rede Neural Híbrida.....	79
3.3	Modelo Computacional da Rede Neural Híbrida.....	83
4	Procedimento Experimental	93
5	Resultados Numéricos	114
6	Conclusão e Trabalhos Futuros	141
6.1	Conclusões	141
6.2	Trabalhos Futuros	142
7	Referências Bibliográficas.....	145
	Apêndice A – Gráficos dos parâmetros comparativos	150
	Apêndice B – Gráficos dos parâmetros VALLEN	152
	Apêndice C – Gráficos dos parâmetros PAC	153
	Apêndice D – Artigo	156

LISTA DE FIGURAS

Figura 1 – Resultado de teste hidrostático sem acompanhamento de ferramenta de avaliação de integridade estrutural [2].....	3
Figura 2 – Visualização dos danos causados por falhas catastróficas em gasodutos [37].	18
Figura 3 – Classificação do tipo de agrupamentos de sinais EA por quantidade versus faixa de pressão interna segundo a norma JIS Z 2342-2002 [4].	22
Figura 4 – Emissão Acústica com os fenômenos Efeito Kaiser, Efeito Felicity e Corolário de Dunegan durante ciclos de carga de pressão [3].	25
Figura 5 – (a) Emissão de fratura (b) Emissão Contínua [6].....	27
Figura 6 – Formato padrão da forma de onda para emissão acústica [3].	28
Figura 7 – Parâmetros temporais de aquisição da onda EA [1].....	30
Figura 8 – Gráfico da relevância dos parâmetros em cada classe [39].....	33
Figura 9 – Histograma/Relevância dos parâmetros para as classes juntas [39].	34
Figura 10 – Separação de conjuntos pela relevância com percentual de acerto na classificação de cada conjunto [39].	34
Figura 11 – Curva PoP [39].	35
Figura 12 – Variação da pressão e das deformações nas duas extremidades da trinca durante o ensaio hidrostático [40].	37
Figura 13 – Variação das deformações durante o ensaio hidrostático medidas com a roseta extensométrica nas direções longitudinal, a 45 graus e na transversal do tubo [40].	37
Figura 14 – Taxonomia do reino dos materiais e seus atributos [41].	39
Figura 15 – Modos de carregamento e estados de tensão [41].	40
Figura 16 – Definição de tensão, deformação e módulos de elasticidade [41].	41
Figura 17 – Curva de tensão de tração-deformação para metais [41].	42
Figura 18 – Defeitos em Cristais: (a) Vacância (b) Impurezas (c) Deslocamento (d) Contornos [41].	44
Figura 19 – Processo de discordância [41].	45
Figura 20 – Linhas de forças de um corpo trincado sob carga [41].	46
Figura 21 – Liberação de energia elástica quando uma trinca propaga [41].	47

Figura 22 – Zona plástica se forma na ponta da trinca, onde caso contrário, a tensão ultrapassaria a tensão de escoamento [41].....	48
Figura 23 – Transição de escoamento para a fratura no comprimento da trinca crítico (c_{crit}) [41].....	48
Figura 24 – Propagação da trinca [41].	49
Figura 25 – (a) Fadiga de alto ciclo (b) Fadiga de baixo ciclo [41].	50
Figura 26 – Energia de interação efetiva entre dois íons [42].	51
Figura 27 – (a) modelo em equilíbrio (b) deslocamentos dos íons numa onda longitudinal (c) deslocamentos dos íons numa onda transversal [42].	52
Figura 28 – Processo de modulação	54
Figura 29 – Modulação e Demodulação AM [44].....	58
Figura 30 – Sinais no domínio do tempo durante a modulação e a demodulação [44].	59
Figura 31 – Sinais no domínio da frequência durante a modulação e a demodulação [44].	59
Figura 32 – Conceito de frequência instantânea [44].	60
Figura 33 – Relações entre as modulações PM e FM: (a) FM (b) PM [44].	62
Figura 34 – Processo básico de demodulação em ângulo [44].	62
Figura 35 – (a) Sinal modulante (b) derivada do sinal modulante (c) sinal FM (d) sinal PM [44].	63
Figura 36 – (a) Sinal modulante (b) derivada do sinal modulante (c) sinal FM (d) sinal PM [44].	63
Figura 37 – Circuito Lógico XOR(c) e circuitos equivalentes (a,b).	67
Figura 38 – Rede Neural.....	68
Figura 39 – Rede PMC [45].	71
Figura 40 – Princípio do algoritmo <i>K-means</i>	74
Figura 41 – Grade de neurônios de duas dimensões com quatro entradas e nove neurônios (mapa 3x3).	75
Figura 42 – Algoritmo de formação do SOM.....	76
Figura 43 – Metodologia	78
Figura 44 – Diagrama de Processo do Fenômeno de Emissão Acústica.....	78
Figura 45 – Modelo da metodologia.....	80
Figura 46 – Modelo grafo de fluxo de sinais. Parte Superior: $a_3F[K_{fm}, f_{fm}, m(t)]$ – Parte Central: $a_2F[K_{pm}, f_{pm}, m(t)]$ – Parte Inferior: $a_1F[K_{am}, f_{am}, m(t)]$	83

Figura 47 – Rede Neural Híbrida.	84
Figura 48 – Estrutura Computacional da Rede Híbrida apresentando os nós computacionais e os elos de computacionais.	86
Figura 49 – Rede Neural Híbrida	88
Figura 50 – Exemplo de uma família de sinais.	91
Figura 51 – Visualização do sistema de montagem do tubo para o ensaio hidrostático [47].	93
Figura 52 – Seção tubular submetida a uma pressão interna - longitudinal [47].	94
Figura 53 – Seção tubular submetida a uma pressão interna - transversal [47].	95
Figura 54 – Preparativos do corpo de ensaio no <i>bunker</i> para realização do ensaio hidrostático.	95
Figura 55 – Estrutura do Ensaio Hidrostático Experimental.	96
Figura 56 – Estrutura de dados do ensaio.	97
Figura 57 – Tela inicial do programa de análise.	98
Figura 58 – Estrutura do corpo de prova no ensaio hidrostático.	99
Figura 59 – Coordenadas dos sensores considerando a trinca na origem (0,0).	100
Figura 60 – Variação de Pressão e Profundidade da Trinca medida pelo ToFD.	100
Figura 61 – Distribuição dos sinais EA, da pressão e da dimensão da trinca durante o ensaio hidrostático.	103
Figura 62 – Distribuição dos sinais EA, da pressão e dos impulsos ocorridos na medição da trinca durante o ensaio hidrostático.	105
Figura 63 – Distribuição dos sinais EA pelos canais durante o ensaio hidrostático. ...	107
Figura 64 – Representação gráfica da Tabela 2.	108
Figura 65 – Quantidades de sinais EA por canal (sensor).	109
Figura 66 – Distribuição dos sinais EA registrados no tempo por sensor.	111
Figura 67 – Plano XY (Tempo versus Sensor) da Figura 66.	112
Figura 68 – Plano XZ (Tempo versus Sequencia EA) da Figura 66.	113
Figura 69 – Plano YZ (Sensor versus Sequencia EA) da Figura 66.	113
Figura 70 – Subconjunto de sinais EA contido na classe de propagação PE.	114
Figura 71 – Subconjunto de sinais EA contido na classe de propagação PI.	115
Figura 72 – Média e Variância dos sinais EA.	115
Figura 73 – Espectros de Frequências do subgrupo de sinais EA na classe de propagação PE representados na Figura 70.	117

Figura 74 – Espectros de Frequências do subgrupo de sinais EA na classe de propagação PI representados na Figura 71.	118
Figura 75– Sinal no domínio do tempo e da frequência - Exemplo de sinal na classe de propagação PE (Sinal Completo, Parte do Sinal selecionado pela Janela e Parte do Sinal Suprimida).	119
Figura 76 – Sinal no domínio do tempo e da frequência - Exemplo de sinal na classe de propagação PE. (Sinal Completo, Parte do Sinal selecionado pela Janela e Parte do Sinal Suprimida)	120
Figura 77 – Sinais no domínio do tempo e da frequência - Exemplo de sinal na classe de propagação PI. (Sinal Completo, Parte do Sinal selecionado pela Janela e Parte do Sinal Suprimida).	121
Figura 78 – Sinais no domínio do tempo e da frequência - Exemplo de sinal na classe de propagação PI. (Sinal Completo, Parte do Sinal selecionado pela Janela e Parte do Sinal Suprimida)	122
Figura 79 – Curva de erro durante o treinamento.....	123
Figura 80 – Resultado do Mapa SOM.	126
Figura 81 – Curva de Erro Médio Quadrado e Diferença Vetorial para uma simulação do SOM.	126
Figura 82 – Dispersão final dos vetores com a indicação de classe.....	127
Figura 83 – Exemplo de mapa resultante dos parâmetros dos sinais EA's.....	128
Figura 84 – Matriz da correlação na frequência de cada sinal em relação ao conjunto de sinais do ensaio hidrostático.	129
Figura 85 – Matriz da correlação no tempo de cada sinal em relação ao conjunto de sinais do ensaio hidrostático.	129
Figura 86 – Correlação da Energia Relativa.....	131
Figura 87 – Médias Móveis para a distribuição da Figura 86.	131
Figura 88 – Destaque dos grupos para análise da energia.	132
Figura 89 – 1ª faixa ($0,4 \cdot 10^5$ Hz a $0,9 \cdot 10^5$ Hz).....	134
Figura 90 – 2ª faixa ($0,4 \cdot 10^5$ Hz a $0,6 \cdot 10^5$ Hz).....	135
Figura 91 – 3ª faixa ($0,8 \cdot 10^5$ Hz a $0,9 \cdot 10^5$ Hz).....	136
Figura 92 – 4ª faixa ($1,6 \cdot 10^5$ Hz a $4,2 \cdot 10^5$ Hz).....	137
Figura 93 – 5ª faixa ($2,0 \cdot 10^5$ Hz a $2,4 \cdot 10^5$ Hz).....	138
Figura 94 – Distribuição da Energia por Classe de Propagação.....	140

Figura 95 – Ensaios hidrostático experimental para dutos longos (coluna esquerda: visão do corpo de provas de 40 metros – coluna direita: trinca, trinca e ToFD e trinca após o ruptura:	143
Figura 96 – Sistema de aquisição <i>streaming</i>	144

LISTA DE TABELAS

Tabela 1 – Parâmetros de emissão acústica extraídos de ensaios [39].....	32
Tabela 2 – Características das sub-regiões da classe PE.....	108
Tabela 3 – Estatísticas nos intervalos de tempo das classes de propagação.....	109
Tabela 4 – Faixas de Frequências e Correlações.....	132
Tabela 5 – Percentual de acertos pela classificação por <i>k-means</i>	139

1 INTRODUÇÃO

O campo da engenharia é dividido em áreas de atuação e neste trabalho se apresenta o compartilhamento de conhecimentos entre duas áreas: Engenharia Elétrica e Engenharia Metalúrgica/Materiais.

As ferramentas de análise comumente utilizadas na Engenharia Elétrica, como Análise e Processamento de Sinais, Análise de Sistemas, Inteligência Computacional, Transitórios e outras, são integradas ao contexto da Engenharia Metalúrgica e de Materiais no que tange ao estudo do processo de Emissão Acústica (EA) por elementos metalúrgicos (descontinuidades) em duto pressurizado. Este fenômeno se baseia na transformação de energia – química, mecânica ou elétrica – em ondas mecânicas – energia sonora – pelo Princípio da Conservação de Energia.

A emissão acústica também está presente em fenômenos da Engenharia Elétrica, como por exemplo: no ruído elétrico/magnético produzido por falta de aterramento; nas variações do campo magnético na estrutura, nas descargas elétricas e na súbita magnetização de materiais ferrosos, emissão magneto-acústica¹. As fontes de interesse para a área de petróleo e gás seriam, por exemplo, a monitoração da corrosão de fundos de tanques, as deformações plásticas em metais, o vazamento de líquido em vaso de pressão (fluxo turbulento) e as deformações (escoamento e crescimento de trinca) [1].

A maior contribuição desta técnica é a de viabilizar a análise do comportamento dinâmico das descontinuidades. Isso permite a inspeção de equipamentos em serviço para avaliar a presença de descontinuidades que possam comprometer sua condição de integridade e possível falha.

A detecção destas descontinuidades se torna um assunto importante para as áreas da Engenharia de Manutenção/Inspeção, pois o desenvolvimento de técnicas de inspeção não destrutiva para a detecção das descontinuidades pode reduzir possíveis paralisações da operação.

¹ Geração de ondas elásticas devido a rápidas e descontínuas mudanças na magnetização do material que induzem deformações locais – magnetoestricção.

Esta importância levou o Centro de Pesquisas da Petrobras (CENPES²), desde 1979, a realizar projetos de pesquisa no tema da emissão acústica em ambientes da indústria de petróleo e gás. O grupo de pesquisa da Associação Brasileira de Ensaio Não Destrutivos e Inspeção (ABENDI³) preparou um programa em 1988 com o objetivo de desenvolver a técnica de emissão acústica no país [2].

O interesse da aplicação da técnica de emissão acústica na indústria de petróleo e gás é apresentado pelo fato dos dutos de transporte de derivados de petróleo geralmente apresentarem comprimentos superiores a 100 km e encontrarem-se enterrados. Durante a operação destes dutos, a atividade de inspeção torna-se complicada pela impossibilidade de realizar a inspeção em toda a extensão do duto sem o auxílio de *pigs*⁴ instrumentados.

A funcionalidade da análise de emissão acústica está direcionada no perfil da manutenção industrial. O perfil da manutenção em plantas do setor industrial pode ser classificado como [3]:

- a) Manutenção Corretiva: correção da falha ou do desempenho menor do que o esperado.
- b) Manutenção Preventiva: realizada de forma a reduzir ou evitar a falha ou queda no desempenho de acordo com um plano periódico previamente elaborado.
- c) Manutenção Preditiva: realizada com base em modificação de parâmetro de condição ou desempenho, cujo acompanhamento obedece a uma sistemática.
- d) Manutenção Detectiva: atuação efetuada em sistemas de proteção buscando detectar falhas ocultas ou não perceptíveis à equipe de operação e manutenção.

Dos tipos de manutenções apresentados, a técnica de Ensaio Não Destrutivos (END) utiliza o fenômeno de emissão acústica em manutenção preventiva. Isso se deve ao fato de que uma descontinuidade quando submetida a uma solicitação pode se tornar uma área geradora de sinais de emissão acústica. Sendo assim, a descontinuidade

² Centro de Pesquisas e Desenvolvimento Leopoldo Américo Miguez de Mello.

³ <http://www.abendi.org.br>

⁴ Sistemas de inspeção de dutos dotados de sensores.

representa uma área de concentração de tensões que devida à estimulação origina uma redistribuição de tensões localizadas com a liberação rápida de ondas de tensão mecânica, localizadas internamente no material na forma de ondas mecânicas transientes [2].

Por tudo proposto acima, a principal motivação para o tema em questão é o conhecimento do fenômeno de emissão acústica por meio das ferramentas e técnicas existentes para a análise dos dados em ensaios hidrostáticos. Com esse conhecimento, os profissionais da área de Metalurgia/Materiais responsáveis pela tomada de decisão durante a inspeção e a manutenção de dutos pressurizados poderão aplicá-las em dados que estiverem à sua disposição para concluir hipóteses, criar cenários, modelar tendências e simular comportamentos.

As respostas desses estudos em ambiente controlado permitem a visualização de características que podem auxiliar os profissionais responsáveis pelas plantas industriais na tomada de decisão durante uma gestão estratégica operacional de dutos (planejamento e gestão da manutenção). Os quais poderiam trazer consequências inesperadas para a indústria em caso de falha na integridade estrutural – desastres ecológicos, danos à vida humana e problemas econômicos. A Figura 1 ilustra um acidente ocorrido por dano estrutural devido à propagação de uma descontinuidade.



Figura 1 – Resultado de teste hidrostático sem acompanhamento de ferramenta de avaliação de integridade estrutural [2].

A necessidade de uma investigação de novas estruturas informativas presentes e disponíveis nos fenômenos de emissão acústica aplicados na engenharia para deles extrair o máximo de informação é fundamental para auxiliar na exploração dos recursos industriais e na avaliação dos possíveis riscos envolvidos em qualquer ação ou conclusão.

1.1 Objetivo do Trabalho

O presente trabalho tem como propósito apresentar uma metodologia baseada em princípios de outras ciências no cenário descrito anteriormente (sinais de emissão acústica em dutos rígidos pressurizados). O contexto consiste em estudar, através de uma visão analítica dos dados técnicos e operacionais de ensaios experimentais controlados, o comportamento deste sistema dinâmico de inúmeras variáveis. E por meio desse estudo analítico (quantitativo e qualitativo), ser possível analisar como algum dado coletado (características da forma da onda) como parte do processo (emissão acústica) pode ser utilizado para melhorar o conhecimento do processo de propagação de descontinuidade no futuro.

O conhecimento para o processo de tomada de decisão na área Inspeção de Equipamentos é retirado, portanto, a partir dos dados resultantes dos ensaios realizados. Neste ponto, consiste o principal momento, a transformação eficiente e eficaz da informação em conhecimento útil que possa resultar num melhor desempenho na operação/manutenção de dutos rígidos pressurizados. Isso é realizado por meio das técnicas de análise dos dados obtidos em campo, ou seja, “extração de conhecimento” a partir das informações contidas nas bases do fenômeno.

O processo de solução do problema – extração de conhecimento da emissão acústica em dutos rígidos pressurizados pela forma da onda – consiste em entender como a modelagem entra em todo o processo de resolução para tornar-se um elemento eficaz.

No fim, o objetivo será a abordagem pela modelagem do conhecimento da emissão acústica em dutos rígidos pressurizados com o intuito de proporcionar um aumento de disponibilidade e confiabilidade dos equipamentos e instalações (avaliação preditiva).

O objetivo do trabalho consiste por estes motivos em estudar as características das formas de onda de emissão acústica no intuito de aperfeiçoar a detecção de defeitos em dutos rígidos pressurizados pela classificação da trinca em estados de propagação. As classes de propagação da trinca (Sem Propagação – SP, Propagação Estável – PE ou Propagação Instável – PI) indicam a correlação entre a dinâmica dos sinais conforme a propagação da trinca e a pressão interna do duto pressurizado.

1.2 Motivação do Estudo

A motivação do estudo consiste em apresentar uma metodologia que compara sinais temporais na sequência de ocorrência dentro de um conjunto de observações, pois por meio desta comparação é possível realizar uma análise pela modificação dos parâmetros das portadoras que simulam a transição entre os sinais no decorrer do ensaio hidrostático.

A metodologia proposta é baseada numa estrutura de rede híbrida (rede neural especializada) na qual a sua topologia é estruturada no princípio de superposição das modulações analógicas em amplitude (linear) e em angulo (não linear). A arquitetura da rede permite avaliar as transições entre os sinais de emissão acústica registrados durante o ensaio hidrostático pela estimação dos parâmetros das portadoras pelos pesos sinápticos. Estes parâmetros indicam a dinâmica entre os sinais pela comparação da forma temporal da onda do sinal via modulação analógica. Por fim, os conjuntos de parâmetros foram utilizados como entrada em classificadores não lineares e não supervisionados com resultados em torno de 91,2% a 94,3% de acerto na classificação dos sinais em regiões de propagação: sem propagação, propagação estável e propagação instável.

A metodologia pode ser aplicada em qualquer conjunto de séries temporais. A estimação dos parâmetros das portadoras analógicas que por superposição modulam um sinal em outro do conjunto pela rede híbrida disponibiliza um novo conjunto de variáveis (parâmetros das portadoras). A partir deste conjunto os sinais são representados por sua decomposição na transição entre seus os elementos consecutivos do conjunto de observações.

O presente estudo compreendeu a análise de dados provenientes de ensaios hidrostáticos em corpo de prova com 2 metros de comprimento.

Para tal, foram realizadas as seguintes etapas:

- a) Simulação do comportamento de propagação da onda em ensaios experimentais de emissão acústica com defeitos inseridos artificialmente (trinca);
- b) Pré-processamentos dos sinais (normalização, aplicação de filtros e outros);
- c) Modelagem da rede neural híbrida a partir do desenho da topologia com base no princípio de modulação analógica;
- d) Formulação dos novos parâmetros extraídos da forma de onda pela rede neural híbrida;
- e) Classificação não supervisionada via redes neurais dos parâmetros determinados pela rede neural híbrida.

As técnicas de redes neurais são utilizadas por apresentarem um conjunto de características importantes para a modelagem, como por exemplo, a capacidade de aprender e de se adaptar a mudanças por treinamento supervisionado e de extrair características estatísticas por treinamento não supervisionado.

1.3 Contribuições do Trabalho

No campo experimental, a contribuição foi por meio da participação dos ensaios hidrostáticos em dutos pressurizados de 2 metros de comprimentos e de 40 metros de comprimentos do projeto de pesquisa entre UFRJ, CENPES e UFRGS. Durante a preparação e a execução destes ensaios hidrostáticos foi possível a identificação de melhorias e ajustes junto às equipes da COPPE e do LAMEF⁵ nos procedimentos de

⁵ O autor acompanhou a preparação e a execução dos ensaios hidrostáticos junto à equipe do LAMEF pelo projeto de pesquisa entre COPPE-UFRJ, CENPES-PETROBRAS e LAMEF-UFRGS como a avaliação dos dados oriundos dos ensaios. Projeto de pesquisa detalhado no capítulo 4.

captação dos sinais de emissão acústica para melhor avaliação do fenômeno entre os ensaios realizados como também na qualidade nos dados registrados.

No campo teórico, pela disponibilização de novas características (parâmetros) do fenômeno de Emissão Acústica a partir do estudo e análise da forma de onda dos sinais captados durante os ensaios hidrostáticos. Estes novos parâmetros apresentam a decomposição dos sinais via rede neural e a classificação posterior destes avalia as modificações ocorridas entre os sinais no decorrer do tempo de ensaio. Portanto, para os sinais de um conjunto de observações, permite a avaliação da evolução das mudanças sequencias ocorridas entres os sinais no decorrer do tempo.

Na área acadêmica, o estudo contribui com a metodologia para a análise da transição entre sinais pela forma de onda a partir das modulações analógicas (amplitude e ângulo) presentes por meio de redes neurais. Esta análise pode ser realizada tanto utilizando o sinal antecessor para avaliar a mudança em relação ao sinal posterior dentro de um conjunto de observações ou utilizar um sinal base (determinístico) para fins de comparação da variação dos sinais do conjunto em relação a este sinal de referência.

2 REVISÃO DA LITERATURA

A ciência dos materiais sempre esteve presente nas atividades humanas relacionadas à confecção e manipulação de elementos químicos básicos. Esta ciência teve suas primeiras aparições na idade média, por exemplo, no fenômeno conhecido como “choro do estanho”, técnica de beneficiamento (sonoro) do material estanho em espada utilizada pelo ferreiro para analisar a atividade de confecção da espada durante as marteladas próximo ao forno. Essa técnica estudada por Joseph Kaiser em 1950 caracterizou o fenômeno como um ensaio não destrutivo aplicado na avaliação da integridade de materiais industriais [4].

Entretanto este método possuía grande margem de erro, o que era inevitável pelo tipo de ciência aplicada no diagnóstico. Nos atuais dias, esse dilema acompanha os cientistas, na ocorrência de erros em classificações que resultem em interpretação divergente e incorreta (falsos positivos e falsos negativos). A ocorrência de erros de interpretação dos defeitos existentes seja na não detecção de um defeito presente ou pela classificação incorreta do defeito detectado provocado pela similaridade de características entre tipos de defeito ou mesmo no desconhecimento de características, estimula a pesquisa no tema.

Na expectativa de conhecimento científico nas áreas da engenharia são realizados estudos que envolvem: a extração de características de classes por classificadores lineares e não lineares; análise de critérios de relevância de características; dentre outras. Por isso, a utilização de técnicas do campo da Inteligência Computacional em temas da Engenharia Metalúrgica e de Materiais expõe novos conhecimentos como apresentados por outros trabalhos realizados recentemente [4 – 11].

2.1 O Fenômeno de Emissão Acústica

A técnica de Emissão Acústica (EA) é um método qualitativo de inspeção da área de Ensaio Não Destrutivo (END) baseada na detecção de fontes de sinais acústicos (ondas elásticas) emitidos durante a propagação de descontinuidades e deformações

plásticas acentuadas. A emissão destas ondas tem como condição a existência de descontinuidade ativa durante o carregamento estrutural, uma vez que a emissão acústica está relacionada com a liberação de energia ocorrida durante o rearranjo do campo de tensões na ponta das descontinuidades [4].

Na emissão acústica, as ondas sonoras são produzidas quando o material é submetido a uma mudança de tensão interna resultante de uma força externa decorrente da variação de carga mecânica das fontes geradoras de ondas elásticas. Uma vez que esta ocorrência é decorrente do deslocamento da superfície do material, produz as ondas de tensão – energia no material (energia elástica) ou sobre a sua superfície quando liberada instantaneamente [1,4,6].

Sendo assim, as ondas elásticas transitórias dentro de um material liberam a energia da tensão localizada. Desta forma, uma fonte de evento é o fenômeno que liberta energia elástica para dentro do material, que depois se propaga como uma onda elástica. Quanto maior a força ou a deformação, maior a energia armazenada no material. Logo, se o limite elástico do material é excedido, o material pode ser deformar plasticamente ou pode trincar, liberando essa energia na forma de onda sonora que percorrerá o material. As emissões acústicas podem ser detectados em faixas de frequência abaixo de 1 kHz, porém existem relatos de frequências de sinais gerados até 100 MHz [1,4].

Observa-se, entretanto, que a emissão acústica pode ser relacionada a uma libertação irreversível de energia, mas também podem ser geradas a partir de fontes que não envolvam falha do material.

O órgão normativo brasileiro, Associação Brasileira de Normas Técnicas (ABNT), define a emissão acústica como o fenômeno onde ondas elásticas transientes são geradas por rápida liberação de energia mecânica a partir de fontes localizadas em um material ensaiado. Portanto, os sinais detectados de emissão acústica são gerados pelo objeto em teste, normalmente mediante a aplicação de um estímulo, detectando-se as descontinuidades durante o processo de degradação da integridade da estrutura, pois instabilidades locais são desenvolvidas nas estruturas antes do colapso. As tensões desenvolvidas nas regiões que contém descontinuidades podem assumir valores superiores às tensões limites de escoamento em função dos concentradores de tensão. Nesta situação, a propagação das descontinuidades atua como uma fonte de sinais de emissão acústica. Ou seja, o ensaio de emissão acústica é um método passivo que

monitora dinamicamente a redistribuição dos campos de tensão em componentes submetidos a esforços [4].

2.2 Aplicações da técnica de Emissão Acústica

Desde o final dos anos 1950, muitos testes bem sucedidos de emissão acústica foram concluídos. No entanto, para conseguir um uso mais amplo é necessário organizar e reexaminar a metodologia aplicada neste tempo ao monitoramento da integridade estrutural em quatro etapas [12]:

- i. Fontes de emissão: fontes primárias de fratura e fissuras em contraste com fontes secundárias de atrito, oxidação, etc.
- ii. Ferramentas de avaliação: avaliação do Efeito Kaiser permite a detecção de nível de carga prévia e de estados de dano.
- iii. Localização de fonte: esta abordagem identifica a área de perda de integridade.
- iv. Caracterização de fonte: parâmetros combinados fornecem boa perspectiva para os tipos de falha, incluindo a amplitude do sinal, a frequência do sinal, a forma de onda e sua propagação.

O objetivo final determina se a integridade estrutural é atingível apenas com abordagem sistemática com danos quantificados via técnicas não destrutivas e com o uso da mecânica da fratura.

A emissão acústica pode ser aplicada em inúmeros contextos – nos processos corrosivos em equipamentos da indústria de petróleo, na detecção de discontinuidades em equipamentos submetidos a carregamentos com pressão interna e na avaliação da integridade estrutural.

Por exemplo, na relação entre a perda de massa obtida e a quantidade de sinais de emissão acústica em ensaios de corrosão acelerada (ensaios de laboratório em meios corrosivos para simular a operação de um equipamento). Uma vez que a formação e liberação de moléculas de hidrogênio em materiais metálicos apresentou uma relação proporcional com a quantidade de sinais de emissão acústica demonstrou o efeito galvânico como uma fonte de sinais de emissão acústica [4].

Outra aplicação é o monitoramento da corrosão do trincamento por corrosão-sob-tensão e da corrosão-fadiga como fontes de emissão acústicas presentes em processos de degradação do material. A inspeção de tanques de armazenamento de óleos e derivados visando à detecção de regiões nas quais ocorre processo corrosivo é realizada por meio da captação dos sinais em interrupções programadas da operação do tanque (carga e descarga). Desta forma os tanques foram classificados numa escala quanto à necessidade (priorização) de manutenção [4].

Durante a avaliação de processos corrosivos em dutos enterrados, os corpos de provas com o produto de corrosão apresentaram sinais de emissão acústica com maior amplitude. A maior quantidade de sinais detectada ocorreu com sensores com centro de frequência em 30 kHz e 60 kHz quando comparados aos captados por sensores com centro de frequência em 150 kHz. Neste caso, apresentou-se como banda de frequência para o processo corrosivo a faixa de 20 kHz a 80 kHz [4].

Em monitoramento da integridade estrutural com a técnica de emissão acústica foi possível visualizar que a distribuição da energia dos sinais em tempo-frequência e sua dispersão permitiu que os sinais emitidos na falha fossem separados dos ruídos, uma vez que os sinais captados foram analisados de acordo com o seu comportamento dispersivo [13].

Existe a identificação das características principais dos sinais de emissão acústica oriundos de fenômenos de corrosão quando comparados aos sinais de outras fontes de emissão acústica. Pois, através de furos usinados que simulavam o vazamento, pode-se visualizar a diferença na quantidade de sinais, no valor de amplitude do sinal e no valor de energia do sinal para cada furo inserido no tanque no momento do vazamento. Desta forma, diferenciando os sinais de emissão acústica oriundos de processos corrosivos dos sinais provenientes de vazamentos e em função do nível do fluido e da amplitude dos sinais de emissão acústica estimou-se o diâmetro do furo usinado [4].

Outro exemplo é a verificação da proporcionalidade das amplitudes dos sinais de emissão acústica oriundos de vazamentos de gás com a pressão aplicada no interior dos recipientes e comparação as dimensões dos furos. Como também a detecção de possíveis danos em estruturas (cilindros de armazenamento de gás) por meio do acompanhamento de contagens durante o ensaio, pois incrementos rápidos de atividade de emissão acústica são indícios de possíveis falhas [4].

Outra aplicação da técnica foi realizada em conjunto com a técnica de líquidos penetrantes para a localização e o dimensionamento das descontinuidades detectadas por emissão acústica em inspeção de sistemas de tubulação em fábrica de fertilizantes. Notou-se que a maior causa de falhas ocorreu pelo fenômeno de corrosão-sob-tensão. Entretanto, houve um grande número de falsos-positivos e falsos-negativos das regiões estimadas pela emissão acústica para a posterior aplicação da técnica dos líquidos penetrantes [4].

O estudo da natureza aleatória da emissão acústica, normalmente observado durante a deformação plástica dos materiais metálicos, foi usado como fonte de emissão. A distribuição de amplitude dos sinais encontrada era Gaussiana e alguns desvios menores foram observados quando as emissões de ruptura estavam sobrepostas. Técnicas de análise de séries temporais foram aplicadas para obtenção de parâmetros e provou serem estocásticos. No entanto, quando uma fonte de excitação de laser foi aplicada sobre amostras de tração de geometrias comuns, sinais de emissão acústica resultantes exibiram distribuição de Gauss [14].

A emissão acústica também é aplicada na manutenção da integridade estrutural em plataformas *off-shore*, após a entrada em serviço dos equipamentos, pois apresentam com o tempo o fenômeno de degradação, descontinuidades nucleadas e propagadas [4].

Outra aplicação é na avaliação de cilindros de distribuição de gases industriais em caminhões para o serviço constituído por três etapas: a carga, o transporte e a descarga de gases. Por meio de estimação da quantidade de eventos e das amplitudes registradas, a caracterização de possíveis descontinuidades seria detectada a partir das regiões sinalizadas pela técnica de emissão acústica conjuntamente com a inspeção com método ultrassônico para verificação da descontinuidade [4].

Como também na determinação da tenacidade à fratura e na monitoração do processo de fratura no aço 9Cr-1Mo pelo início de propagação de trincas. Por exemplo, na proposta de relação entre os parâmetros amplitude e energia da emissão acústica com a resistência à fadiga para aço de construções de pontes metálicas. Pois, observou-se que a amplitude não apresentou proporcionalidade com o fator de intensidade de tensão, mas o parâmetro energia apresentou uma correlação com o incremento dos ciclos de

fadiga⁶. A estimativa do fator de intensidade de tensão possuiu maior contribuição no parâmetro energia quando feita uma análise estatística por meio de componentes principais [4].

Aplicações com emissão acústica que utilizam parâmetros como amplitude, energia, contagem e outros relacionados à pressão do ensaio – uma análise paramétrica da emissão acústica – também apresenta resultados com a utilização da Inteligência Computacional [4 – 11,15 – 18].

Outras aplicações envolvendo técnicas de estatísticas, de reconhecimento de padrões e de redes neurais em emissão acústica pesquisadas possuem a contribuição da Inteligência Computacional no assunto.

Por exemplo, na normalização de formas de onda, na utilização de métodos de agrupamento (*clustering*) e na análise de componentes principais (PCA – *Principal Component Analysis*) para identificar mecanismos de danos [1].

Como também pela utilização de transformada de *wavelets* para decompor os sinais de emissão acústica em faixas de frequências com o objetivo de monitorar a evolução do dano e na aplicação de fractais com o intuito de prever a nucleação e a propagação de trincas de fadiga em aços [1].

As características de crescimento de trincas por fadiga em conexões de aço e solda estruturais foram analisadas utilizando a técnica de emissão acústica. A investigação experimental ocorreu por testes de flexão sob baixos ciclos de carregamentos de amplitude usando a análise de *wavelet*. A propagação de trincas e fraturas foi extraída das bandas de frequência correspondentes [19].

Um método de detecção de desgaste de ferramenta com condições de corte incluiu o modelo de rede neural difusa *wavelet*, com emissão acústica e um modelo de classificação *fuzzy* com corrente do motor. Os resultados da ferramenta de desgaste por condições de corte estimado detectou sinais fundidos por inferência *fuzzy* [20].

A técnica de emissão acústica pode sinalizar a rachadura de eixo devido à vibração. Esta é uma das principais avarias que ocorrem frequentemente em máquinas rotativas. A transformada *wavelet* foi aplicada aos sinais para decompor em uma série de sinais no

⁶ Falha catastrófica em estrutura submetida a esforços cíclicos.

domínio de tempo. Cada uma das quais cobre uma faixa específica de frequência oitava. Em seguida, um método foi aplicado para detectar a localização da fenda eixo. O método dos elementos finitos foi usado para construir o modelo da rachada do rotor e a profundidade da fenda foi identificada através da comparação da resposta de experiência e simulação de vibração. Os resultados mostraram que o sinal de emissão acústica foi eficaz na localização da fenda e o sinal de vibração determinou a profundidade de rachadura no eixo [21].

Na análise de sinais de emissão acústica por redes neurais para identificar e discriminar mecanismos de dano e na classificação não linear baseada em redes neurais para diferenciar estados de propagação e não propagação em vasos de pressão [1].

Também pelo estudo de sinais parametrizados utilizando métodos de agrupamento do tipo K-vizinho mais próximo (*K-nearest neighbour*) e K-médio (*K-means clustering*) para identificar mecanismos de falha [1].

A análise de sinais de emissão acústica por redes neurais tem apresentado inúmeras aplicações como no processamento de características que identifiquem a detecção da peça indesejável pelas mudanças em propriedades metalúrgicas do material produzido [22].

A rede neural SOM foi utilizada para identificar as formas de onda de sinal de emissão acústica de aeronaves em ensaio de fadiga. O que produziu um grupo de sinais suspeitos e três picos relativamente grande de energia aparecem simultaneamente em espectros de frequência [23].

Sinais de emissão acústica foram adquiridos a partir de três tipos de máquinas sob o funcionamento normal e com várias condições de falha. A análise dos sinais no domínio do tempo permitiu a identificação de temporização da máquina que puderam então ser utilizadas para isolar automaticamente as partes do sinal associada a eventos mecânicos específicos. Análise estatística e técnicas de padrão de reconhecimento foram utilizadas em uma janela de tempo selecionada do sinal para identificar condições de falha da máquina [24].

Os princípios básicos de reconhecimento supervisionado e não supervisionado para classificação de dados de emissão acústica de dados foram apresentadas em conjunto com aplicações bem sucedidas na condição-avaliação de vasos de pressão [25].

Uma sequência de processamento de sinal e técnicas de agrupamento hierárquico foi utilizada para processar sinais com baixa relação de sinal-ruído (SNR) medido por vários sensores. As características de formas de onda são utilizadas para o agrupamento e a localização da fratura. Com agrupamento hierárquico foi possível localizar a posição do plano de fenda com alta precisão utilizando sinais de baixa qualidade, em que a distribuição espacial dos aglomerados é um indicativo de propagação [26].

A técnica de emissão acústica é bem adequada para o controle em tempo real e da detecção ativa de defeitos dentro de uma estrutura. Por análise multivariada, foram identificados três estágios de mecanismos de dano: ativação, propagação e ruptura. Uma análise por mapa de auto-organização neural artificial (SOM) foi usada para identificar a relação entre as variáveis e classificar eventos. Esta metodologia provou ser particularmente eficiente na identificação da evolução e da extensão dos danos do monitorada pós tensionamento da viga de concreto. A análise SOM tornou possível correlacionar cada fase de emissão acústica com variáveis da fase de degradação [27].

A localização de fontes sob alto ruído de fundo foi projetada via algoritmo baseado em princípios probabilísticos. Neste caso, os eventos de emissão acústica foram classificados de acordo com sua energia e probabilidade de localização [28].

Durante o processamento de dados de emissão acústica, muitas vezes é necessário à determinação dos pontos de mudança de parâmetros. O tempo de chegada do primeiro sinal de emissão acústica (AE) é um parâmetro muito importante, o qual é utilizado para a identificação do local do evento baseados em um cálculo de vários parâmetros estatísticos dentro de uma janela de tempo. Este comprimento de janela de tempo é muitas vezes escolhida empiricamente pelo operador. Um método baseado na interseção de intervalo de confiança permite seleccionar parâmetros de tempo. Aplicação do princípio aumenta a precisão e a confiabilidade de estimativa de tempo de primeira chegada [29].

Um objetivo para a engenharia é vincular parâmetros específicos aos mecanismos de fratura que são sucessivamente dominam o fracasso do material. Resultados preliminares mostram que os parâmetros de forma de onda de emissão acústica como frequência e energia mudaram durante o carregamento, após a mudança de mecanismos de fratura. Além disso, o comportamento da emissão acústica nas amostras com a

curvatura diferente foi muito indicativo do modo de estresse confirmando os resultados [30].

Técnicas baseadas em emissão acústica são utilizadas na inspeção não destrutiva de sistemas mecânicos. Para o monitoramento automático de falhas de confiança relacionadas com a geração e propagação de fissuras é importante identificar os sinais relacionados com transitórios na presença de ruído forte variável no tempo e outras interferências. Uma dificuldade importante é a incapacidade para diferenciar eventos devido ao crescimento de ruído de várias origens. O ruído é separado dos eventos de interesse e subsequentemente removido utilizando uma combinação de análise de covariância, análise do componente principal (PCA). Em seguida processa os dados restantes usando uma rede neural mapa de auto-organização (SOM) que identifica os sinais de ruído e os de emissão acústica em neurônios separados. Para melhorar a eficiência de classificação, a transformada de Fourier de curta duração foi aplicada para manter as características dos eventos restantes tempo-frequência, a redução da dimensão dos dados [31].

A técnica de Emissão Acústica ganha cada vez mais interesse na área de engenharia como uma metodologia de monitoramento e como uma ferramenta de avaliação para a segurança e confiabilidade avaliação de estruturas. Existem métodos estatísticos que podem ser usados na análise de dados para avaliar danos e estado de uma estrutura sujeita a uma situação de carga particular. Redes neurais artificiais foram recentemente aplicadas como ferramenta para reduzir a redundância de dados e otimizar conjunto de recursos de sinais EA's. A análise de agrupamento foi geralmente usada para separar um conjunto de parâmetros para várias classes que refletem a estrutura interna do conjunto de dados. Por exemplo, tal procedimento analítico foi aplicado na avaliação de dados de emissões acústicas obtidos durante os testes de flexão em vigas de concreto com condição de carga constante e crescente. Dois tipos de métodos de agrupamento sem supervisão foram utilizados: a análise de componentes principais (PCA) e o mapa auto-organizado (Mapa Kohonen). Pela combinação de ambos os métodos, foi possível quantificar a severidade dos danos e identificar a evolução do próprio dano durante o ensaio [32].

Algoritmo de reconhecimento de padrões é também aplicado para diferenciar os sinais de corrosão a partir de sinais de interferência. Características típicas baseadas em

freqüência são extraídas e selecionadas por mínimo de redundância máxima relevância para o reconhecimento de padrões. Para validar a eficácia deste algoritmo, o resultado do reconhecimento de modelo foi comparado com *Back Propagation*, *Support Vector Machine* e Modelo Oculto de Markov [33].

Um método de implementação de redes neurais artificiais e sensores de emissão acústica para rotinas de inspeção aeroespacial obteve 95% de confiança. Elementos estruturais simples, consistindo de placas planas de alumínio, foram submetidos a aumento da carga de tração estática. À medida que a carga aumentou, liberando ondas de tensão no processo, sinais de onda de tensão, medidos por sensores de emissão acústica, foram analisados no pós-processamento por redes neurais artificiais. As redes foram treinadas em uma porção dos dados adquiridos pelos sensores e foram então validadas com os dados restantes. A combinação de um sistema de sensores de emissão acústica e uma rede neural permitiu determinar a extensão de trinca com precisão [34].

Uma abordagem bayesiana para localizar fonte acústica de emissão em estruturas do tipo placa com a consideração das incertezas de erro de modelagem e ruído de medição. O procedimento de identificação de parâmetros Bayesian foi desenvolvido para obter o local de origem da emissão acústica e a velocidade da onda em uma freqüência específica, simultaneamente, e quantificar as suas incertezas. Este procedimento baseia-se no teorema de Bayes para as distribuições dos parâmetros sobre a localização de origem das emissões e a velocidade de onda foram obtidas por relativas seus antecedentes e a probabilidade dos dados de diferença de tempo medido. O algoritmo de Monte Carlo da cadeia de Markov foi empregado para colher amostras para aproximar os posteriores. Além disso, um sistema de fusão de dados é realizado para fundir resultados identificados em múltiplas freqüências para aumentar a precisão e reduzir a incerteza dos resultados finais de localização [35].

Pelos exemplos supracitados, nota-se que os principais interesses práticos da técnica de emissão acústica para as áreas de engenharia seriam:

- a) O local de origem: determinar os locais onde uma fonte do evento (trinca) ocorreu.
- b) O desempenho mecânico do material: avaliar e caracterizar materiais e estruturas.

Estes interesses são objetos de estudo de aplicações com métodos de inteligência artificial como citado anteriormente [20,22-23,27-29,31-32,34-36].

Por isso, o entendimento deste fenômeno com a busca de padrões é motivado pelo retorno de conhecimento prático aplicável na engenharia. Uma vez que um padrão é uma descrição quantitativa ou estrutural de um objeto, ou de outra entidade de interesse que em geral é composto por um ou mais descritores, frequentemente conhecidos como características. Tendo em vista o descrito anteriormente, uma classe de padrões poderá ser considerada como uma família de padrões que compartilham propriedades comuns [5].

A inspeção de pequenos trechos do duto, em torno de 1 km, para a identificação de descontinuidades oriundas da operação do duto pode ser efetuada pela técnica de emissão acústica em função do comprimento máximo de cabo de sinal de emissão acústica estar situada na faixa de 500 metros para sensores com frequência de 30 kHz, uma vez que as descontinuidades tornam-se ativas acusticamente pelo incremento da pressão interna de operação do duto [4].

A Figura 2 ilustra uma consequência de uma trinca que comprometeu a integridade do duto enterrado provocando a falha estrutural e paralização da operação.



Figura 2 – Visualização dos danos causados por falhas catastróficas em gasodutos [37].

2.3 Agentes influentes no processo de Emissão Acústica

Na ocorrência do processo de emissão acústica no material, uma parcela da energia é liberada sob a forma de ondas de tensão elástica (longitudinal⁷ ou transversal⁸) que atinge a superfície do material propiciando conversão de modo e conseqüente geração de outras formas de propagação, ondas superficiais, que podem tornar-se sinais espúrios durante a captação dos sinais durante o ensaio de emissão acústica [4].

A presença de sinais espúrios provenientes de outras fontes como conexões, junções, etc. deve ser avaliada durante o ensaio de emissão acústica, pois são agentes influentes na interpretação dos sinais provenientes de um defeito.

Em estudo realizado por Cole e Gautrey (2004 apud SOARES, 2008), no qual aspectos relacionados com a aplicação do ensaio de emissão acústica durante o teste hidrostático de vasos de pressão na condição de após fabricação, antes da entrada em serviço, apresentou o supracitado. A propagação de uma descontinuidade ou um sinal espúrio poderia significar mais de um sinal coletado pela instrumentação de emissão acústica. No trabalho em questão, diversas análises foram realizadas durante este teste permitindo a identificação de descontinuidades que poderiam ser críticas para o vaso de pressão na condição operacional. Entretanto, sinais de emissão acústica foram detectados sem a presença de descontinuidades em um dos testes apresentados, porém uma posterior análise detalhada deste equipamento detectou a realização de soldas com diferentes aportes térmicos que resultaram em diferentes níveis de tensões residuais. Os diversos níveis de tensão residual acarretaram sinais de emissão acústica durante o teste hidrostático. A solução empregada consistiu na realização de outro ciclo de carregamento para detectar a nucleação de descontinuidades nas áreas de maior tensão residual. Em função da inexistência de ocorrência de novos sinais de emissão acústica, o vaso de pressão em teste teve sua análise concluída com caracterização de falsos positivos.

Os ensaios de emissão acústica realizados durante os testes hidrostáticos dos equipamentos são influenciados por fatores ambientais – incidência de chuva ou

⁷ Onda Longitudinal: o deslocamento das partículas possui a mesma direção de propagação da onda (energia).

⁸ Onda Transversal: o deslocamento das partículas possui direção perpendicular a da propagação da onda (energia).

partículas carregadas por vento – e por perdas de estanqueidade originadas de vazamentos. Estes fatores afetam o ensaio pela geração de sinais espúrios que podem contaminar os dados genuínos de emissão acústica, caso não sejam devidamente identificados e filtrados antes da análise dos dados do teste [4].

A existência de sinais espúrios se torna um inconveniente no estudo de emissão acústica, pois se caracterizam como um ruído com a possibilidade de possuírem as mesmas grandezas dos sinais de interesse. Este fato pode levar a erros de interpretações como apresentado anteriormente.

Os sinais detectados em um sensor poderiam se propagar nos corpos de prova confeccionados e em função disto representar a mesma fonte de emissão acústica, seja a propagação de uma descontinuidade ou um sinal espúrio, poderiam significar mais de um sinal coletado pela instrumentação de emissão acústica. Para minimizar o problema da reflexão de sinais em função de sua contínua propagação, pode-se utilizar uma técnica de filtragem de sinais conhecida como “primeiro sinal”. A metodologia do primeiro sinal consiste em um filtro baseado em tempo para a redução de dados de modo a não permitir que reflexões do mesmo sinal de emissão acústica detectado em mais de um sensor sejam utilizadas na análise. Este filtro utiliza o valor da velocidade de propagação do sinal de emissão acústica e a maior distância (geralmente a diagonal do corpo de prova planejado) do corpo em teste. Sinais que sejam detectados em outros sensores dentro do tempo necessário de propagação na maior distância do corpo de prova e que permitam a localização precisa de sua origem são filtrados [4,38].

2.4 A Fonte de Emissão Acústica

Observa-se que até o presente, a meta de aquisição de conhecimentos por meio da emissão acústica é predominantemente quanto às características medidas como, por exemplo, amplitude, energia, contagem da forma de onda captada pelos sensores, e outros. Entretanto, a viabilidade de identificar a fonte e sua localização também se tornam importantes para as áreas de Engenharia de Equipamentos e de Inspeção.

Dentre os mecanismos de fontes de emissão acústica, destacam-se [1]:

- a) Fontes em Materiais Cristalinos: o regime de deformação plástica é a região mais propícia para a ocorrência de fontes de emissão acústica, uma vez que esta deformação plástica ocorre em um único cristal orientado em um plano de escorregamento. Sendo assim, facilita a propagação das ondas elásticas transientes, gerando dessa forma sinais de emissão acústica.
- b) Fontes em Compósitos: grandes quantidades de sinais de emissão acústica e aumento na atividade (taxa de emissão acústica) antes da falha; altos níveis de tensão, ou seja, emissão contínua durante patamar de carga.

A localização da fonte pode ser determinada por três métodos [1,4]:

- a) Localização linear: Pela diferença temporal entre as medições de dois sensores estima-se a posição sobre o segmento de reta que os une.
- b) Localização superficial: Pela diferença temporal entre as medições de três sensores estima-se a posição sobre o plano pela intersecção das hipérboles traçadas a partir da posição dos sensores.
- c) Localização zonal: Pela sequência de recepção de três sensores é visualizado a região candidata a partir da divisão em zonas realizada na estrutura.

A norma *JIZ Z 2342-2002*⁹ do Instituto Japonês de Normalização propõe procedimentos para estimação da localização da fonte de emissão acústica [4]:

- a) A localização zonal, que consiste em identificar as regiões que contenham a maior atividade, ou seja, o maior número de sinais ou valores acumulados dos parâmetros de emissão acústica por canal.
- b) A localização com a técnica de agrupamentos de sinais, que consiste em verificar se um ou mais sinais são provenientes da mesma fonte de emissão acústica.

⁹ Mori, Y., Shiwa, M., Nakano, M. E Iwai, K., *New concept of AE standard: JIS Z 2342-2002 "Methodos for acoustic emission testing of pressure vessels during pressure tests and classification of test results"*, Journal of Acoustic Emission, vol. 21, pp 197-205, Estados Unidos da América, 2003.

Pela referida norma, o tipo do agrupamento de sinais foi definido pelo somatório de energia dos sinais de emissão acústica pela pressão aplicada conforme ilustrado pela Figura 3. A figura apresenta o agrupamento do tipo I (entre P_0 e $P_0+P_i/5$) que corresponde aos sinais de emissão acústica esparsamente detectadas em vários níveis de pressurização sem grande intensidade. O agrupamento tipo II (entre $P_0+P_i/5$ e $P_0+2.P_i/5$) foi identificado por sinais de intensidade baixa/moderada e ocorrem em baixas ou médias pressões. Quando são detectados sinais de emissão acústica com incremento exponencial de atividade em pressões elevadas caracteriza-se o agrupamento tipo III (entre $P_0+2.P_i/5$ e $P_0+3.P_i/5$), enquanto o agrupamento tipo IV (entre $P_0+3.P_i/5$ e $P_0+4.P_i/5$) foi caracterizado quando os sinais de emissão acústica ocorreram durante todo o ciclo de pressurização. Ou seja, a classificação é de acordo com o número de sinais registrado pelas faixas no intervalo de pressão interna aplicada.




Figura 3 – Classificação do tipo de agrupamentos de sinais EA por quantidade versus faixa de pressão interna segundo a norma JIS Z 2342-2002 [4].

Portanto, conclui-se que o ensaio de emissão acústica difere dos outros métodos de ensaios não destrutivos em dois principais aspectos:

- a) O sinal detectado é gerado pelo próprio material ou estrutura, ou seja, a energia detectada é liberada de dentro do material em teste.
- b) O método de emissão acústica é capaz de avaliar o comportamento dinâmico do material ou estrutura para a tensão aplicada.

Os fenômenos associados à degradação da integridade estrutural – crescimento de trincas e deformações plásticas – são as maiores fontes de emissão acústica. No entanto, a técnica de emissão acústica possui, por exemplo, algumas limitações [1]:

- a) A detecção de uma descontinuidade presente na estrutura é dependente do tipo de excitação induzida durante o ensaio, o que exige a realização de estudos específicos, principalmente para as situações mais críticas de utilização.
- b) A grande quantidade de informações geradas durante o ensaio pode ocasionar uma dificuldade de análise.
- c) Não é ainda uma técnica desenvolvida para o dimensionamento de descontinuidades devendo, sempre que necessário, ser complementada pelas técnicas não destrutivas convencionais.

2.5 Processos inerentes ao Ensaio Hidrostático

Os ensaios experimentais que foram realizados neste trabalho consistiam na introdução de descontinuidades artificiais para simulação de defeitos em corpos de prova (segmentos de dutos). Durante os testes hidrostáticos, o estímulo da descontinuidade é devido à aplicação de pressão interna, sendo os sinais de emissão acústica coletados em diversos canais colocados ao longo do corpo-de-prova – próximos e distantes da localização do defeito. Ensaio de ultrassom¹⁰, tais como a técnica ToFD¹¹ (*Time of Flight Diffraction*) podem ser utilizados para monitorar o crescimento do defeito.

¹⁰ O ultrassom mede a resposta do material a uma excitação acústica artificial e repetitiva. Enquanto, a EA é uma técnica passiva e receptiva.

¹¹ A técnica permite identificar a dimensão da descontinuidade pela diferença de tempo na recepção das ondas difratadas pelas extremidades da descontinuidade.

2.6 Fundamentos para a Emissão Acústica

No ensaio de Emissão Acústica, os metais apresentam um comportamento característico de emitirem ondas de emissão acústica somente quando a descontinuidade sofre ação de estímulo (força) acima do máximo carregamento aplicado previamente. Esta característica conhecida como “Efeito Kaiser”¹², embora seja definido como um fenômeno irreversível apresenta reversibilidade para materiais que possuem capacidade de recozimento¹³ em temperatura ambiente.

A presença do efeito Kaiser em materiais metálicos permitiu o desenvolvimento de uma estratégia de inspeção de componentes estruturais e vasos de pressão para a detecção de danos registrada como “Corolário Dunegan”¹⁴. Essa estratégia consiste em fazer testes repetidos durante os serviços de manutenção do componente, pois no teste consecutivo, para componentes sem a presença de dano estrutural não seriam gerados sinais de emissão acústica. Essa característica ocorre pelo fato que a existência e a detecção de sinais de emissão acústica corresponderiam a danos oriundos da operação do componente [4].

O efeito Felicity é a ocorrência de emissão durante a estabilização da carga, em ambos os sinais estão associados a defeitos significativos, estruturais, naturais e instáveis [3].

A Figura 4 ilustra os efeitos supracitados, onde os trechos AB, BD e GH representam o efeito Kaiser, o ponto F representa o efeito Felicity e o Corolário de Dunegan pelos ciclos de execução de pressurização (trechos BC e DE).

¹² Quando um material é carregado até um nível de tensão e descarregado, nenhuma EA é observada no carregamento subsequente até a tensão prévia ter sido excedida [1].

¹³ Remoção de tensões devidas a tratamento mecânicos e eliminação do efeito de quaisquer tratamentos térmicos ou mecânicos a que tenha sido submetido anteriormente.

¹⁴ A emissão acústica experimentada durante testes de prova (ensaio) revela dano ocorrido durante o período operacional precedente. Caso uma estrutura não sofra dano durante um período particular, então nenhuma emissão será observada no teste de prova subsequente [1].

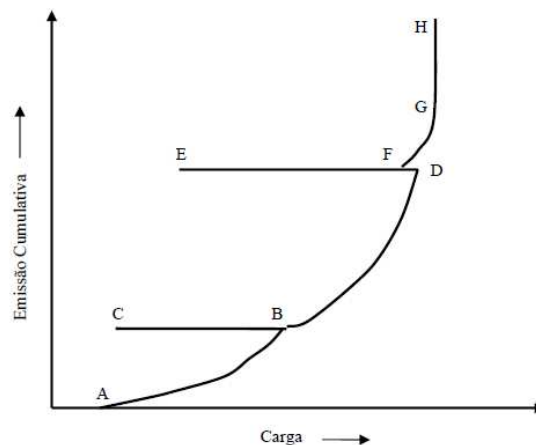


Figura 4 – Emissão Acústica com os fenômenos Efeito Kaiser, Efeito Felicity e Corolário de Dunegan durante ciclos de carga de pressão [3].

Em suma, os efeitos podem ser descritos como: Efeito Kaiser mostra a irreversibilidade de um resultado de emissão acústica; o Efeito Felicity é uma indicação de danos significativos e o Corolário de Dunegan são defeitos estruturalmente significativos que emitem sinais de emissão acústica em serviço subsequente entre o primeiro carregamento e carregamento repetido [3].

2.7 Características dos Sensores no Ensaio

Os sensores utilizados para a detecção de sinais de emissão acústica são do tipo piezoelétricos. O fenômeno da piezoelectricidade permite a geração de cargas elétricas como resultado da deformação mecânica e do efeito reverso. O efeito consiste na passagem da onda sonora na superfície do material com a geração de uma diferença de potencial no sensor piezoelétrico¹⁵ transferida para o sistema de aquisição.

A frequência de ressonância do sensor é identificada como na qual ocorre a maior resposta em amplitude e a banda em frequência é descrita pela faixa percentual da frequência de ressonância para uma resposta de até – 3 dB. Com isso, os sensores são identificados como banda estreita ou banda larga, para bandas de frequência de até 50% e acima de 50%, respectivamente. Os sensores mais utilizados no ensaio de emissão

¹⁵ O sensor piezoelétrico pode ser encontrado na forma de transdutores ressonantes ou de banda larga [1].

acústica em materiais metálicos são ressonantes em 150 kHz, com banda larga em frequência (100%), ou seja, apresentam uma extensa faixa útil de 75 kHz até 225 kHz.

Os pré-amplificadores de ganho típico na ordem de 40 dB diminuem a interferência de ruídos pelos cabos de transmissão (distância máxima de 40 centímetros entre pré-amplificador e sensor). Um pré-amplificador normalmente inclui filtros passa-alta ou passa-faixa por causa do ruído de baixa frequência. A faixa de passagem é de 100 kHz a 300 kHz, sendo a frequência de ressonância em 150 kHz. Desse modo, as frequências menores apresentam o ruído de fundo de origem mecânica e as frequências maiores a alta atenuação [1,4].

Os pré-amplificadores geram ruído eletrônico e este ajusta o limite do menor movimento detectável pelo equipamento de emissão acústica. O limiar é de $10\mu\text{V}$ na saída do receptor o que corresponde a um deslocamento na superfície de 25pm para sensores de alto desempenho [1].

Desta forma, os sensores são conectados a pré-amplificadores e estes a um conversor Analógico Digital (A/D) para a aquisição de dados. Um limiar de aquisição é estabelecido e, portanto, os sinais acima deste limiar serão armazenados e os abaixo considerados ruídos [1].

A utilização de acoplante no acoplamento entre o sensor e a amostra é necessária, pois existe uma fina camada de ar entre as superfícies dos elementos devido à rugosidade. Desta forma, provendo um melhor casamento de impedância acústica.

O sinal filtrado é enviado para um conversor A/D de 16 bits (digitalizado a taxa de até 10 MHz) e por seguinte para um circuito de extração de características do sinal (conversão do sinal em outros parâmetros) e então gravada a forma de onda em um módulo específico (cada módulo é um circuito independente do outro). O módulo paramétrico extrai os parâmetros da emissão acústica do sinal captado [1].

A taxa de aquisição, o *pre-trigger* e o comprimento do sinal são dados fornecidos pelo usuário. A taxa de aquisição informa que o aparelho realizará uma medição, no máximo a cada $1\mu\text{s}$ ou no mínimo a cada $10\mu\text{s}$. O *pre-trigger* representa o tempo (μs) no qual o equipamento registra dados antes do limiar ter sido cruzado (varia de zero até o valor correspondente a divisão do comprimento do sinal pela taxa de aquisição). O comprimento do sinal varia na faixa de 1ms a 15ms.

2.8 A Forma de Onda de Emissão Acústica

Existem dois tipos de sinal para emissão acústica [6]:

- 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 (Figura 5-a).
- 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 (Figura 5-b).




Figura 5 – (a) Emissão de fratura (b) Emissão Contínua [6].

A forma de onda da emissão acústica em estudo neste texto é a Emissão de Fratura.

As características predefinidas no sinal de emissão acústica de acordo com a norma NBR-15181 (Ensaio Não Destrutivos – Emissão Acústica – Terminologia) da Associação Brasileira de Normas Técnicas são:

- a) Amplitude máxima de emissão acústica: O valor máximo de voltagem obtido pelo sinal de emissão acústica.
- b) Contagem de emissão acústica: O número de vezes que o sinal de emissão acústica ultrapassa o limite de referência durante o ensaio.

- c) Limite de referência do sistema: O limite de referência do sistema eletrônico acima do qual os sinais serão detectados.
- d) Energia: A medida da área retificada do sinal de emissão acústica.
- e) Tempo de subida: Intervalo de tempo entre a da primeira contagem e o da amplitude máxima.
- f) Duração: Intervalo de tempo entre o primeiro e último cruzamento do limiar.

A Figura 6 ilustra as características da norma referida em conjunto com a visualização de uma típica onda de emissão acústica como apresentada na Figura 5(a).

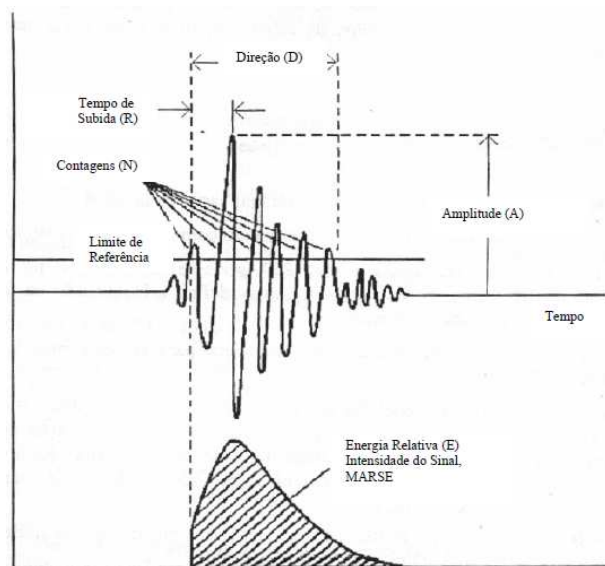


Figura 6 – Formato padrão da forma de onda para emissão acústica [3]¹⁶.

¹⁶ Este gráfico por assumir energia a partir da primeira contagem apresenta um equívoco no final da área ilustrada, pois por definição é a área entre a primeira contagem e a última contagem.

De acordo com a empresa *Physical Acoustics Corporation* (PAC¹⁷), o formato de onda da emissão acústica apresenta alguns elementos [1]:

- a) *Peak Definition Time (PDT)*: função temporal que permite a determinação do tempo do pico verdadeiro da forma de onda acústica. O PDT é ativado quando o primeiro sinal ultrapassa o limiar e inicia a contagem regressiva até zero, a menos que um valor maior de amplitude ocorra.
- b) *Hit Definition Time (HDT)*: função temporal que permite o sistema determinar o fim do sinal, finalizar o processo de medição e armazenar as informações do sinal. A contagem de HDT finaliza quando o último cruzamento do limiar acontece.
- c) *Hit Lockout Time (HLT)*: função que inibe a medição de reflexos e chegadas tardias de partes do sinal de emissão acústica. O circuito HLT é ativado pela finalização do HDT.

Estes valores podem assumir valores na faixa de 30 μ s até 130ms. Os valores padrões do equipamento são: PDT = 200 μ s, HDT = 800 μ s, HLT = 1.000 μ s. – o manual do fabricante sugere como padrão mínimo: HDT igual ao dobro de PDT e HLT igual a 300 μ s [1].

A Figura 7 apresenta as faixas temporais das características PDT, HDT e HLT durante a aquisição do sinal de emissão acústica. Para fins exemplificação da aplicação destas características, a Figura 6 representa um sinal de emissão acústica registrado até o término da faixa temporal HDT.

¹⁷ <http://www.pacndt.com/>

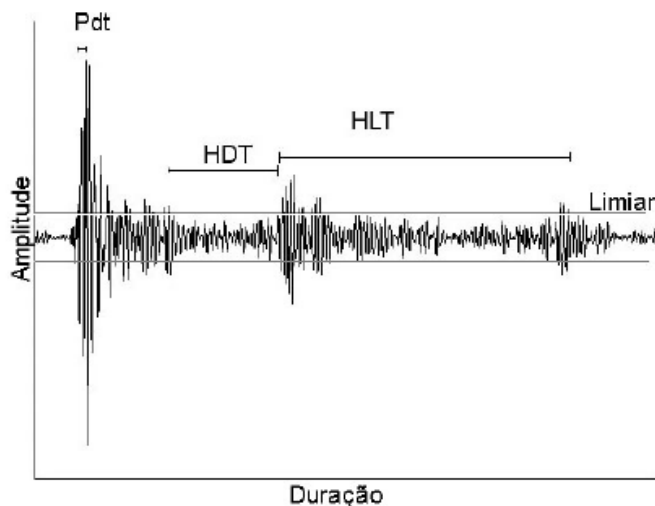


Figura 7 – Parâmetros temporais de aquisição da onda EA [1].

A contagem de um sinal de emissão acústica está relacionada com a frequência de oscilação da onda mecânica gerada durante o processo de emissão acústica e com a intensidade do sinal. Sinais com grande número de contagens estão relacionados com altas intensidades de emissão acústica em função de o sinal ter um extenso tempo de duração antes de sua completa atenuação. Profissionais da área de inspeção de equipamentos utilizam o valor de 10.000 contagens como limiar para a existência de fenômenos de propagação de discontinuidades [4].

A razão obtida entre a contagem e a duração do sinal de emissão acústica é identificada como frequência média do sinal de emissão acústica. A transformação do sinal do domínio do tempo para o domínio da frequência, expresso pelo parâmetro frequência média, é calculada pela divisão entre as contagens de emissão acústica e a duração do sinal.

2.9 Emissão Acústica e Inteligência Computacional

Os parâmetros comumente utilizados na análise de emissão acústica – contagem, amplitude, duração, tempo de subida e área medida abaixo da envoltória do sinal

retificado – possuem correlações intrínsecas identificadas por ferramentas da área de Inteligência Computacional, por exemplo, via redes neurais artificiais [6-11,17,39].

A Tabela 1 apresenta de forma sucinta descrições para cada parâmetro extraído nos ensaios de emissão acústica utilizados em estudos de identificação das classes de propagação com o equipamento de emissão acústica da PAC (*Physical Acoustics Corporation*). Os parâmetros são disponibilizados pelo equipamento em arquivo com base nas formas de onda captadas pelo mesmo.

Tabela 1 – Parâmetros de emissão acústica extraídos de ensaios [39].

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

As Figuras 8, 9 e 10 apresentam a relevância destes parâmetros para a classificação dos sinais de emissão acústica em classes de propagação (SP – Sem Propagação; PE – Propagação Estável; PI – Propagação Instável). Nesse estudo, o parâmetro freqPP3 demonstrou uma alta relevância para critério de separação entre as classes PE e PI [39].

A Figura 8 apresenta o índice de relevância de cada parâmetro para cada uma das classes. O gráfico mostra que o AMP e ASL influenciam apenas na classificação de SP e PI, enquanto que o I-Freq e o C-Freq, são fundamentais para a discriminação de PE, assim como Freq-PP3. O parâmetro I-Freq contribuiu para a identificação de SP e PE, enquanto que FreqPP1 e Freq PP2 para as três classes. Os demais parâmetros contribuem pouco para a discriminação entre as classes.




Figura 8 – Gráfico da relevância dos parâmetros em cada classe [39].

A Figura 9 apresenta o histograma dos índices de relevância, no eixo vertical esquerdo estão parâmetros analisados, no eixo horizontal está o valor do índice de relevância e no eixo vertical direito a altura da coluna do histograma. O histograma é referente às relevâncias para as três classes juntas. Observa-se que o parâmetro de maior relevância é o Freq-PP3, seguido do Freq-PP1 e do I-Freq. O AMP, o ASL e o Freq-PP2 apresentam relevância um pouco abaixo. Os demais parâmetros apresentaram valores baixos indicando pouca ou nenhuma influência na classificação.




Figura 9 – Histograma/Relevância dos parâmetros para as classes juntas [39].

Para confirmar a influência de cada parâmetro na discriminação das classes, criaram-se cinco conjuntos com os pares de entrada e saída, conforme descrito na Figura 10, quanto mais no interior, maior a relevância do parâmetro. Separação de conjuntos pela relevância. À direita o percentual de acerto na classificação de cada conjunto.

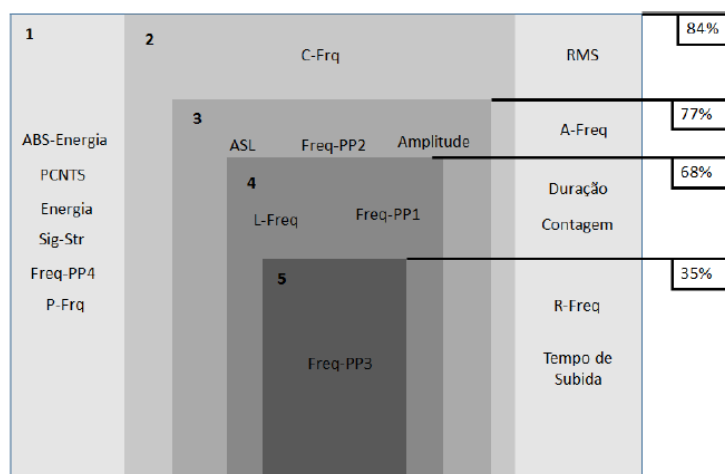


Figura 10 – Separação de conjuntos pela relevância com percentual de acerto na classificação de cada conjunto [39].

Nota-se em todas as análises que os parâmetros relacionados a frequências são os mais relevantes na classificação. Inclusive, observou que o acréscimo de parâmetros relativos à frequência aumentou o percentual de acerto quando utilizados para discriminar os conjuntos de parâmetros nas classes de propagação.

A partir destas análises, apresentou-se a função de regressão calculada para cada uma das classes. Através destas, pode-se calcular a probabilidade do sinal de entrada pertencer a cada classe (SP, PE e PI). O gráfico na Figura 11 apresenta o resultado e a partir dele é possível estimar a faixa no tempo para cada classe de propagação [39].




Figura 11 – Curva PoP [39].

2.10 Elementos de Ensaio Hidrostático Controlado

Os segmentos de dutos são de aço especificação API XL 60 com costura, diâmetro nominal de 20 polegadas (50,8cm), comprimento de 1,50m e espessura de parede 14,5mm. A descontinuidade inserida possuía morfologia planar longitudinal em formato semielíptico sendo fabricada por eletroerosão, objetivando-se a simulação de possíveis trincas reais. Recorreu-se a sensores para coleta dos sinais de emissão acústica e transdutores de ultrassom para a medição da profundidade das descontinuidades inseridas. As descontinuidades foram posicionadas longitudinalmente nos corpos de

prova com a finalidade de serem submetidas à tensão circunferencial de tração, que é a tensão principal nos dutos [4].

A trinca pode ser considerada um defeito transversal (tipo de característica visual) de soldagem. Caracterizada por uma zona muito estreita e irregular com baixo contraste na inspeção radiográfica [5].

Os corpos de prova foram carregados com pressão interna durante a realização de testes hidrostáticos. Foram utilizadas curvas de pressurização que permitiram atingir pressões equivalentes a 90% da tensão limite de escoamento. Para os corpos de prova confeccionados, a pressão correspondente à tensão limite de escoamento do material empregado nos testes (API XL 60) foi calculada como 267 kgf/cm^2 [4].

O posicionamento da trinca em corpo de provas deve ser considerado para o estudo de emissão acústica, pois a sua localização externa ou interna na calota do duto pressurizado pode impactar nos fenômenos ondulatórios (reflexão, refração e difração) durante o fenômeno da emissão acústica. Nos ensaios em questão deste estudo, as trincas possuíam localização externa da calota do duto.

Normalmente, o ensaio hidrostático causa uma resistência local em regiões de tensão secundária elevada. Esta resistência local é acompanhada por sinais de emissão acústica os quais não necessariamente indicam descontinuidades. Portanto, durante as provas de carga hidrostática é possível a detecção de atividades no primeiro ciclo. Estes sinais estão associados ao trabalho mecânico induzido pela pressão final de teste, normalmente muito superior a de operação ocorrida nos últimos anos. Nesta situação, é normal a ocorrência de pequenas fissuras superficiais e a presença de atividade acústica próxima a regiões onde existem estas descontinuidades. Isso ocorre, pois estas atuam como concentradores de tensão promovendo uma redistribuição localizada, sem contudo estarem associadas a um processo de crescimento subcrítico de defeito. Os casos citados são caracterizados pela ausência de atividades durante o segundo ciclo.

Este comportamento também é notado, nas situações em que a prova de carga promove uma deformação plástica na extremidade de trincas, a qual evita o crescimento do defeito. Este caso é muito comum em vasos de pressão que não tiveram tratamento térmico após soldagem (alívio de tensões) [3].

Outro aspecto é quanto à diferenciação que poderá ocorrer entre as deformações nas pontas da trinca. Indicando, portanto um direcionamento dos esforços e da propagação da descontinuidade pelo esforço recebido.

Um exemplo deste fato é visualizado pelas Figuras 12 e 13, onde as deformações foram medidas via extensometria de resistência elétrica e a constatação que a direção da tensão máxima principal é coincidente com a direção tangencial do tubo [17].

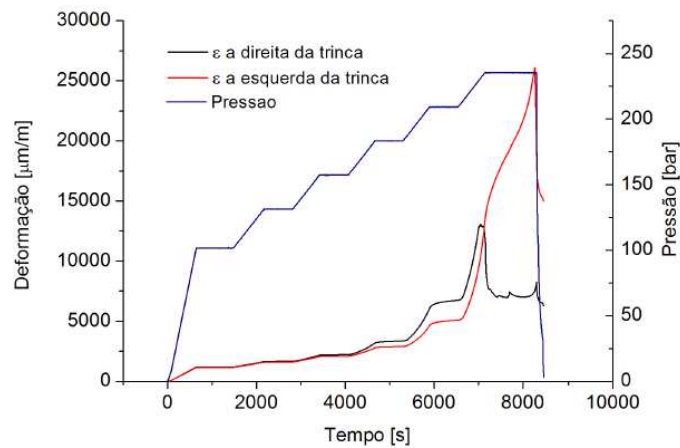


Figura 12 – Variação da pressão e das deformações nas duas extremidades da trinca durante o ensaio hidrostático [40].

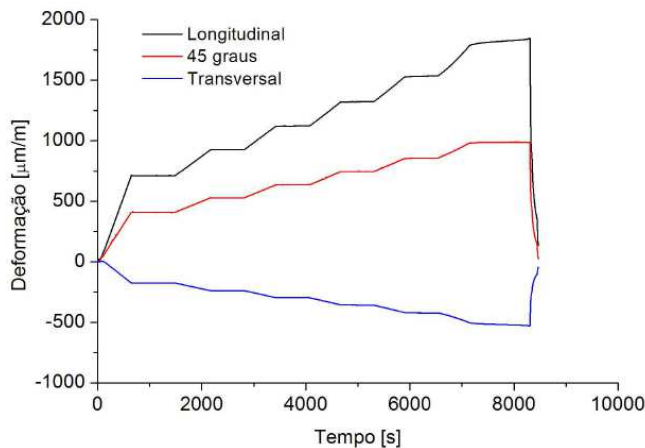


Figura 13 – Variação das deformações durante o ensaio hidrostático medidas com a roseta extensométrica nas direções longitudinal, a 45 graus e na transversal do tubo [40].

Do início deste capítulo até este ponto do texto foram apresentados conceitos e resultados discutidos em trabalhos acadêmicos e científicos sobre o tema. Sua relevância no estudo é percebida quando os benefícios do entendimento do fenômeno e sua mensuração permitem avaliações estruturais mais eficientes. A dificuldade envolvida no tema foi ilustrada diante dos inúmeros fatores que impactam as medições e os registros da emissão acústica, inclusive pela previsibilidade em torno do crescimento da descontinuidade na trinca.

2.11 Fundamentos da Ciência dos Materiais

Desta seção ao final do capítulo são apresentados conceitos que influenciam a propagação da descontinuidade da trinca por estes estarem associados à estrutura interna do material pelo qual haverá a emissão das ondas de emissão acústica. Estas influências são variáveis não controladas¹⁸ e que afetam os resultados das medições durante o ensaio hidrostático.

A Engenharia dos Materiais por meio de propriedades básicas dos materiais (mecânicas, térmicas, elétricas, magnéticas, óticas e químicas) desenvolvem projetos limitados por estas características. Os projetos de engenharia dependem de materiais que são conformados, unidos e acabados por processos (métodos de conformação, união ou acabamento de um material – tratamento da superfície). E desta forma, são definidos pelas propriedades dos materiais.

Por exemplo, os metais têm rigidez¹⁹ relativamente alta, medida pelo módulo de elasticidade²⁰. A maioria quando puros é macia e se deforma facilmente, o que significa que a tensão de escoamento é baixa. Por meio de adição de elementos e tratamento térmico, a tensão limite de escoamento de ligas metálicas pode aumentar, mas ainda permanecendo dúcteis, o que permite que sejam conformados por processos de deformação. E em geral, são rígidos, com a característica de tenacidade à fratura alta.

¹⁸ Características que não são controladas ou influenciadas por qualquer projeto ou ensaio. São inerentes ao processo de fabricação e da composição do material.

¹⁹ Rigidez é a resistência elástica à mudança de forma, o material volta a sua forma original quando a tensão cessa. Resistência está relacionada à distorção permanente ou à falha total.

²⁰ Tensão causa deformação e a capacidade de lidar com tensão, sem sofrer deformação, é denominada resiliência (módulo de elasticidade). A tensão está relacionada ao carregamento e, portanto, a deformação é a resposta da magnitude da tensão e do modo como ela é aplicada.

Muitos são bons condutores térmicos e elétricos. Porém, os metais são reativos, sofrem corrosão se não forem protegidos [41].

Portanto, o material é definido por um perfil de propriedades identificado pela “árvore de materiais”. A “árvore de materiais” é uma estrutura hierárquica composta por Reino, Família, Classes, Subclasses e Membro para definição dos atributos do material (perfil de propriedades) aplicados na Engenharia dos Materiais conforme exemplificado pela Figura 14 [41].

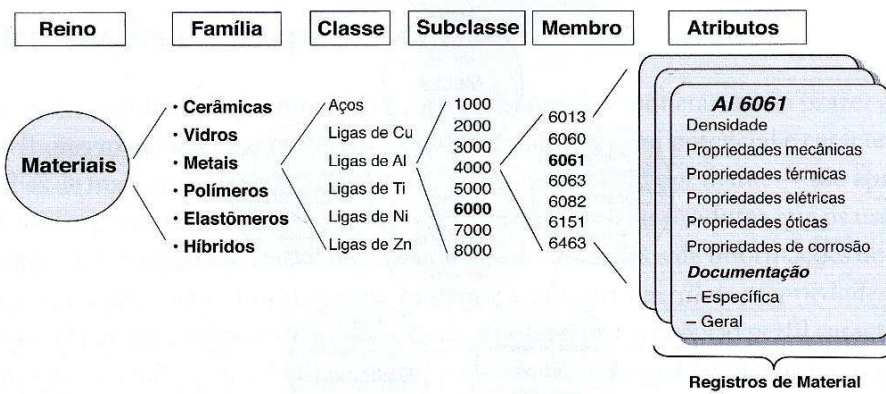


Figura 14 – Taxonomia do reino dos materiais e seus atributos [41].

Em síntese uma matéria-prima sofre processo de conformação primária (fundição moldagem, deformação, etc.), processos secundários (usinagem e tratamento térmico) e seguidos dos processos de acabamentos (união e tratamento de superfície) para chegar ao estágio de produto acabado. Estes processos são caracterizados por um conjunto de atributos conforme os atributos do material, por exemplo, os apresentados na Figura 14.

2.11.1 Rigidez e Peso

A maioria dos componentes de engenharia suporta cargas. A resposta elástica destes componentes depende do modo como às cargas são aplicadas. Os componentes são projetados para aguentar diferentes modos de carregamento: tração, compressão, torção, flexão e pressão interna ou externa.

Normalmente, um dos modos é dominante e o componente material pode ser idealizado como um dos casos simplesmente de carregamento. A Figura 15 apresenta os tipos básicos de carregamento com os estados de tensão associados.




Figura 15 – Modos de carregamento e estados de tensão [41].

A rigidez (medida pelo módulo de elasticidade) e a resistência (medida pelo módulo limite elástico ou pela resistência a tração) são propriedades dos materiais, no entanto a tensão e deformação que se aplicam aos materiais não são propriedades dos mesmos e sim um estímulo e uma resposta.

A tensão²¹ causa deformação, pois módulo de elasticidade é a capacidade de lidar com tensão sem sofrer deformação. Portanto, a tensão, a deformação e os módulos de elasticidades se relacionam, pois a tensão é devida a um carregamento e deformação a mudança de forma conforme modo de carregamento que está associado ao módulo de elasticidade [41].

A Figura 16 apresenta os tipos de módulos de elasticidade associados à tensão de tração, à tensão de cisalhamento e à pressão.

²¹ Tensão de tração provoca um estiramento.

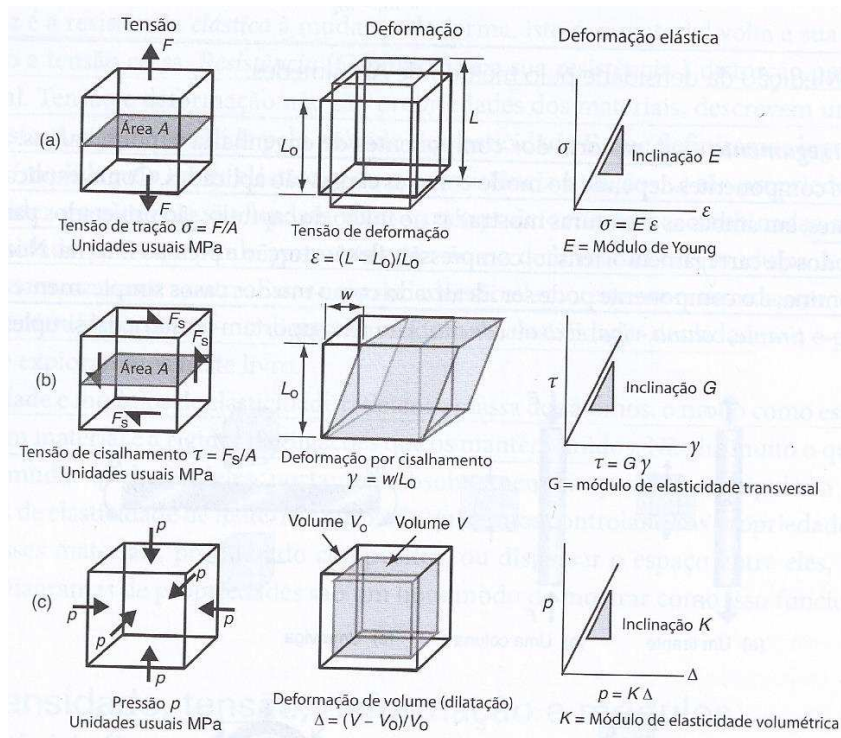


Figura 16 – Definição de tensão, deformação e módulos de elasticidade [41].

A diferença de pressão aplicada a uma concha (tubo cilíndrico) gera tensão ou compressão biaxial. As tensões em qualquer elemento pequeno no interior do componente material sempre podem ser descritas por uma combinação de tração, compressão e cisalhamento conforme ilustrado pela Figura 16 [41].

Densidade e módulos de elasticidades refletem a massa dos átomos, o modo de empacotamento de um material e a rigidez das ligações que os mantém unidos. Por isso, a deformação é a resposta dos materiais a tensão.

2.11.2 Resistência e ductilidade

Como visto, a tensão de escoamento é a tensão além da qual o material se torna plástico. O escoamento e a plasticidade permitem que metais sejam conformados e que estruturas suportem impactos e absorvam energia.

A Figura 17 mostra uma curva típica de tensão de tração-deformação para um metal. A parte inicial até o limite elástico é aproximadamente linear, denominada Lei de

Hooke. Esta fase é elástica, o que significa que a deformação é recuperável. As tensões acima do limite elástico causam deformação permanente (comportamento dúctil) ou fratura. Quando submetidos à tensão que ultrapassa o ponto de escoamento, a maioria dos metais sofre encruamento, que resulta na parte ascendente da curva até alcançar um máximo, a resistência à tração. Sob tração, essa fase é seguida por deformação não uniforme (estricção) e fratura [41].




Figura 17 – Curva de tensão de tração-deformação para metais²² [41].

A ductilidade é uma medida de deformação plástica que um material pode tolerar. A área sob a parte elástica da curva tensão-deformação é definida como a energia elástica armazenada por unidade de volume. Ultrapassando o limite elástico é realizado trabalho plástico na deformação permanente de um material por escoamento²³ ou esmagamento. Assim, o trabalho plástico é área sob a curva tensão-deformação.

A deformação plástica é a deformação permanente resultante da plasticidade, portanto, é a deformação total menos a parte recuperável (elástica). A deformação por escoamento significa a deformação à qual o material cessa de ser linearmente elástico.

Metais, em geral, são policristalinos – formados por muitos cristais minúsculos orientados aleatoriamente. Átomos são muitos diferentes em peso, mas poucos diferem em tamanho quando empacotados para formar sólidos. Assim, a densidade é

²² A tensão de escoamento é a tensão além da qual ele se torna plástico. Para metais, o início da plasticidade nem sempre é clara, portanto define-se a tensão à qual a curva se desvia por deformação de 0,2% da linha elástica linear.

²³ Deformação por escoamento significa a deformação à qual o material cessa de ser linearmente elástico.

determinada, sobretudo pelo peso atômico e é influenciada em menor grau pelo tamanho dos átomos pelo modo como são empacotados. Metais são densos porque são feitos de átomos pesados, densamente empacotados.

Muitas propriedades dos materiais dependem diretamente do modo como os átomos ou moléculas em seu interior são empacotados. Os metais, em sua maioria, são cristalinos, com um padrão de unidades estruturais repetido regularmente.

As ligações entre átomos têm um ponto de ruptura e os cristais contêm imperfeições de vários tipos [41]:

- a) Defeitos pontuais: todos os cristais contêm vacâncias – sítios nos quais faltam átomos.
- b) Impurezas herdadas do processo de fabricação: criação de ligas – solução sólida substitucional (os átomos dissolvidos substituem os do hospedeiro) e solução sólida intersticial (os átomos substituídos se apertam dentro dos espaços ou “interstícios” entre os átomos do hospedeiro). Os átomos ou solutos dissolvidos raramente têm o mesmo tamanho dos átomos do material hospedeiro, portanto distorcem o reticulado ao seu redor. Soltos causam distorção local (essa distorção é uma das razões das ligas serem mais fortes do que materiais puros).
- c) Discordância: a parte superior do cristal tem uma camada dupla a mais de átomos do que a parte inferior tornando os metais macios e dúcteis e distorcem o reticulado.
- d) Contornos de grãos: superfícies de encontro de cristais individuais perfeitos com orientações distintas. Formam-se em ligas quando a mistura de átomos de um grão pode ter composição química diferente da dos seguintes.

A Figura 18 ilustra os defeitos em cristais apresentados anteriormente. Esses defeitos explicam difusão, resistência, ductilidade, resistência elétrica, condutividade térmica e outros.

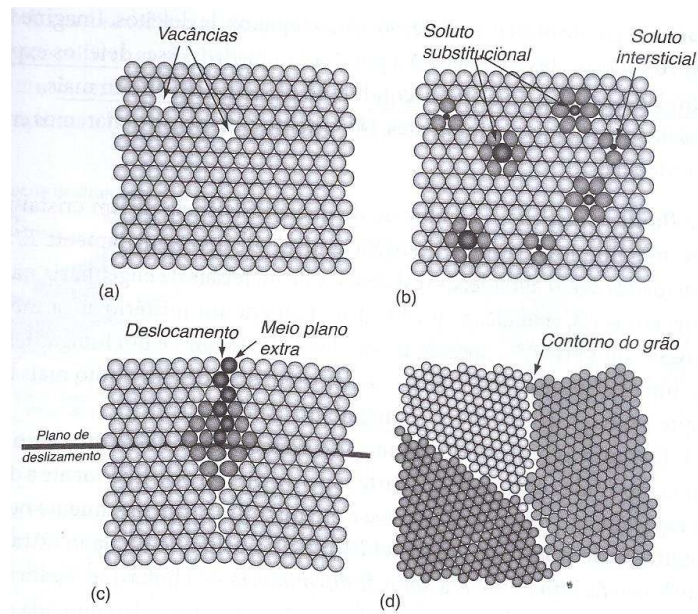


Figura 18 – Defeitos em Cristais: (a) Vacância (b) Impurezas (c) Deslocamento (d) Contornos [41].

A parte ascendente da curva tensão-deformação é causada por encruamento que representa o acúmulo de discordância²⁴ gerado por deformação plástica. Quando metais são deformados, as discordâncias se multiplicam, o que provoca o crescimento de sua densidade.

Na Figura 19 apresenta-se a exemplificação do processo de discordância: (a) mediante corte, deslizamento e recomposição de ligações e (b) configuração atômica em discordância de aresta [41].

²⁴ Linha de discordância é a linha de união átomos de planos distintos após deslizamentos das superfícies (separa a parte do plano que deslizou da parte que não deslizou). Quando uma discordância se move, provoca o deslizamento do material que está acima do plano de deslizamento sobre o que está abaixo, produzindo uma deformação por cisalhamento.




Figura 19 – Processo de discordância [41].

2.11.3 Mecânica da Fratura

A resistência do material é a sua resistência à fluidez plástica. Em geral a resistência aumenta com a deformação plástica provocada por encruamento e alcança um máximo à resistência à tração. A área sob toda a curva tensão-deformação até a fratura é denominado Trabalho de Fratura [41].

Tenacidade²⁵ é a resistência de um material à propagação de uma trinca (trincas são agudas – raio da ponta tende a zero – e concentram tensão). A tensão local, proporcional ao número de linhas de forças que cruzam uma unidade de comprimento da seção transversal, não é uniforme, pois aumenta acentualmente à medida que se aproxima da ponta da trinca, ilustrado na Figura 20.

²⁵ Tenacidade à fratura é uma propriedade de material.

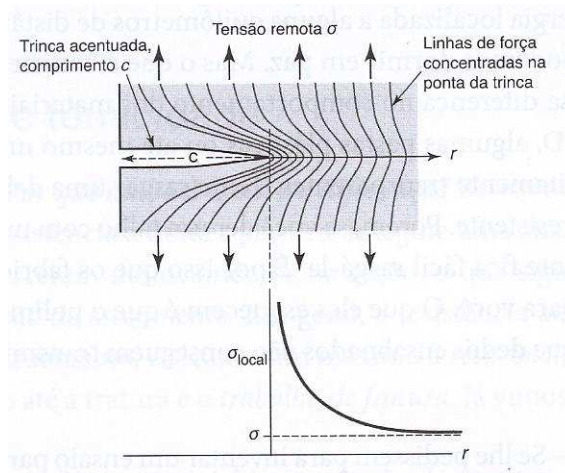


Figura 20 – Linhas de forças de um corpo trincado sob carga [41].

A análise do campo de tensão à frente de uma trinca aguda de comprimento c mostra que a tensão local a uma distância r de sua ponta provocada por uma tensão de tração uniforme remota σ é [41]:

$$\sigma_{local} = \sigma \left(1 + Y \sqrt{\frac{\pi c}{2\pi r}} \right) \quad (1)$$

Onde Y é uma constante com valor próximo da unidade que depende da geometria do corpo trincado.

A equação 1 pode ser aproximada pelas seguintes relações:

$$a) \quad r \gg c \text{ (distante da trinca): } \sigma_{local} = \sigma \quad (2)$$

$$a) \quad r \ll c \text{ (próximo da ponta): } \sigma_{local} = \sigma \left(Y \sqrt{\frac{\pi c}{2\pi r}} \right) \quad (3)$$

A trinca se propaga quando o fator de intensidade de tensão ultrapassa um valor crítico (tenacidade à fratura).

A condição necessária para a fratura é que seja realizado trabalho externo suficiente, ou liberação de energia elástica para, no mínimo, fornecer a energia superficial por unidade de área das duas novas superfícies que são criadas. Isso deve ao fato da deformação plástica ao redor da ponta da trinca conforme apresentado na Figura 21.




Figura 21 – Liberação de energia elástica quando uma trinca propaga [41].

O campo de tensão interna na ponta de uma trinca gera uma zona de processo (uma zona elástica em sólidos dúcteis). Dentro da zona de processo é realizado trabalho contra forças plásticas e de atrito pela diferença entre a energia de fratura e a energia superficial²⁶.

É possível estimar o tamanho de uma zona plástica que se forma na ponta da trinca. No ponto em que ela alcança a tensão de escoamento, o material sofre escoamento (exceto algum encruamento – a tensão não pode subir mais do que isso). A parte truncada do campo de tensão elástica é redistribuída, o que aumenta a zona plástica. Este processo é ilustrado na Figura 22.

²⁶ Energia superficial de um sólido é a energia necessária para estruturar a nova superfície. Prover energia coesiva associada às ligações que antes uniam a área do corte.

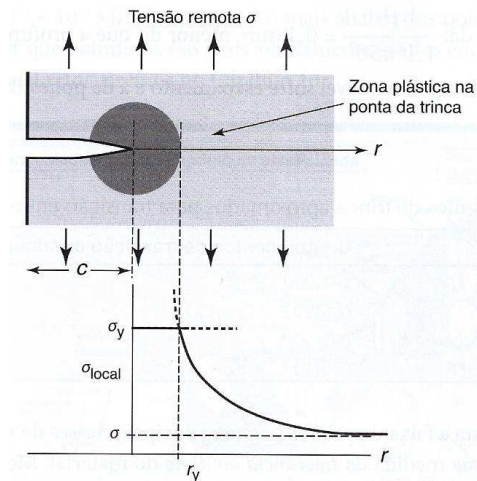


Figura 22 – Zona plástica se forma na ponta da trinca, onde caso contrário, a tensão ultrapassaria a tensão de escoamento [41].

Quando as trincas são pequenas, os materiais sofrem escoamento antes de sofrer fratura; quando são grandes, ocorre o contrário. A tensão de falha por tração varia com o tamanho da trinca conforme Figura 23.




Figura 23 – Transição de escoamento para a fratura no comprimento da trinca crítico (c_{crit}) [41].

Metais dúcteis se deformam plasticamente quando carregados acima de sua tensão de escoamento e sofrem encruamento até alcançarem o limite da resistência à tração, enfraquecem e falham.

A tensão aumenta à medida que se aproxima da ponta da trinca, mas no ponto em que ultrapassa a tensão de escoamento, o material sofre encruamento, e uma zona plástica se desenvolve. Dentro desta zona plástica, vazios se nucleiam, crescem e se

unem para dar uma fratura dúctil. A trinca avança de modo dúctil, absorvendo energia no processo e o processo se repete [41].




Figura 24 – Propagação da trinca [41].

A energia absorvida por uma trinca quando avança, resulta da deformação que ocorre na zona plástica em sua ponta. O aumento da tensão de escoamento faz a zona encolher e quando menor a zona, menor a tenacidade. A separação dentro da zona plástica permitindo o avanço da trinca resulta do crescimento de vazios que se nucleiam nas inclusões. A tenacidade aumenta sem nenhuma perda de resistência se as inclusões forem eliminadas, pois atrasa a nucleação de vazios [41].

2.11.4 Fadiga

Parte da energia sempre é perdida em um ciclo de carga-descarga. O coeficiente de perda mecânica ou coeficiente de amortecimento mede o grau de dissipação de energia de vibração por um material. A fração de energia elástica armazenada não devolvida com o descarregamento é denominada coeficiente de perda. Vibração de baixa amplitude não causa dano nos materiais, mas com o aumento da amplitude pode ocorrer fadiga [41].

Em fadiga de alto ciclo, se houver trinca, ela se propagará da seguinte maneira: durante a parte de tração de um ciclo, uma minúscula zona plástica se forma na ponta da trinca, estirando-a, abrindo-a, e com isso criando uma nova superfície. Na parte de compressão do ciclo, a trinca se fecha novamente e a superfície recém constituída forma uma prega, dobra-se para frente, e faz a trinca avançar. Ciclos repetidos fazem a trinca progredir, deixando minúsculas ondulações na face da trinca que marcam sua posição em cada ciclo.

Esse processo é característico de uma falha por fadiga e úteis para identificar onde a trinca iniciou e com a velocidade que se propagou conforme ilustrado na Figura 25-a. Em fadiga de baixo ciclo, as tensões são mais altas e a zona plástica maior.

A maioria das deformações está na ponta da trinca, onde a plasticidade faz com que os vazios se nucleiam, cresçam e se unam. Exatamente como uma fratura dúctil, ilustrado na Figura 25-b [41].




Figura 25 – (a) Fadiga de alto ciclo (b) Fadiga de baixo ciclo [41].

Após explanação dos conceitos desta subseção, observa-se que o comportamento da trinca está diretamente relacionado a inúmeros fatores que afetam sua resposta ao estímulo. As discontinuidades metalúrgicas nos corpos de provas podem sofrer comportamentos distintos durante os ensaios. Estes comportamentos são derivados das características apresentadas anteriormente.

2.12 Ondas Elásticas em Sólidos

A onda de vibração da rede cristalina é o tipo de onda em cristais pela qual as propriedades são deduzidas da física clássica, uma vez que os íons que formam a rede são relativamente pesados.

A energia de interação entre dois íons apresenta uma posição de equilíbrio conforme ilustrado na Figura 26. Esta posição de mínima energia de ligação ocorre em zero absoluto (temperatura de 0 K) e quando não há nenhuma perturbação externa ao sistema. Desta forma, a posição de equilíbrio tende a oscilar em torno deste ponto para pequenos desvios próximo a um oscilador harmônico [42].




Figura 26 – Energia de interação efetiva entre dois íons [42].

A vibração coletiva dos íons pode ser vista como uma superposição de ondas. As excitações da rede tem caráter ondulatório e estas ondas de vibração são referenciadas como ondas elásticas.

A Figura 27 ilustra o caráter vibratório indicando a propagação da energia e o sentido do deslocamento dos íons numa onda elástica. Onde (a) representa o modelo mecânico massa-mola associado em equilíbrio; (b) os deslocamentos dos íons numa onda longitudinal e (c) deslocamentos dos íons numa onda transversal.




Figura 27 – (a) modelo em equilíbrio (b) deslocamentos dos íons numa onda longitudinal (c) deslocamentos dos íons numa onda transversal [42].

2.13 Modulações Analógicas

Nesta seção são apresentados princípios básicos de modulação analógica utilizada em Engenharia de Telecomunicações para entendimento do conceito base da metodologia sugerida pela qual o sinal da onda de emissão acústica foi avaliado.

O uso da modulação não se restringe exclusivamente a sistemas de comunicações. A modulação é usada de uma forma ou de outra em processamento de sinais, radiometria, radar, sonar, sistemas de controle e instrumentos de uso geral como, por exemplo, analisadores de espectro e sintetizadores de frequência. No contexto dos sistemas de comunicações os benefícios seriam, por exemplo [43]:

- a) A modulação é usada para deslocar o conteúdo espectral de um sinal de mensagem de forma que ele se situe na faixa de frequência operacional de um canal de comunicação.
- b) A modulação constitui um mecanismo para colocar o conteúdo da informação de um sinal de mensagem numa forma que possa ser menos vulnerável a ruído ou interferência.
- c) A modulação permite o uso de multiplexação.

Um sinal é um conjunto de informação ou dados e, portanto, um sistema pode processar um sinal por meio de alguma modificação ou extração adicional de alguma

informação. Desta forma, um sistema é uma entidade que processa um conjunto de sinais (entradas) para produzir outro conjunto de sinais (saídas).

Um sistema de comunicação é composto basicamente por elementos fundamentais: fonte, transmissor, canal, receptor e destino.

A fonte fornece a informação básica (sinal de mensagem) referida como sinal em banda base. O transmissor modifica o sinal em banda base para transmissão eficiente e este pode constituir em um ou mais subsistemas. O canal é um meio pelo qual os sinais elétricos na saída do transmissor são transportados ao longo de uma dada distância. O receptor processa o sinal recebido do canal, revertendo às modificações feitas pelo transmissor no sinal e minimizando as distorções feitas pelo canal.

Um canal é um meio físico o qual se comporta parcialmente como um filtro que atenua o sinal e distorce as formas de ondas transmitidas. A atenuação do sinal aumenta com o comprimento do canal e a distorção das formas de onda dos sinais tem origem em fenômenos físicos como ganhos dependentes da frequência, efeitos multipercorso e deslocamento Doppler [43].

Sinais que passam por canais de comunicação não apenas sofrem distorções do canal, mas também são corrompidos ao longo do percurso por interferências e perturbações indesejadas, ruídos. Esses sinais interferentes são aleatórios e imprevisíveis e suas fontes são externas e internas.

Portanto, em sistemas de comunicação, o canal distorce o sinal e o ruído se acumula ao longo do percurso. A intensidade do sinal diminui com a distância, enquanto o nível do ruído se mantém estacionário, independente do afastamento desde o transmissor. Em consequência, a qualidade do sinal se deteriora continuamente enquanto transpõe o comprimento do canal. A amplificação do sinal recebido para compensar a atenuação é inútil, pois o ruído será amplificado na mesma proporção.

É impossível evitar o acúmulo de ruído e distorção na banda passante ao longo do percurso. Logo, a distorção e a interferência do ruído podem acumular por todo o percurso de transmissão à medida que o sinal se propaga pela rede/meio. O sinal é continuamente atenuado no percurso da transmissão e desta forma com aumento da distância, o sinal se torna mais fraco enquanto há o acúmulo de distorção e ruído.

Sinais analógicos gerados são referidos como sinais em banda base, pois tem natureza passa-baixos. Sinais em banda base podem ser transmitidos diretamente por meio de um canal apropriado. Contudo, dependendo das características do canal e do sinal no domínio da frequência, sinais em banda base produzidos por diversas fontes de informação nem sempre são adequados à transmissão direta através de um dado canal. Quando as bandas de frequências do sinal e do canal não coincidem exatamente, os canais não podem ser deslocados em frequência. Portanto, as mensagens devem ser deslocadas para as bandas de frequências adequadas aos canais.

Este processo de conversão para que a transmissão se torne possível a partir da modificação do sinal se chama modulação. O sinal em banda base é usado para modificar (modular) algum parâmetro (característica) de uma portadora de sinal de radiofrequência (RF) [43,44].

Uma portadora é uma senoíde de alta frequência e através da modulação, um dos parâmetros da portadora senoidal (amplitude, frequência ou fase) é variado proporcionalmente em função do sinal em banda base $m(t)$.

A Figura 28 ilustra o processo de modulação, onde o sinal modulado é resultado da influência do sinal modulador sobre o sinal da portadora. A modulação será linear se o termo $\beta(t)$ for uma função do sinal modulador e não linear caso $\alpha(t)$ seja uma função $m(t)$.




Figura 28 – Processo de modulação

Sendo assim:

- a) Modulação em Amplitude (AM: *amplitude modulation*): a amplitude da portadora varia em proporção ao sinal modulador.
- b) Modulação em Frequência (FM: *frequency modulation*): a frequência da portadora varia em proporção ao sinal modulador.
- c) Modulação em Fase (PM: *phase modulation*): a fase da portadora varia em proporção ao sinal modulador.

A Modulação em Amplitude (AM) é uma operação linear enquanto os outros dois tipos de modulações com portadoras são similares e não lineares ambas designadas pelo nome Modulação em Ângulo (FM e PM) [43,44].

A modulação, em geral, se refere a um processo que desloca o sinal de mensagem a uma banda específica de frequências do canal físico. Uma vez que sinais em banda base têm bandas que se sobrepõem, haveria forte interferência entre sinais que compartilhassem o mesmo canal. Quando há a modulação de vários sinais em banda base e o resultante deslocamento de seus espectros as bandas de frequências não havendo a sobreposição dos espectros constitui a multiplexação por divisão da frequência (FDM: *frequency division multiplexing*) pelo qual muitos usuários podem compartilhar um canal, utilizando a maior parte da banda disponível.

2.13.1 Modulação em Amplitude

Modulação em amplitude (AM) é caracterizada por uma amplitude portadora de informação, que é uma função linear do sinal de banda base. Ao mesmo tempo, a frequência e a fase da portadora permanecem constantes.

O processo de modulação desloca o espectro do sinal modulante para a esquerda e para a direita por f_c (banda lateral superior - USB: *upper sideband* e banda lateral inferior - LSB: *lower sideband*) [44].

Como transformada de Fourier é definida como:

$$\mathcal{F}\{g(t)\} = \int_{-\infty}^{+\infty} g(t) \cdot e^{-j2\pi ft} dt = G(f) \quad (4)$$

então,

$$\begin{aligned} \mathcal{F}\{g(t) \cdot e^{j2\pi f_c t}\} &= \int_{-\infty}^{+\infty} g(t) \cdot e^{j2\pi f_c t} \cdot e^{-j2\pi ft} dt = \\ &= \int_{-\infty}^{+\infty} g(t) \cdot e^{-j2\pi(f-f_c)t} dt = G(f - f_c) \end{aligned} \quad (5)$$

e por consequencia,

$$\begin{aligned} \mathcal{F}\{g(t) \cdot e^{-j2\pi f_c t}\} &= \int_{-\infty}^{+\infty} g(t) \cdot e^{-j2\pi f_c t} \cdot e^{-j2\pi ft} dt = \\ &= \int_{-\infty}^{+\infty} g(t) \cdot e^{-j2\pi(f+f_c)t} dt = G(f + f_c) \end{aligned} \quad (6)$$

A partir destas relações das equações 5 e 6, obtém-se então a propriedade de modulação (propriedade de Translação na Frequência) [43,44]:

$$g(t)e^{j2\pi f_c t} \leftrightarrow G(f - f_c) \quad (7)$$

$$g(t)e^{-j2\pi f_c t} \leftrightarrow G(f + f_c) \quad (8)$$

De acordo com a propriedade de Translação na Frequência, a multiplicação de um sinal por um fator $e^{j2\pi f_c t}$ desloca o espectro do sinal por $f = f_c$. Como $e^{j2\pi f_c t}$ não é uma função real que possa ser gerada, o deslocamento em frequência é obtido pela multiplicação de $g(t)$ por uma senoíde.

Ou seja²⁷,

$$g(t) \cdot \cos(2\pi f_c t) = \frac{1}{2} [g(t)e^{j2\pi f_c t} + g(t)e^{-j2\pi f_c t}] \quad (9)$$

²⁷ Relação de Euler: $e^{+j\theta} = \cos(\theta) - j \cdot \text{sen}(\theta)$

Notação Fasorial: $a \cdot e^{j\theta} \cdot e^{j2\pi ft}$, onde $a \cdot e^{j\theta}$ é o termo não girante e $e^{j2\pi ft}$ é o termo girante.

E aplicando as definições da propriedade da modulação – Equações 7 e 8:

$$F\{g(t) \cos(2\pi f_c t)\} = \frac{1}{2} [G(f - f_c) + G(f + f_c)] \quad (10)$$

Ao usar a portadora $\cos(2\pi f_c t + \theta_c)$ no lugar de $\cos(2\pi f_c t)$, a fase de cada componente espectral de um sinal modulado será transladado por um valor constante θ_c pois:

$$\begin{aligned} F\{g(t) \cos(2\pi f_c t + \theta_c)\} &= \quad (11) \\ &= \frac{1}{2} [g(t)e^{j2\pi f_c t} \cdot e^{j\theta_c} + g(t)e^{-j2\pi f_c t} \cdot e^{j\theta_c}] = \\ &= \frac{1}{2} [G(f - f_c)e^{j\theta_c} + G(f + f_c)e^{-j\theta_c}] \end{aligned}$$

O sinal modulado não contém uma componente discreta da frequência da portadora f_c , pois o processo de modulação não introduz uma senoíde em f_c . Por este motivo é referido como “modulação em banda lateral dupla com portadora suprimida” (DSC-SC: *double-sideband suppressed carrier*) conforme ilustrado pela Figura 29.

A relação entre B (largura de banda) e f_c (frequência da portadora) é importante para a superposição dos espectros modulados centrados em f_c e em $-f_c$. Se $f_c < B$, as duas cópias do espectro da mensagem se sobreporiam e a informação de $m(t)$ seria perdida durante a modulação, o que impossibilitaria a recuperação do sinal modulante do sinal modulado. Nota-se pela inclusive que o sinal modulado tem o dobro da largura de banda do sinal modulante como apresentado na Figura 29(c) [43,44].

Para recuperar o sinal original, $m(t)$, do sinal modulado é necessário devolver o espectro a posição original. O processo de recuperação se chama demodulação que consiste em multiplicar o sinal modulado recebido por uma portadora e aplicar o resultado a um filtro passa-baixas.

O processo básico da modulação em amplitude é representado pela Figura 29:

- O princípio da modulação pela propriedade de translação da frequência.
- O sinal modulante e o respectivo espectro de frequência.
- O sinal modulado e respectivo espectro de frequência.
- O espectro do sinal $e(t)$ no processo de demodulação.
- O processo de demodulação para recuperação do sinal original.

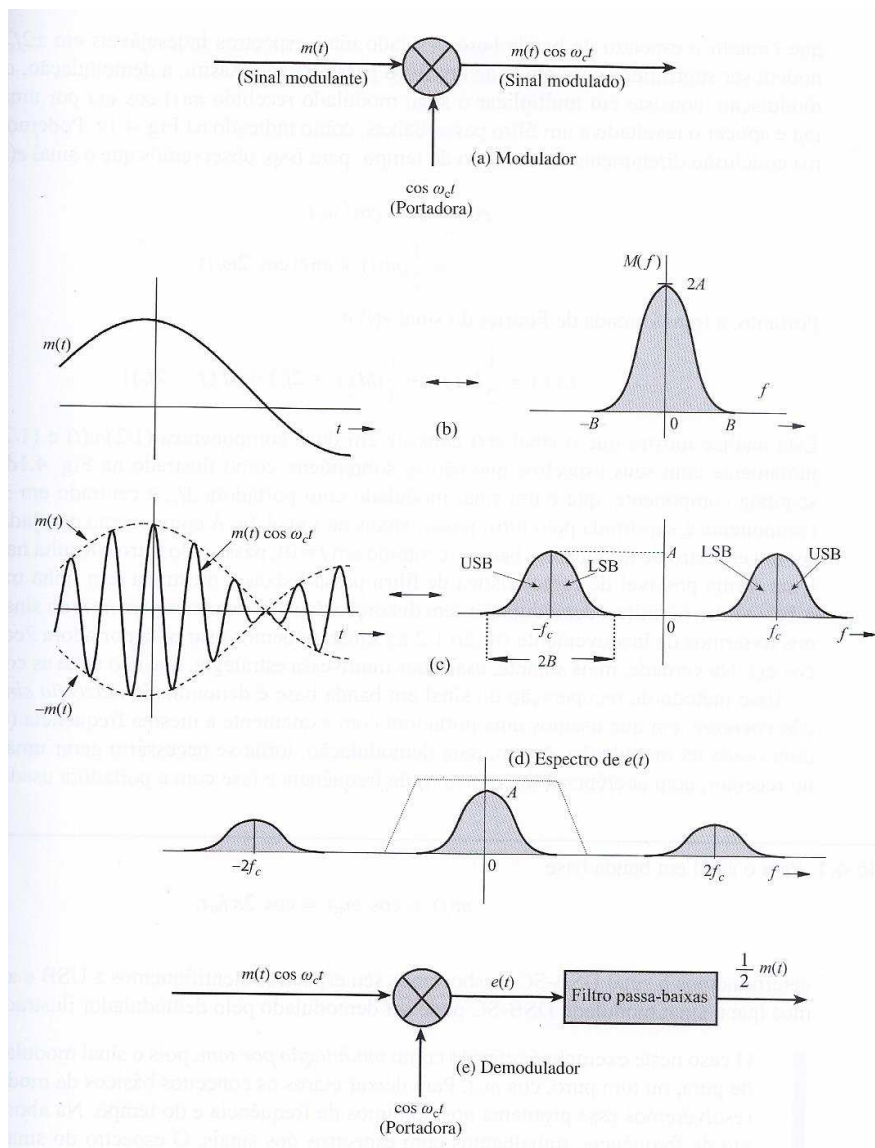


Figura 29 – Modulação e Demodulação AM [44].

As Figuras 30 e 31 ilustram os sinais das fases destacadas pela Figura 29 no domínio do tempo e da frequência respectivamente para fins de ilustração do processo de modulação e demodulação em amplitude (AM).

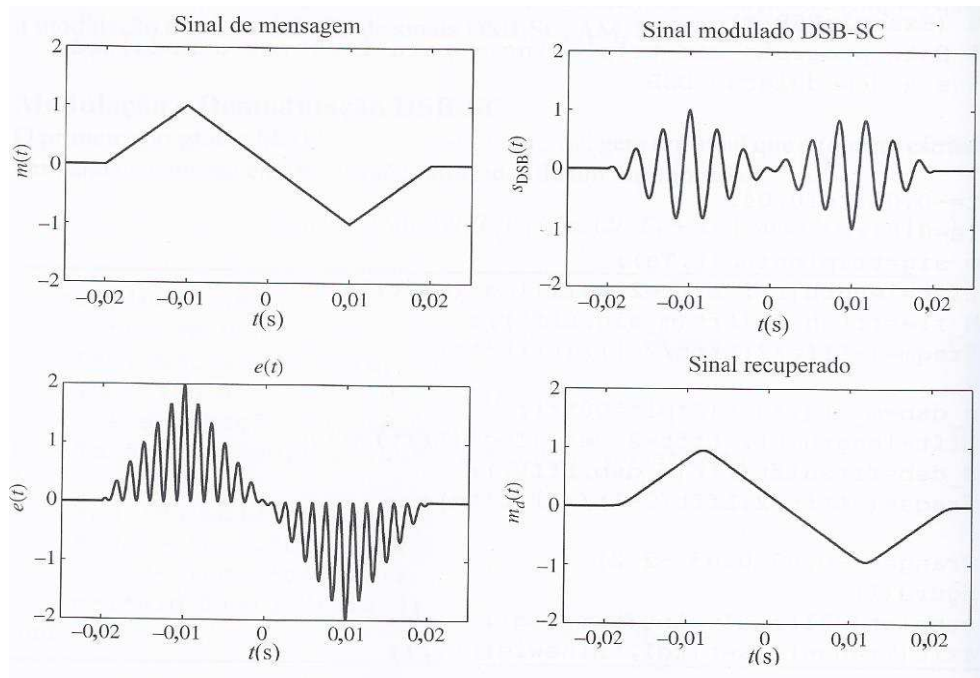


Figura 30 – Sinais no domínio do tempo durante a modulação e a demodulação [44].

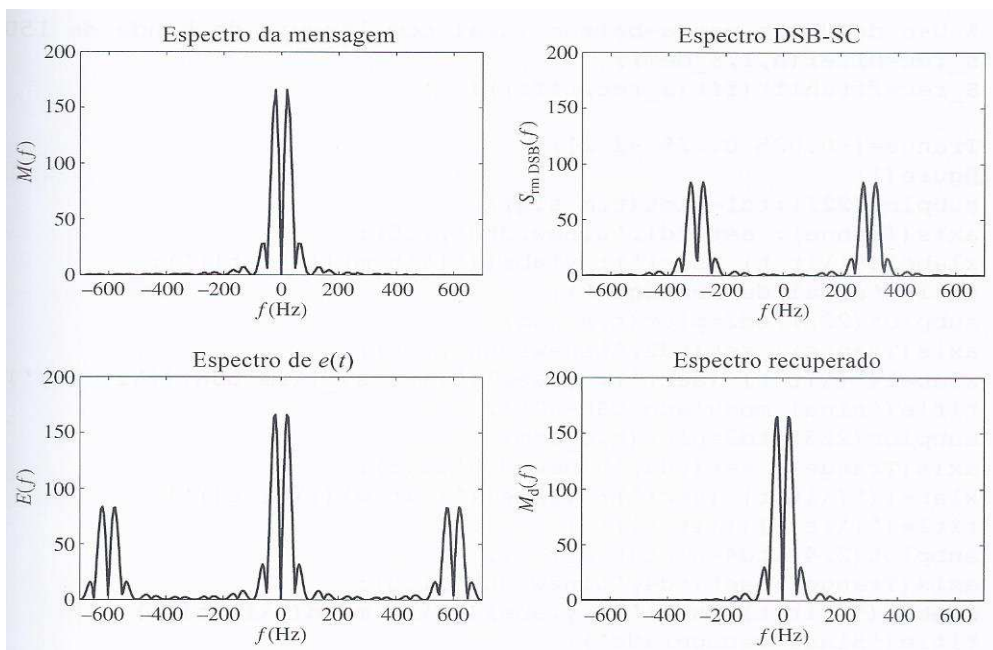


Figura 31 – Sinais no domínio da frequência durante a modulação e a demodulação [44].

2.13.2 Modulação em Ângulo

Sinais em modulação em frequência (FM) podem variar a frequência instantaneamente proporcionalmente ao sinal modulante. Isso significa que frequência da portadora é alterada de modo contínuo a cada instante.

A frequência instantânea, portanto, é para um ângulo $\theta(t)$ sua tangente em algum instante t . No entanto, em torno do instante t , num intervalo pequeno ($\Delta t \rightarrow 0$) a tangente coincide com ângulo da reta $\omega_c t + \theta$, o qual representa o ângulo generalizado de uma senoíde $\varphi(t) = A \cos(\omega_c t + \theta)$ como apresentado pela Figura 32.

Em um intervalo Δt , a frequência angular de $\varphi(t)$ é ω_c . Como $(\omega_c t + \theta)$ tangencia $\theta(t)$, a frequência angular de $\varphi(t)$ é a inclinação de seu ângulo $\theta(t)$ neste pequeno intervalo. Assim, a frequência angular instantânea e o ângulo generalizado são representados pelas equações 12 e 13.

Frequência angular instantânea:

$$\omega_i(t) = \frac{d\theta}{dt} \quad (12)$$

Ângulo:

$$\theta(t) = \int_{-\infty}^t \omega_i(\alpha) d\alpha \quad (13)$$




Figura 32 – Conceito de frequência instantânea [44].

As técnicas de modulação, em que o ângulo de uma portadora é variado de alguma forma por um sinal modulante, são conhecidas como Modulação em Ângulo ou Modulação Exponencial. Tendo como possibilidades a Modulação em Fase (PM) e a Modulação em Frequência (FM).

Na modulação em fase (PM), o ângulo $\theta(t)$ varia linearmente com o sinal modulante, $m(t)$:

$$\theta(t) = \omega_c t + \theta_o + k_p m(t) \quad (14)$$

Em que k_p é uma constante e ω_c a frequência portadora. Supondo que $\theta_o = 0$, sem perda de generalidade, o sinal da modulação PM é:

$$\varphi_{PM}(t) = A \cdot \cos[\omega_c t + k_p m(t)] \quad (15)$$

E neste caso, a frequência angular instantânea é dada por:

$$\omega_i(t) = \frac{d\theta(t)}{dt} = \omega_c + k_p \frac{dm(t)}{dt} \quad (16)$$

Observa-se que para modulação em fase (PM) a variação da frequência angular instantânea é linear com a derivada do sinal modulante, $m(t)$.

E caso, a frequência angular instantânea possui variação linear com o sinal modulante, $m(t)$, será, portanto, modulação em frequência (FM). Desta forma, a frequência angular instantânea é:

$$\omega_i(t) = \omega_c + k_f m(t) \quad (17)$$

em que k_f é uma constante.

O ângulo $\theta(t)$ será:

$$\theta(t) = \int_{-\infty}^t [\omega_c + k_f m(\alpha)] d\alpha = \omega_c t + k_f \int_{-\infty}^t m(\alpha) d\alpha \quad (18)$$

E desta forma, o sinal FM será dado por:

$$\varphi_{FM}(t) = A \cdot \cos \left[\omega_c t + k_f \int_{-\infty}^t m(\alpha) d\alpha \right] \quad (19)$$

Por meio da Figura 33 observa-se um sinal FM para $m(t)$ é equivalente a um sinal PM para $\int_{-\infty}^t m(\alpha)$. Da mesma forma que uma onda PM para $m(t)$ corresponde a um sinal FM para $\frac{dm(t)}{dt}$. Por isso, ambos os casos são identificados como Modulação em Ângulo. Em PM, o ângulo é diretamente proporcional a $m(t)$ enquanto em FM é proporcional à integral de $m(t)$.

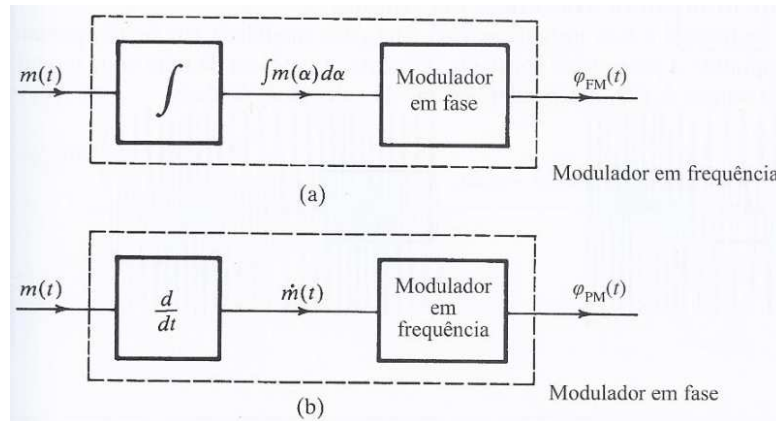


Figura 33 – Relações entre as modulações PM e FM: (a) FM (b) PM [44].

Sendo assim, a portadora com modulação em ângulo será:

$$\varphi_{EM}(t) = A \cdot \cos \left[\omega_c t + k_f \int_{-\infty}^t m(\alpha) h(t - \alpha) d\alpha \right] \quad (20)$$

Onde $h(t) = k_p \delta(t)$ para PM e $h(t) = k_p u(t)$ para FM [43,44].

O processo básico de demodulação é ilustrado na Figura 34 considerando a modulação em ângulo generalizado.




Figura 34 – Processo básico de demodulação em ângulo [44].

O melhor desempenho é alcançado não com cada modulação individualmente, mas sim conjuntamente.

As Figuras 35 e 36 ilustram para fins de exemplificação as características da modulação em ângulo nas perspectivas FM e PM.

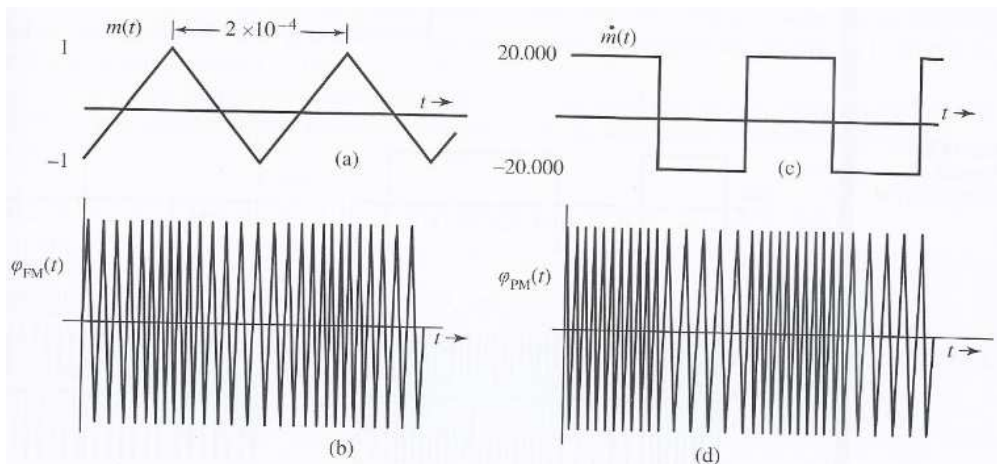


Figura 35 – (a) Sinal modulante (b) derivada do sinal modulante (c) sinal FM (d) sinal PM [44].

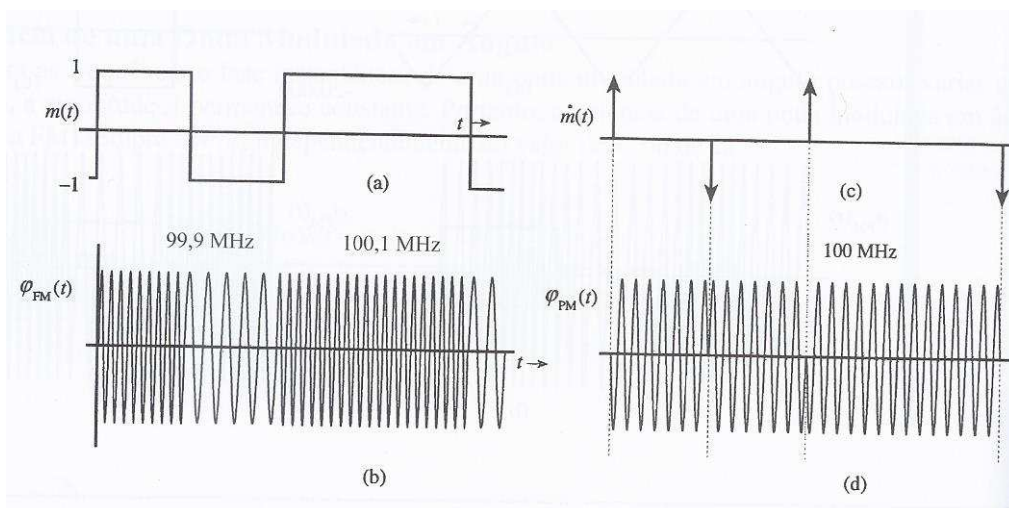


Figura 36 – (a) Sinal modulante (b) derivada do sinal modulante (c) sinal FM (d) sinal PM [44].

Nota-se que para sinal modulante $m(t)$ seja descontínuo, o sinal PM sofrerá mudanças bruscas de fase e por consequência $\frac{dm(t)}{dt}$ possuirá impulsos.

Nesta seção os princípios de modulações foram apresentados para ilustrar como a trinca pode ser considerada um emissor e o sensor como um receptor. Nesta analogia o corpo de prova se torna o meio de transmissão e o sinal de emissão acústica (EA), o sinal a ser transmitido. Como também o processo de emissão acústica visualizado por um sistema que transforma as variáveis de entrada, pressão hidrostática e características da ciência dos materiais na descontinuidade da trinca, em variáveis de saída, um sinal acústico (sinal EA). Neste contexto, os ruídos são provenientes da emissão de sinais de outras fontes no corpo de prova e a distorção do meio (duto) até o sensor.

2.14 Redes Neurais Artificiais

Nesta seção são apresentados conceitos envolvendo Redes Neurais como ferramenta para a aplicação da metodologia.

As Redes Neurais Artificiais (RNA), ou simplesmente Redes Neurais, possuem a capacidade de tratar as não linearidades intrínsecas de problemas cotidianos e estão inseridas dentro da área de Sistemas Inteligentes (Conexionistas) ou Inteligência Computacional (IC). Esta área é composta por outras técnicas, como sistemas *fuzzy*, computação evolutiva, inteligência coletiva, sistemas imunológicos artificiais e agentes inteligentes [45].

As redes neurais possuem elevadas habilidades em mapear sistemas não lineares por meio da aprendizagem dos comportamentos envolvidos. A partir de medições (medidas, amostras ou padrões) obtidas, as redes se tornam modelos computacionais com capacidade de aquisição e manutenção do conhecimento baseado em informações das medições. Podem, portanto, serem definidas como um conjunto de unidades de processamentos (neurônios artificiais) interligados por interconexões (vetores e matrizes – pesos sinápticos).

Desta forma, as redes neurais possuem as seguintes características mais relevantes [45,46]:

- a) Adaptação por experiência: as adaptações dos parâmetros internos da rede (pesos sinápticos) são devidas ao treinamento da rede que caracterizam o comportamento do processo.
- b) Capacidade de aprendizado: a capacidade é dada pela extração de relacionamentos entre as variáveis pelos métodos de aprendizagem.
- c) Habilidade de generalização: a estimação de soluções é obtida pela generalização do conhecimento adquirido no treinamento.
- d) Organização de dados: a organização interna para o agrupamento de padrões baseado nas características intrínsecas de determinado conjunto de informações.
- e) Tolerância a falhas: quando a estrutura interna da rede é sensivelmente corrompida, a tolerância é devida às interconexões entre os neurônios.
- f) Armazenamento distribuído: o conhecimento adquirido está distribuído entre as sinapses.

Diante das características apresentadas, as redes neurais podem ser aplicadas em [45,46]:

- a) Aproximador Universal de Funções: mapear o relacionamento funcional entre variáveis de um sistema a partir de um conjunto de valores.
- b) Controle de Processos: identificar as ações de controle que permitam o alcance dos requisitos de qualidade e eficiência do processo.
- c) Reconhecimento/Classificação de padrões: associar um padrão de entrada (amostra) para uma das classes previamente definidas.

- d) Agrupamento de dados (Clusterização): identificação e detecção de similaridades e particularidades entre os diversos padrões de entrada a fim de possibilitar seu agrupamento (*clusters*).
- e) Sistemas de Previsão: estimação de valores futuros de um processo em consideração as medidas prévias observadas em seu domínio.
- f) Otimização de Sistemas: minimizar ou maximizar uma função custo (objetivo) com restrições para a definição do problema.
- g) Memória Associativa: recuperar padrões a partir de elementos incertos e/ou imprecisos.

Uma rede neural pode ser dividida em três partes:

- a) Camada de entrada: composta por neurônios que receberam os dados de entrada (amostras, padrões de sinais, características ou medições).
- b) Camadas escondidas (intermediárias ou ocultas): compostas por neurônios que possuem a função de extrair as características associadas ao processo ou sistema em análise.
- c) Camada de saída: composta por neurônios responsáveis pela produção e apresentação dos resultados finais.

O processo de treinamento de uma rede consiste da aplicação de uma rotina (algoritmo de aprendizagem) para sintonização dos pesos sinápticos e limiares dos neurônios. O objetivo final é alcançado pela generalização de soluções a serem produzidas na camada de saída para representar o sistema físico em análise. Durante o processo de treinamento da rede, cada apresentação completa das amostras pertencentes ao subconjunto de treinamento é denominada época de treinamento.

Existem dois tipos de treinamentos [45,46]:

- a) Treinamento Supervisionado (com professor): a estratégia consiste em ter a disposição da rede um conjunto de dados de entrada associado a um conjunto de dados de saída (conjuntos de amostras de treinamento). No treinamento supervisionado os parâmetros livres da rede são ajustados em função de conhecer a priori quais são as saídas desejadas ao sistema.
- b) Treinamento Não Supervisionado (sem professor): a estratégia consiste em deixar a própria rede se auto-organizar em relação às particularidades existentes entre os elementos do conjunto de entrada identificando subconjuntos (*clusters*).

Durante o treinamento, a rede não necessariamente realiza simetria de dados e a saída do neurônio pode representar a estrutura funcional que o mesmo assumiu representar durante o treinamento. Desta forma, estruturas distintas podem ser modeladas pela rede onde cada neurônio se torna responsável por uma carga de modelagem.

Para fins de exemplificação do supracitado, suponha que uma rede neural simule o comportamento do circuito lógico XOR, ilustrado na Figura 37(c). Observa-se que o circuito lógico XOR em questão pode ser equivalente a outros dois circuitos lógicos apresentados na Figura 37(a,b).




Figura 37 – Circuito Lógico XOR(c) e circuitos equivalentes (a,b).

Se uma a rede neural com duas camadas tendo dois neurônios a 1ª camada e um neurônio a 2ª camada conforme ilustrado na Figura 38 for treinada para simular o circuito XOR este poderá assumir duas das opções de circuitos equivalentes - Figura 37(a) ou Figura 37(b). Pois, a rede neural poderá assumir para representar o mesmo modelo final conforme treinamento. Neste caso ilustrativo, ao comparar as Figuras 37(a,b) com a Figura 38, nota-se que os neurônios representariam componentes lógicos distintos com o intuito de gerar o circuito equivalente.

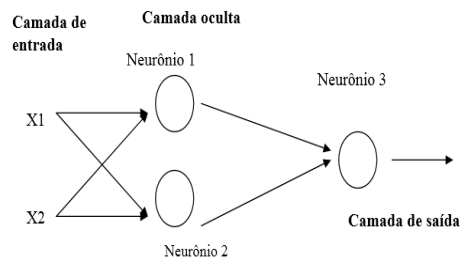


Figura 38 – Rede Neural²⁸.

Existem quatro princípios para a representação do conhecimento numa rede neural [46]:

- a) Entradas de classes similares normalmente devem produzir representações similares no interior da rede e conseqüentemente pertencem a mesma categoria.
- b) Atribuições diferentes na rede neural em itens que pertencem a classes separadas.
- c) Se uma característica é importante então a representação da mesma será realizada por um número maior de neurônios envolvidos na rede neural.
- d) A informação prévia e invariâncias devem ser incorporadas no projeto da rede neural para simplificar e otimizar o aprendizado.

²⁸ <http://www.ica.ele.puc-rio.br>

Como afirmado anteriormente, uma rede neural aprende por meio do seu ambiente através do processo iterativo de ajustes aplicados a seus pesos sinápticos e limiares (bias). Durante este processo, os parâmetros livres de uma rede neural são adaptados através de um processo de estimação pelo ambiente no qual a rede está inserida. Portanto, o tipo de aprendizagem é decorrente pelo modo no qual a alteração dos parâmetros ocorre com base nos seguintes pontos: a rede neural é estimulada pelo ambiente; a rede modifica seus parâmetros conforme estimulação e a rede responde o ambiente conforme modificação na sua estrutura interna [46].

A aprendizagem aplicada neste estudo consiste na Aprendizagem por Correção de Erro, onde um sinal de erro estimula uma sequência de ajustes corretivos aos pesos sinápticos dos neurônios. Estes ajustes corretivos são projetados para aproximar passo a passo o sinal de saída da resposta desejada. O objetivo é alcançado minimizando uma função de custo (índice de desempenho ou valor da energia do erro). Desta forma, o ajuste feito em um peso sináptico de um neurônio é proporcional ao produto do sinal de erro pelo sinal de entrada da sinapse proporcionando o ajuste.

O neurônio é uma unidade de processamento de informação na operação da rede neural e formado pelos seguintes elementos:

- a) Sinapses (elos de conexão): representam os pesos (\mathbf{W}_{ji}) dos componentes do sinal de entrada (\mathbf{Y}_i) no neurônio.
- b) Potencial de Ativação (campo local induzido): combinador linear (junção aditiva, \mathbf{I}_j) para somar os sinais de entrada ponderados pelas respectivas sinapses entre as camadas (L) e (L-1):

$$I_j^{(L)} = \sum_{i=1}^n W_{ji}^{(L)} \cdot Y_i^{(L-1)} \quad (19)$$

- c) Função de Ativação: função restritiva para a amplitude de saída (\mathbf{Y}_j) em função do potencial de ativação e do bias.

$$Y_j^{(L)} = g(I_j^{(L)}) \quad (20)$$

As funções utilizadas como funções de ativação g neste estudo são a tangente hiperbólica e a linear.

- d) Nível de bias: transformação afim na saída do combinador linear (efeito de acréscimo ou decréscimo da entrada da função de ativação).

2.14.1 Rede Supervisionada

Esta seção apresenta os conceitos básicos de uma rede neural supervisionada conhecida como *Rede Perceptron de Múltiplas Camadas*. A rede híbrida proposta pela metodologia deste trabalho utiliza como base operacional este modelo de rede.

Rede Perceptron de Múltiplas Camadas

A rede *Perceptron de Múltiplas Camadas* (PMC) pertence à arquitetura *feedforward* de camadas múltiplas, cujo treinamento é realizado de forma supervisionada.

A Figura 39 apresenta uma típica rede PMC com topologia $n_1:n_2:n_3$, uma rede alimentada adiante com n_1 nós de fonte, n_2 neurônios na primeira camada oculta, n_3 neurônios na camada de saída.

A rede é classificada como *totalmente conectada*, pois cada um dos nós de uma camada da rede neural está conectado (via conexões sinápticas) a todos os nós da camada seguinte conforme apresentado na Figura 39.

Na estrutura desta rede, os elementos estruturais e de conexão são:

- a) $\mathbf{W}_{ji}^{(L)}$ é a matriz de pesos sinápticos entre a camada (L) e a camada (L-1).
Ou seja, o elemento $w_{ij}^{(L)}$ representa o valor do peso sináptico conectado o j -ésimo neurônio da camada (L) ao i -ésimo neurônio da camada (L-1).
- b) $\mathbf{I}_j^{(L)}$ é o vetor de entrada na camada (L).
- c) $\mathbf{Y}_j^{(L)}$ é o vetor de saída de saída da camada (L).




Figura 39 – Rede PMC [45].

O processo de treinamento de rede PMC é por meio do algoritmo *backpropagation* realizado mediante aplicações de duas fases específicas:

- a) 1ª fase – Propagação Adiante (*forward*)
- b) 2ª fase – Propagação Reversa (*backward*)

O algoritmo de retropropagação possui em síntese as seguintes etapas básicas para as fases acima com base na Figura 39:

1) 1ª fase – Propagação Adiante (*forward*)

- a) Determinação do Potencial de Ativação da 1ª camada.

$$I_j^{(1)} = \sum_{i=0}^n W_{ji}^{(1)} \cdot X_i \quad (23)$$

- b) Determinação da Função de Ativação da 1ª camada.

$$Y_j^{(1)} = g(I_j^{(1)}) \quad (24)$$

- c) Determinação do Potencial de Ativação da 2ª camada.

$$I_j^{(2)} = \sum_{i=0}^{n_1} W_{ji}^{(2)} \cdot Y_i^{(1)} \quad (25)$$

d) Determinação da Função de Ativação da 2ª camada.

$$Y_j^{(1)} = g(I_j^{(1)}) \quad (26)$$

e) Determinação do Potencial de Ativação da 3ª camada.

$$I_j^{(3)} = \sum_{i=0}^{n_2} W_{ji}^{(3)} \cdot Y_i^{(2)} \quad (27)$$

f) Determinação da Função de Ativação da 3ª camada.

$$Y_j^{(3)} = g(I_j^{(3)}) \quad (28)$$

2) 2ª fase – Propagação Reversa (*backward*)

a) Determinação do Erro Quadrático.

$$E = \frac{1}{2} \sum_{j=1}^{n_3} [d_j - Y_j^{(3)}]^2 \quad (29)$$

b) Determinação do Gradiente Local da 3ª camada.

$$\delta_j^{(3)} = (d_j - Y_j^{(3)}) \cdot g'(I_j^{(3)}) \quad (30)$$

c) Ajuste dos Pesos Sinápticos da 3ª camada.

$$w_{ji}^{(3)} = w_{ji}^{(3)} + \eta \cdot \delta_j^{(3)} \cdot Y_i^{(2)} \quad (31)$$

d) Determinação do Gradiente Local da 2ª camada.

$$\delta_j^{(2)} = \left[\sum_{k=1}^{n_3} (\delta_k^{(3)} \cdot w_{jk}^{(3)}) \right] \cdot g'(I_j^{(2)}) \quad (32)$$

e) Ajuste dos Pesos Sinápticos da 2ª camada.

$$w_{ji}^{(2)} = w_{ji}^{(2)} + \eta \cdot \delta_j^{(2)} \cdot Y_i^{(1)} \quad (33)$$

f) Determinação do Gradiente Local da 1ª camada.

$$\delta_j^{(1)} = \left[\sum_{k=1}^{n_2} (\delta_k^{(2)} \cdot w_{ji}^{(2)}) \right] \cdot g'(I_j^{(1)}) \quad (34)$$

g) Ajuste dos Pesos Sinápticos da 1ª camada.

$$w_{ji}^{(1)} = w_{ji}^{(1)} + \eta \cdot \delta_j^{(1)} \cdot X_i \quad (35)$$

onde η é o taxa de aprendizagem e g' é a derivada da função g .

2.14.2 Rede Não Supervisionada

Esta seção apresenta os conceitos básicos de dois métodos não supervisionados conhecidos como *K-means* e *Kohonen*. A partir dos resultados da rede híbrida, o estudo utiliza estes métodos para avaliar a classificação dos parâmetros propostos pela rede em classes de propagação da trinca.

A análise de classes (*cluster*) está relacionada ao agrupamento ou separação de uma coleção de objetos em subconjuntos, *clusters*, de forma que os elementos pertencentes a um mesmo *cluster* estejam mais relacionados do que os pertencentes a outro [46].

Desta forma, o processo consiste em examinar um conjunto de “pontos” e agrupá-los em *clusters* de acordo com alguma medida de distância (similaridade). No final objetivo é de que pontos em um mesmo *cluster* sejam próximos uns dos outros e pontos em diferentes *clusters* sejam distantes.

Método de K-means

O algoritmo do *K-means* (K-médias) é um método utilizado para encontrar *clusters* e os centros de *clusters* a partir de um conjunto de dados sem classificação prévia. O

parâmetro "K" se refere ao número de centros no qual se deseja que os dados sejam agrupados. O valor de "K" pode ser determinado por tentativa e erro e o elemento principal do algoritmo está em atribuir iterativamente cada ponto, diferente dos "K" selecionados, ao *cluster* mais próximo, onde “próximo” significa próximo ao centro do *cluster* [45,46].

O diagrama da Figura 40 ilustra os passos do algoritmo. Pelo qual se observa que, pela inicialização aleatória dos centros, os *clusters* 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 ocorrem mais mudanças dos centros. Ou seja, os centros são atualizados para buscar os melhores posicionamentos para representarem e identificarem seus agrupamentos (*clusters*) [45,46].




Figura 40 – Princípio do algoritmo *K-means*.

Método de Kohonen

Os mapas auto-organizáveis de *Kohonen* (SOM: *Self-Organization Maps*) são considerados uma arquitetura de redes neurais de estrutura reticulada com aprendizagem competitiva. Possuem a capacidade de detectar similaridades, regularidades e correlações entre padrões do conjunto de dados agrupando-os em *clusters*.

O princípio básico do processo de aprendizagem competitivo é a concorrência entre os neurônios. Uma das medidas mais utilizada consiste em determinar o nível de proximidade existente entre o vetor de pesos de cada neurônio em relação ao vetor de entrada contendo os elementos da amostra. Uma métrica de proximidade utilizada é a distância euclidiana (norma euclidiana).

Após a convergência do algoritmo competitivo, cada um dos vetores de pesos dos neurônios está posicionado nos centros dos aglomerados (*clusters*) de características comuns representando classes.

Este método pode ser visto com uma versão restrita do algoritmo de *K-means*, na qual as entradas são influenciadas 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 coordenadas (bidimensional) [46].

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 método é particularmente útil quando existe um mapeamento não linear inerente ao próprio problema.

Pelo exposto, 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 [46].

Conclui-se que um SOM pode ser interpretado como uma rede neural *feedforward* de uma única camada, onde cada neurônio está conectado a todos os nós de entrada. Geralmente, os neurônios estão arranjados em linhas e colunas de modo a formar uma grade, como ilustrado na Figura 41.

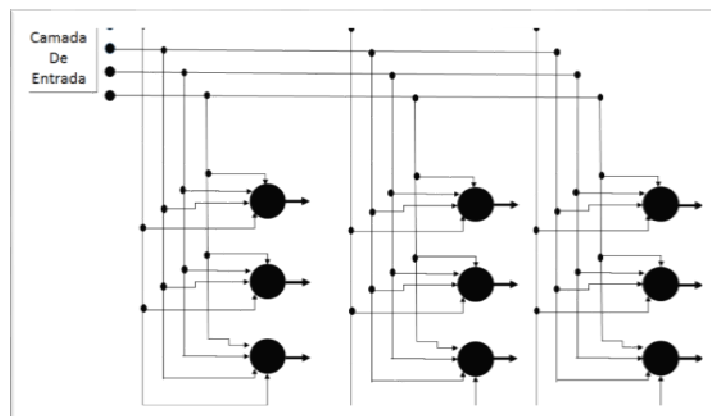


Figura 41 – Grade de neurônios de duas dimensões com quatro entradas e nove neurônios (mapa 3x3).

O algoritmo responsável pela formação do SOM pode ser descrito de acordo com o diagrama representado na Figura 42.




Figura 42 – Algoritmo de formação do SOM.

Como visto nesta seção, as redes neurais encontram aplicações em campos diversos – modelagem, análises de séries temporais, reconhecimentos de padrões, processamento de sinais e controle – devida a sua habilidade de aprender a partir de dados de entrada com ou sem professor, treinamento supervisionado e não supervisionado respectivamente.

Ou seja, uma rede neural é um sistema paralelamente distribuído constituído de elementos simples que possuem a habilidade natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Então, o conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem, por onde as conexões entre os neurônios (pesos sinápticos) são utilizados para armazenar conhecimento.

Por isso, as redes neurais são utilizadas para modelar o princípio das modulações analógicas para compor o sinal de emissão acústica (EA).

3 METODOLOGIA

3.1 *Princípios da Metodologia*

O plano de trabalho de estudo desenvolvido possui, resumidamente, as seguintes etapas:

1. Acompanhamento da montagem e realização dos ensaios experimentais com defeitos inseridos artificialmente (trincas) em corpos de provas rígidos (dutos) pressurizados do projeto de pesquisa (P&D), “*Monitoração de Defeitos em Dutos Rígidos por Redes Neurais*”²⁹.
2. Processamento e análise dos sinais – formas de ondas e parâmetros – captados pelos sensores para avaliação do comportamento da trinca e da propagação de onda de emissão acústica.
3. Aplicação do modelo de rede neural especializada, denominada rede neural híbrida, com base no treinamento supervisionado de uma estrutura que utiliza o princípio de superposição de modulações analógicas em sua arquitetura.
4. Aplicação de classificadores (não supervisionados) para separação dos dados nas classes de propagação: Sem Propagação (SP), Propagação Estável (PE) e Propagação Instável (PI).

A Figura 43 ilustra o processo do plano de trabalho que consiste na metodologia proposta conforme citado anteriormente. Pelo qual, os ensaios experimentais – detalhado no capítulo 4 – fornecem dados do fenômeno de Emissão Acústica (EA) – discutido no capítulo 2. Os referidos dados aplicados na rede neural híbrida permitem a estimação dos parâmetros das portadoras. Pois, a rede neural híbrida possui a arquitetura

²⁹ Os ensaios analisados são oriundos do projeto de pesquisa entre a COPPE-UFRJ, o LAMEF-UFGRS e o CENPES-PETROBRAS, detalhado no capítulo 4. A tese de doutorado é fundamentada na análise dos dados oriundos deste projeto de pesquisa entre as instituições.

para simular o conceito de superposição das portadoras analógicas – discutido no capítulo 2 – sobre as formas de ondas dos sinais de emissão acústica com base no modelo supervisionado – discutido no capítulo 2.

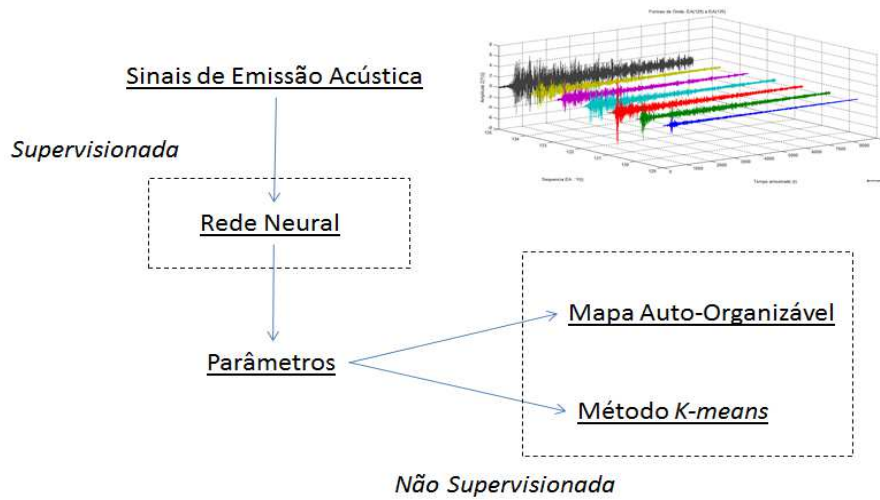


Figura 43 – Metodologia

O estudo parte do princípio que a fonte do sinal é o elemento metalúrgico (descontinuidade) e o ambiente é o duto rígido pressurizado conforme no processo do fenômeno ilustrado no diagrama de eventos da Figura 44.

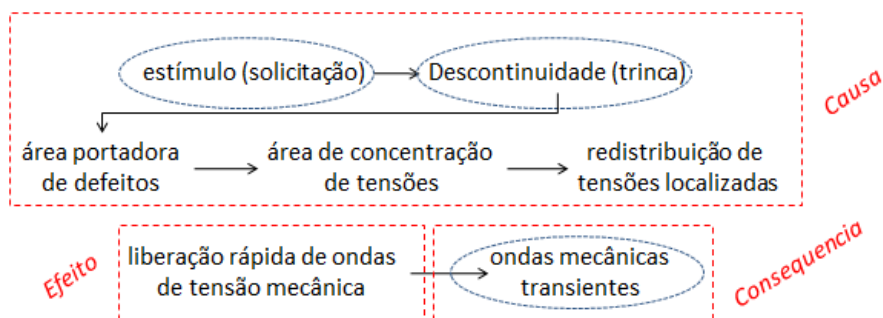


Figura 44 – Diagrama de Processo do Fenômeno de Emissão Acústica.

Por meio desta, observa-se que o estudo do fenômeno possui influência sobre a fase “causa” em dois pontos: no “estímulo (solicitação)”, por meio do controle da pressão

interna durante o ensaio hidrostático e na fase “*descontinuidade (trinca)*”, pelo conhecimento das dimensões da trinca inserida no corpo de prova. A partir, destas influências na fase “*causa*”, obtêm-se elemento “*ondas mecânicas transientes*” na fase “*consequência*”.

O objetivo final é formular novos parâmetros extraídos da forma de onda do sinal de emissão acústica pela rede híbrida para a caracterização dos estados da trinca em “Sem Propagação”, “Propagação Estável” ou “Propagação Instável”. Com isso, viabilizar uma análise do comportamento dinâmico das descontinuidades que permite a inspeção de equipamentos em serviço para avaliar a presença de descontinuidades que possam comprometer sua condição de integridade.

Estes parâmetros das portadoras estimados pela rede neural híbrida constituem um novo grupo de dados sobre a transição entre as formas de ondas de emissão acústica. A aplicação deste conjunto de dados em técnicas não supervisionadas permite a identificação de agrupamentos que representam as classes de propagação da trinca.

Uma vez que entradas de classes similares devem produzir representações similares no interior da rede e, portanto, pertencem a mesma categoria e atribuições diferentes na rede neural em itens que pertencem a classes separadas.

3.2 Modelo Matemático da Rede Neural Híbrida

Um sinal é um conjunto de informação ou dados e, portanto, um sistema processa um sinal por meio de alguma modificação ou extração adicional de alguma informação. Desta forma, um sistema é uma entidade que processa um conjunto de sinais (entradas) para produzir outro conjunto de sinais (saídas).

A modulação analógica altera o formato de um sinal com base em outro pela variação de características definidas conforme apresentado anteriormente.

Na modulação por amplitude em amplitude (AM), o sinal a transmitir (modulador), $m(t)$, influencia a amplitude de uma portadora de frequência f_{am} de modo que a amplitude da portadora varia de forma diretamente proporcional à amplitude do sinal.

Na modulação por fase (PM) ou por frequência (FM) a variação da fase ou da frequência das portadoras de frequências f_{pm} e f_{fm} respectivamente é de forma diretamente proporcional à amplitude do sinal modulador respectivamente.

Com base nestas definições, as equações 36, 37 e 38 ilustram os conceitos para as modulações analógicas, onde $S_m(t)$, K_{am} , K_{pm} e K_{fm} representam o sinal modulado e as constantes de modulação AM, PM e FM respectivamente.

Modulação em Amplitude (AM)

$$S_{m(am)}(t) = (K_{am} + m(t)) \cdot \cos(2\pi \cdot f_{am} \cdot t) \quad (36)$$

Modulação em Fase (PM)

$$S_{m(pm)}(t) = A_{pm} \cdot \cos(2\pi \cdot f_{pm} \cdot t + K_{pm} \cdot m(t)) \quad (37)$$

Modulação em Frequência (FM)

$$S_{m(fm)}(t) = A_{fm} \cos [2\pi(f_{fm} \cdot t + K_{fm} \int_{-\infty}^t m(\alpha) d\alpha)] \quad (38)$$

Diante das informações supracitadas, a Figura 45 ilustra o princípio do modelo da metodologia. Pela qual se observa que o sinal resultante é uma combinação linear dos sinais modulados pelas modulações analógicas.

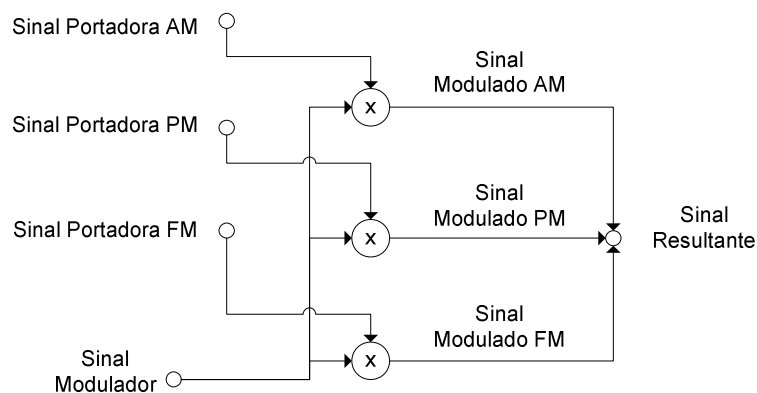


Figura 45 – Modelo da metodologia.

Com base no diagrama da Figura 45, a equação 39 define o sinal resultante $R(t)$ composto por funções $S_{m(i)}(t)$:

$$R(t) \equiv a_0 + \sum_{i=1}^3 a_i S_{m(i)}(t) = \quad (39)$$

$$= a_0 + a_1 S_{m(am)}(t) + a_2 S_{m(pm)}(t) + a_3 S_{m(fm)}(t)$$

Onde, a representação da média do sinal é dada por a_0 . Sendo, a_1 , a_2 e a_3 constantes.

Ao substituir as equações 36, 37 e 38 na definição de $R(t)$ pela equação 39, obtém-se a equação 40:

$$R(t) = a_0 + a_1 [K_{am} + m(t)] \cos(2\pi f_{am} t) + \quad (40)$$

$$+ a_2 A_{pm} \cos[2\pi f_{pm} t + K_{pm} m(t)] + a_3 A_{fm} \cos \left[2\pi \left(f_{fm} t + K_{fm} \int_{-\infty}^t m(\alpha) d\alpha \right) \right]$$

O sinal de emissão acústica (EA), por ser um sinal físico (sinal causal), ocorre somente para $t \geq 0$. Sendo $u(t)$ uma função degrau, a equação 41 representa o modelo físico (MF) da equação 40:

$$MF(t) \cong R(t) \cdot u(t) \cong \quad (41)$$

$$\cong a_0 + a_1 [K_{am} + m(t)] \cos(2\pi f_{am} t) + a_2 A_{pm} \cos[2\pi f_{pm} t + K_{pm} m(t)] +$$

$$+ a_3 A_{fm} \cos \left[2\pi \left(f_{fm} t + K_{fm} \int_0^t m(\alpha) d\alpha \right) \right]$$

Define-se a função $MF(t)$ conforme equação 42. A equação representa o sinal de emissão acústica (EA) – sinal físico – como uma função paramétrica.

$$MF(t) \cong \quad (42)$$

$$\cong a_0 + a_1 F[K_{am}, f_{am}, m(t)] + a_2 F[K_{pm}, f_{pm}, m(t)] + a_3 F[K_{fm}, f_{fm}, m(t)]$$

Observa-se que o modelo da equação 42 pode ser aplicado a qualquer sinal, $MF(t)$, que deseja ser expresso como uma combinação linear das modulações analógicas de um sinal de referência, $m(t)$. As variáveis desta equação são os parâmetros das modulações que definem a equação paramétrica – K_{am} , K_{pm} , K_{fm} , f_{am} , f_{pm} e f_{fm} .

Logo, a rede neural híbrida foi desenvolvida com o objetivo de estimar as constantes da função paramétrica (K e f), uma vez que a variável independente é o tempo (t). Esta estimativa pela rede neural tem como consequência a identificação do comportamento do sinal quanto a sua dinâmica pela amplitude, pela frequência e pela fase na transição entre os elementos de um conjunto de observações – sinais de EA registrados durante o ensaio hidrostático.

Isso apresenta uma nova perspectiva de visão do fenômeno, pois representa uma transformação de sinais amostrados em novo conjunto de menor dimensão. Ou seja, para um conjunto de N sinais – cada um com M pontos amostrados – obtém-se um novo conjunto de $N-1$ sinais – cada um com 6 pontos (K_{am} , K_{pm} , K_{fm} , f_{am} , f_{pm} e f_{fm}).

Por outro prisma, a rede neural híbrida se torna uma transformação matricial – uma matriz $[N \times M]$ se transforma numa matriz $[N-1 \times 6]$.

Diante do supracitado, a Equação 43 apresenta a Equação 42 aplicada à rede neural híbrida neste estudo. Pela qual se observa que para numa sequência de sinais de emissão acústica, um sinal $EA(k)(t)$ será avaliado como uma combinação linear das modulações aplicadas no sinal de emissão acústica anterior $EA(k-1)(t)$.

$$EA^{(K)}(t) \cong a_0 + a_3 F[K_{fm}, f_{fm}, EA^{(K-1)}(t)] + a_2 F[K_{pm}, f_{pm}, EA^{(K-1)}(t)] + a_1 F[K_{am}, f_{am}, EA^{(K-1)}(t)] \quad (43)$$

A Figura 46 ilustra as equações das modulações analógicas em frequência, em fase e em amplitude, nesta ordem, na forma fluxo de sinais em grafo. Estes fluxos representam as funções que compõem a Equação 42.

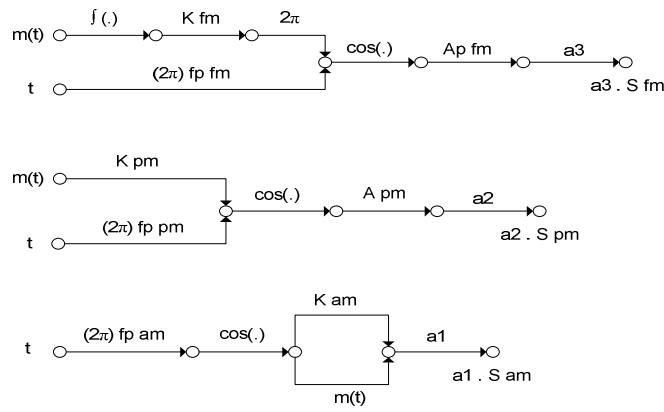


Figura 46 – Modelo grafo de fluxo de sinais.
 Parte Superior: $a_3 F[K_{fm}, f_{fm}, m(t)]$ – Parte Central: $a_2 F[K_{pm}, f_{pm}, m(t)]$ – Parte Inferior: $a_1 F[K_{am}, f_{am}, m(t)]$

Como descrito, estes modelos em grafo representam as modulações presentes na Equação 42, ou seja, apresenta a descrição funcional dos elementos que constituem o modelo grafo de fluxo de sinais, estrutura interna básica da rede neural híbrida desenvolvida.

O termo a_0 presente na Equação 43 é desconsiderado na estruturação da rede neural, pois nos estudos estatísticos dos sinais de emissão acústica (EA) captados, a média (valor esperado) tende a zero. Desta forma, o modelo computacional da rede híbrida será realizado com base na Equação 44.

Ou seja,

$$EA^{(K)}(t) \cong \begin{bmatrix} a_3 \\ a_2 \\ a_1 \end{bmatrix}^T \begin{bmatrix} F[K_{fm}, f_{fm}, EA^{(K-1)}(t)] \\ F[K_{pm}, f_{pm}, EA^{(K-1)}(t)] \\ F[K_{am}, f_{am}, EA^{(K-1)}(t)] \end{bmatrix} \quad (44)$$

3.3 Modelo Computacional da Rede Neural Híbrida

As redes neurais possuem elevadas habilidades em mapear sistemas não lineares. A partir de medições (medidas, amostras ou padrões) obtidas, as redes se tornam modelos computacionais com capacidade de aquisição e manutenção do conhecimento baseado em informações das medições.

A Figura 47 apresenta uma visão da estrutura das modulações em blocos funcionais na rede neural híbrida com base no fluxo de sinais da Figura 46 e do modelo da metodologia ilustrado na Figura 45.

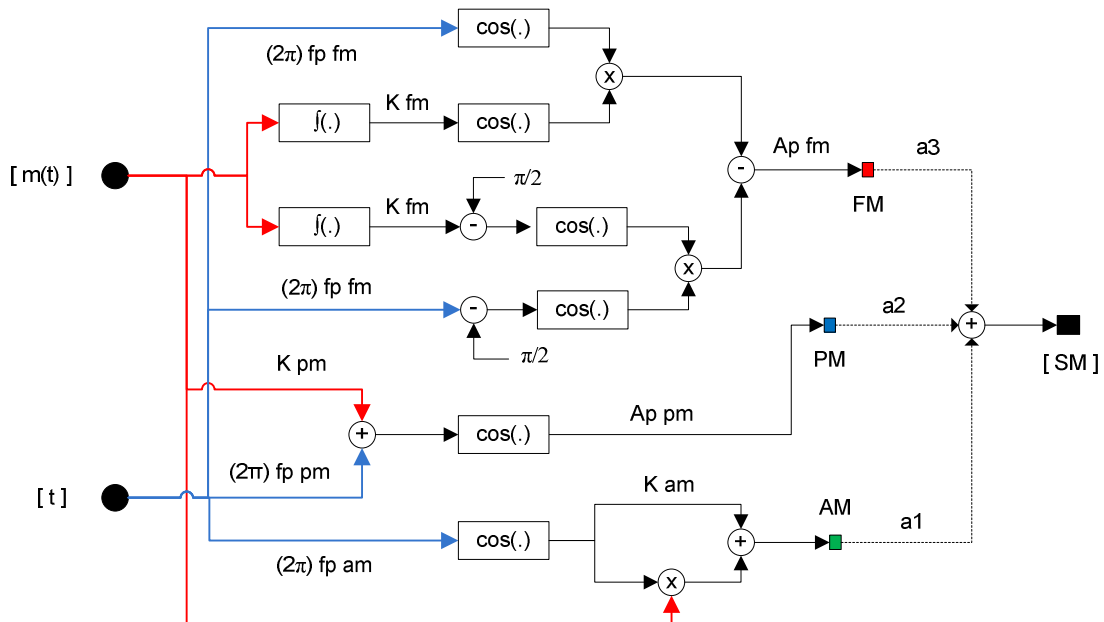


Figura 47 – Rede Neural Híbrida.

A estrutura da metodologia da rede híbrida apresentada na Figura 47 é uma rede parcialmente conectada com os seguintes elementos estruturais:

- a) sinal de contexto: sinal de entrada, $m(t)$.
- b) sinal de entrada: tempo (t).
- c) nós computacionais: redes neurais que representam blocos funcionais.
- d) elos de comunicação: conexão entre os nós computacionais (sinapses da rede híbrida).

Nota-se que algumas informações prévias e invariâncias estão incorporadas no projeto da rede neural híbrida para simplificar e otimizar o aprendizado. Sendo assim, o armazenamento é distribuído, pois o conhecimento adquirido está distribuído entre as sinapses.

A capacidade de aprendizado é dada pela extração de relacionamentos entre as variáveis pelo método de aprendizagem aplicado em toda a rede neural híbrida. Assim, os blocos funcionais possuem a aplicação de um aproximador universal de funções: mapear o relacionamento funcional entre variáveis de um sistema a partir de um conjunto de valores.

Na rede neural, múltiplos neurônios estão interligados para formar uma rede distribuída. A configuração destas interligações (elos computacionais) na rede neural híbrida foi estruturada como base no grafo direcionado para a definição da topologia.

Na rede neural híbrida cada bloco neural – nó computacional – se torna responsável por uma carga do processamento – partes internas da estrutura da rede híbrida. Isso permite que a saída de cada bloco apresente a função que o bloco funcional deve representar.

Essa estratégia é baseada no fato de uma rede neural não realizar necessariamente simetria de dados e o aspecto de especificação topológica da rede possui como base o teorema da aproximação universal (teorema de Kolmogorov), o qual fornece a premissa necessária para definir as configurações estruturais dos blocos neurais como “funcionais” na rede híbrida (aproximação de funções analíticas).

A Figura 48 ilustra a estrutura computacional da rede híbrida, por meio desta é possível considerar uma rede de 4 camadas com características de rede de entradas atrasadas no tempo, pois o sinal de contexto e o sinal de entrada devem possuir a mesma dimensão. Onde cada rede neural é nó computacional e as ligações entre eles são os elos de comunicação.

As camadas foram estruturadas para auxiliar o funcionamento do algoritmo desenvolvido e as estruturas de cada rede neural foram determinadas por sugestão do autor e avaliação de desempenho quando alteradas tanto em relação a quantidades de neurônio como de quantidades de camadas.

Por fim, a estrutura escolhida é composta por:

- 1) 1ª camada com três redes neurais 2:2:1
- 2) 2ª camada com duas redes neurais 2:2:1 e uma rede neural 2:1
- 3) 3ª camada com dois neurônios
- 4) 4ª camada com um neurônio

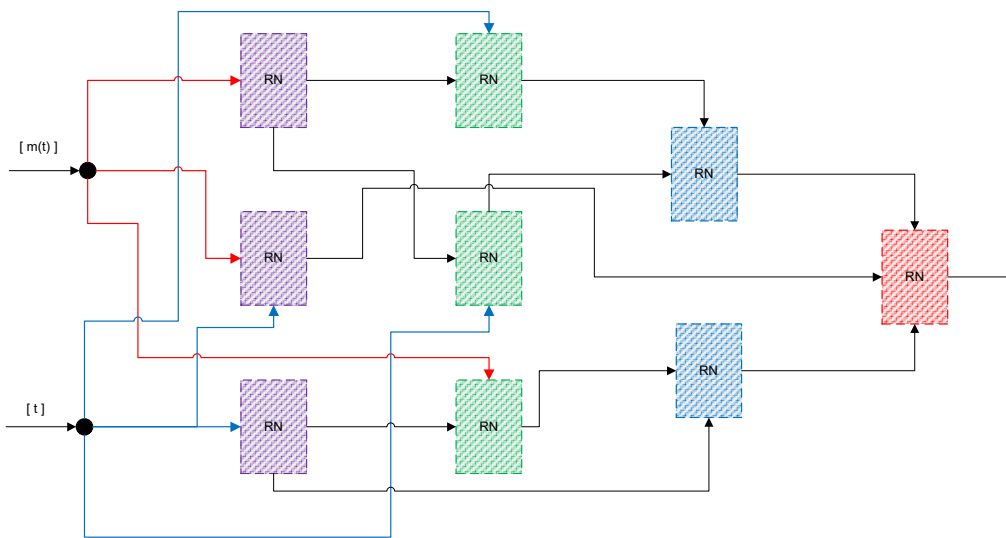


Figura 48 – Estrutura Computacional da Rede Híbrida apresentando os nós computacionais e os elos de computacionais.

O algoritmo foi estruturado conforme o princípio de funcionamento das Redes Neurais *Feedforward* (Redes *Perceptron* Multicamadas), onde cada neurônio é constituído por duas partes: função potencial de ativação e função de ativação. A função potencial de ativação determina como as entradas da rede são combinadas no interior do neurônio conforme os pesos sinápticos e a função de ativação fornece a saída do neurônio.

A implementação do algoritmo de treinamento *backpropagation* – Gradiente Descendente – é realizada em toda a rede híbrida por ramos – elos de comunicação – que representam as modulações e também nas redes neurais internas – nós computacionais – em síntese por meio das Equações 23 a 35. Após o treinamento, as sinapses da rede neural híbrida fornecem os parâmetros das portadoras que constituem o sinal por meio da malha de conexões (sinapses).

Logo, a rede neural híbrida pode ser vista um primeiro plano como uma rede neural, conforme ilustrado na Figura 48, com as seguintes matrizes de pesos sinápticos e vetores de entrada:

$$W^{(1)} \begin{bmatrix} w_{11} & 0 \\ w_{12} & w_{22} \\ 0 & w_{32} \end{bmatrix} \quad X^{(1)} \begin{bmatrix} m(t) \\ t \end{bmatrix} \quad (44)$$

$$W^{(2)} \begin{bmatrix} 0 & w_{12} & w_{13} & 0 \\ 0 & 0 & w_{23} & 0 \\ w_{31} & 0 & 0 & w_{34} \end{bmatrix} \quad X^{(2)} \begin{bmatrix} m(t) \\ t \\ Y_{RN1} \\ Y_{RN3} \end{bmatrix} \quad (45)$$

$$W^{(3)} \begin{bmatrix} w_{11} & w_{12} & 0 & 0 \\ 0 & 0 & w_{23} & w_{24} \end{bmatrix} \quad X^{(3)} \begin{bmatrix} Y_{RN4} \\ Y_{RN5} \\ Y_{RN6} \\ Y_{RN3} \end{bmatrix} \quad (46)$$

$$W^{(4)} [w_{11} \quad w_{12} \quad w_{13}] \quad X^{(4)} \begin{bmatrix} Y_{RN7} \\ Y_{RN8} \\ Y_{RN2} \end{bmatrix} \quad (47)$$

Onde:

$Y_{RN(c)}$: saída do nó computacional (rede neural interna c).

$X^{(L)}$: entrada na camada L externa (entrada na camada de nó computacional).

w_{ji} : elo de comunicação (sinapse da rede neural híbrida).

A Figura 49 apresenta a arquitetura da rede híbrida detalhada, pois ilustra a combinação dos conceitos apresentados pelas Figuras 47 e 48.

REDE HÍBRIDA ($2N:n_1=3:n_2=2:n_3=1:n_4=2$)

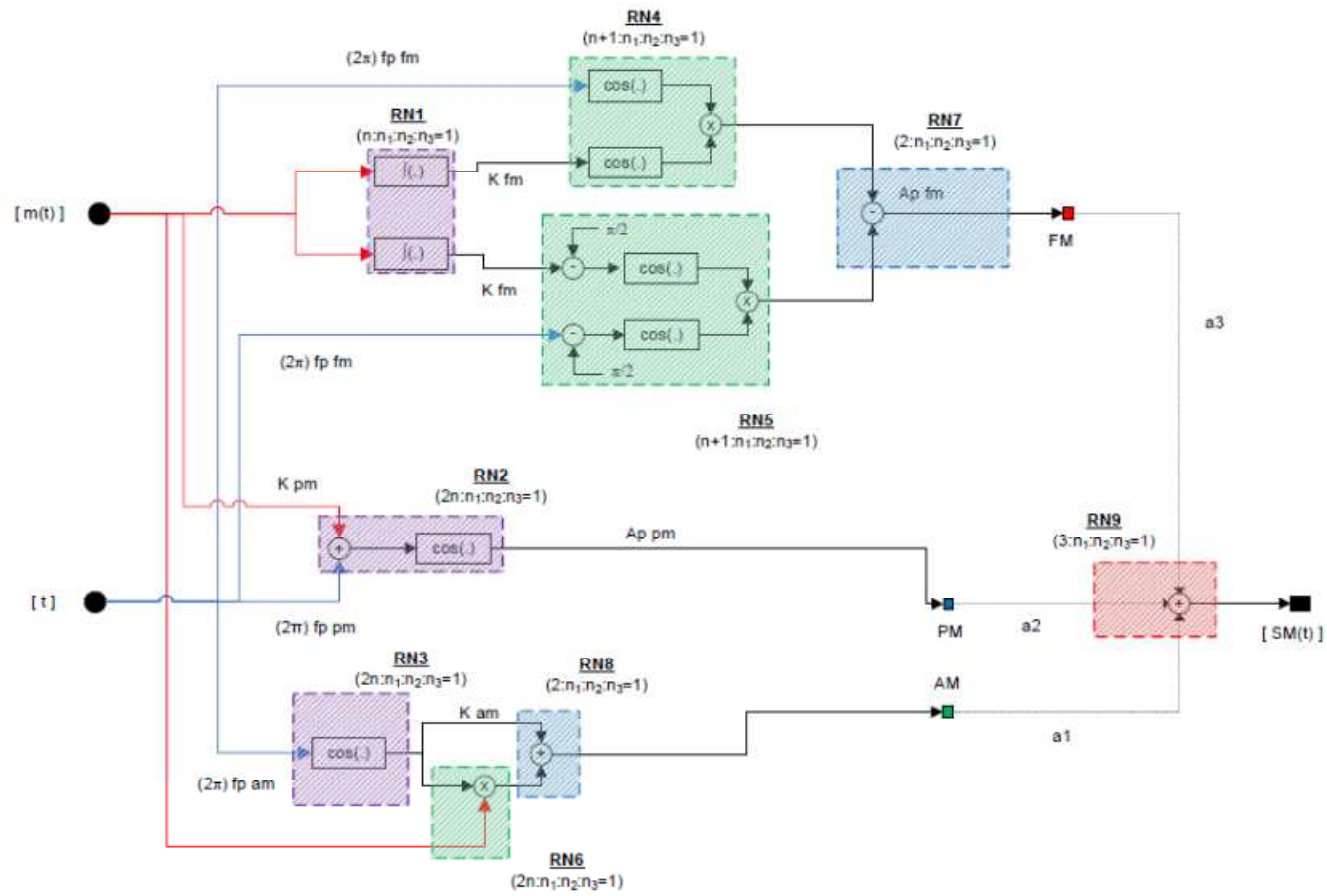


Figura 49 – Rede Neural Híbrida

Em suma, o algoritmo de treinamento supervisionado *backpropagation* foi aplicado na rede neural híbrida (Figura 49) com a seguinte lógica:

- 1) 1ª fase – Propagação Adiante (*forward*)
 - a) Determinação do Potencial de Ativação da 1ª camada externa.
 - b) Determinação da Função de Ativação da 1ª camada externa.
 - c) Aplicação da fase de Propagação Adiante nas Redes Neurais Internas (L1)
 - i) Nó Computacional 1 (Rede Neural 1).
 - ii) Nó Computacional 2 (Rede Neural 2).
 - iii) Nó Computacional 3 (Rede Neural 3).
 - d) Determinação do Potencial de Ativação da 2ª camada externa.
 - e) Determinação da Função de Ativação da 2ª camada externa.
 - f) Aplicação da fase de Propagação Adiante nas Redes Neurais Internas (L2)
 - i) Nó Computacional 4 (Rede Neural 4).
 - ii) Nó Computacional 5 (Rede Neural 5).
 - iii) Nó Computacional 6 (Rede Neural 6).
 - g) Determinação do Potencial de Ativação da 3ª camada externa.
 - h) Determinação da Função de Ativação da 3ª camada externa.
 - i) Aplicação da fase de Propagação Adiante nas Redes Neurais Internas (L3)
 - i) Nó Computacional 7 (Rede Neural 7).
 - ii) Nó Computacional 8 (Rede Neural 8).
 - j) Determinação do Potencial de Ativação da 4ª camada externa.
 - k) Determinação da Função de Ativação da 4ª camada externa.
 - l) Aplicação da fase de Propagação Adiante na Rede Neural Interna (L4)
 - i) Nó Computacional 9 (Rede Neural 9).
- 2) 2ª fase – Propagação Reversa (*backward*)
 - a) Determinação do Erro Quadrático.
 - b) Aplicação da fase de Propagação Adiante na Rede Neural Interna (L4)
 - i) Nó Computacional 9 (Rede Neural 9).
 - c) Determinação do Gradiente Local da 4ª camada externa.
 - d) Ajuste dos Pesos Sinápticos da 4ª camada externa.
 - e) Aplicação da fase de Propagação Adiante na Rede Neural Interna (L3).
 - i) Nó Computacional 7 (Rede Neural 7).
 - ii) Nó Computacional 8 (Rede Neural 8).

- f) Determinação do Gradiente Local da 3ª camada externa.
- g) Ajuste dos Pesos Sinápticos da 3ª camada externa.
- h) Aplicação da fase de Propagação Adiante na Rede Neural Interna (L2)
 - i) Nó Computacional 4 (Rede Neural 4).
 - ii) Nó Computacional 5 (Rede Neural 5).
 - iii) Nó Computacional 6 (Rede Neural 6).
- i) Determinação do Gradiente Local da 2ª camada externa.
- j) Ajuste dos Pesos Sinápticos da 2ª camada externa.
- k) Aplicação da fase de Propagação Adiante na Rede Neural Interna (L1).
 - i) Nó Computacional 1 (Rede Neural 1).
 - ii) Nó Computacional 2 (Rede Neural 2).
 - iii) Nó Computacional 3 (Rede Neural 3).
- l) Determinação do Gradiente Local da 1ª camada externa.
- m) Ajuste dos Pesos Sinápticos da 1ª camada externa.

Observa-se que rede neural híbrida é assimétrica comparada as estruturas típicas de redes neurais, portanto o treinamento é realizado internamente em cada rede neural que compõe um bloco funcional como em toda rede híbrida por meio da função gradiente local aplicada em cada camada interna e externa do bloco neural e da rede híbrida respectivamente.

A caracterização das portadoras pela rede neural evidencia comportamentos que podem auxiliar no entendimento de fenômenos, pois a análise por meio destas portadoras distribui a informações em aspectos relevantes para as modulações de acordo com sua relevância.

Neste tipo de rede neural a informação desejada não está na saída da rede após o treinamento, mas sim na sua estrutura por meio dos pesos sinápticos que representam os parâmetros das portadoras. A rede neural híbrida apresenta a melhor combinação de AM, PM e FM no aprendizado pela redução do erro médio quadrático – critério de parada no treinamento supervisionado.

Desta forma, um problema complexo de interesse é decomposto em um número de tarefas relativamente simples e atribui-se a redes neurais um subconjunto de tarefas que coincidem com as suas capacidades inerentes.

A rede neural com estrutura especializada normalmente tem um número menor de parâmetros livres disponíveis para ajuste do que uma rede totalmente conectada. A rede especializada requer, portanto um conjunto menor de treinamento de dados para treinamento – aprendizagem mais rápida e melhor generalização. Isso influencia numa melhor taxa de transmissão de informação através da rede especializada e num menor custo de projeto e operação em comparação a uma rede totalmente conectada [46].

Esta aplicação com base na técnica de decomposição do sinal tem o propósito de poder identificar as diferentes classes de acordo com o comportamento da trinca quanto a sua propagação: Sem Propagação (SP), Propagação Estável (PE) e Propagação Instável (PI).

Os sinais de emissão acústica do ensaio consistem num conjunto de observações, $\{Z[Y_i], i \in N\}$, onde o sinal é um conjunto, $\{Y(t), t \in T\}$, e sendo $T = \{t: t_1 < t < t_2\}$ conforme o exemplo visualizado na Figura 50.




Figura 50 – Exemplo de uma família de sinais.

O objetivo torna-se, portanto, compreender diferenças entre os sinais por meio das quais viabilizem apresentar as classes e seus elementos.

A visualização dos subconjuntos permite supor a família de sinais de emissão acústica como famílias de trajetórias de um processo, ou seja, séries temporais de um processo estocástico.

Portanto, os sinais de emissão acústica são avaliados pela rede neural em parâmetros para constituírem uma identificação entre as séries da família.

4 PROCEDIMENTO EXPERIMENTAL

O ensaio hidrostático é fruto do projeto “*Monitoramento de Defeitos em Dutos Rígidos por Emissão Acústica e Redes Neurais*” realizado em parceria entre o Centro de Pesquisas Leopoldo Américo Miguez de Mello (CENPES) da Petrobras S.A. e o Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia (COPPE) da Universidade Federal do Rio de Janeiro (UFRJ) pelo Programa de Engenharia Elétrica (PEE). A execução foi realizada em conjunto com o Grupo de Ensaio Não Destrutivos (GEND) do Laboratório de Metalurgia Física (LAMEF) na Universidade Federal do Rio Grande do Sul (UFGRS).

Para o ensaio foi adotado um sistema parafusado de vedação do tubo, empregando água ao invés de óleo como fluido de pressurização. O sistema também utiliza um tubo interno, reduzindo o volume de fluido necessário para a pressurização da amostra conforme ilustrado na Figura 51, o que diminui o tempo de ensaio hidrostático. As calotas foram usinadas em aço de baixo carbono, utilizando um sistema de vedação com cinco anéis de borracha vinílica com 5 mm de diâmetro (*O’Ring*) [37,38,40,47–53].




Figura 51 – Visualização do sistema de montagem do tubo para o ensaio hidrostático [47].

O corpo de prova pode ser caracterizado como um reservatório cilíndrico de parede fina. Um reservatório cilíndrico é considerado de parede fina se a razão entre o raio (r) e a espessura (e) é maior ou igual a dez ($r/e \geq 10$). Nessa condição, pode-se supor que as tensões se distribuem de maneira uniforme ao longo da espessura do cilindro e assim,

sujeito a uma pressão interna uniforme, maior que a atmosférica (pressão manométrica³⁰).

O quadrilátero pequeno na Figura 52 representa uma porção elementar da parede do cilindro, que sofre ação das tensões: σ_1 ao longo da circunferência e σ_2 no sentido longitudinal. Considera-se uma porção cilíndrica de largura Δx como em A. Se essa porção é cortada diametralmente (B), a tensão σ_1 atua na direção perpendicular às superfícies das extremidades S_1 [47].




Figura 52 – Seção tubular submetida a uma pressão interna - longitudinal [47].

Para a tensão σ_2 , considera-se um corte transversal do cilindro conforme Figura 53. Onde a tensão determinante para o dimensionamento do tubo é σ_1 , ou seja, a tensão no sentido da circunferência do cilindro. As junções paralelas ao eixo do cilindro sofrem tensões iguais ao dobro das tensões em junções ao longo da circunferência. Além das tensões superficiais, reservatórios submetidos a pressões internas estão sujeitos a tensões radiais, que variam do valor da pressão na superfície interna até zero na superfície externa [37,38,40,47–53].

³⁰ A pressão manométrica é a medição da pressão em relação à pressão atmosférica existente no local, podendo ser positiva ou negativa.




Figura 53 – Seção tubular submetida a uma pressão interna - transversal [47].

Os dados utilizados no estudo foram coletados durante a execução de ensaios hidrostáticos nas instalações da UFRGS, pelos quais foi realizado o monitoramento da forma de onda por sensores, pressão interna do corpo de prova e dimensões da trinca [37,38,40,47–53].

Os ensaios com corpo de prova curto (2 metros de comprimento) foram realizados no interior de um *bunker* como ilustrado na Figura 54.



Figura 54 – Preparativos do corpo de ensaio no *bunker* para realização do ensaio hidrostático.

A estrutura do ensaio hidrostático é ilustrada na Figura 55, pela qual é possível visualizar todos os equipamentos utilizados e seu posicionamento relativo a todos os outros elementos presentes.

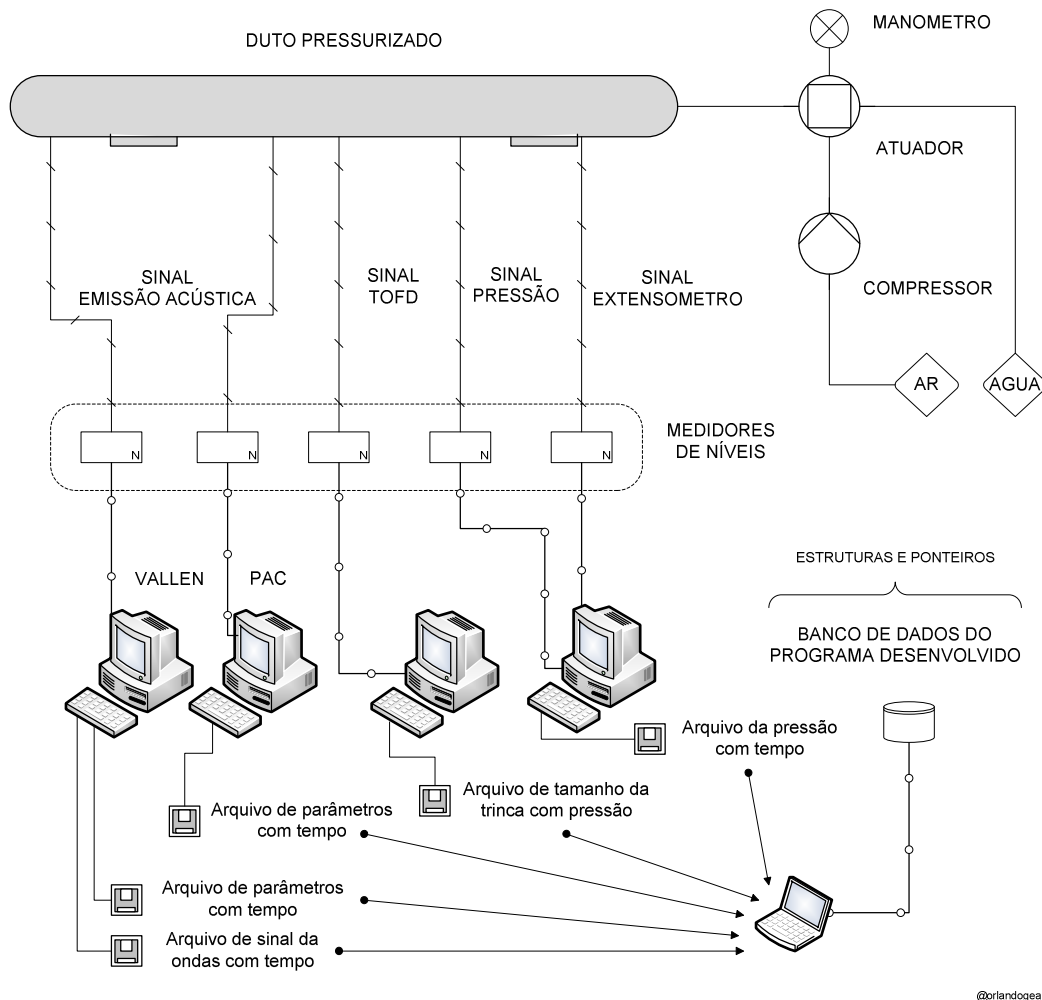


Figura 55 – Estrutura do Ensaio Hidrostático Experimental.

A compilação de todos os dados registrados pelos equipamentos foi realizada de forma estrutural num banco de dados para o Matlab³¹ conforme ilustrado na Figura 56. Isso foi necessário, pois os arquivos disponibilizados pelos equipamentos apresentados na Figura 55 possuem formatos distintos.

³¹ *The Language of Technical Computing* - <http://www.mathworks.com/products/matlab/>

A estrutura de dados contempla todos os registros medidos pelos equipamentos, como também o posicionamento dos sensores e as dimensões do corpo de prova (duto).

Todos os gráficos foram gerados a partir desta estrutura, por meio do programa desenvolvido. Desta forma, ensaios futuros podem ser analisados pelo programa a partir da criação da sua estrutura no banco de dados, apresentado na Figura 56.

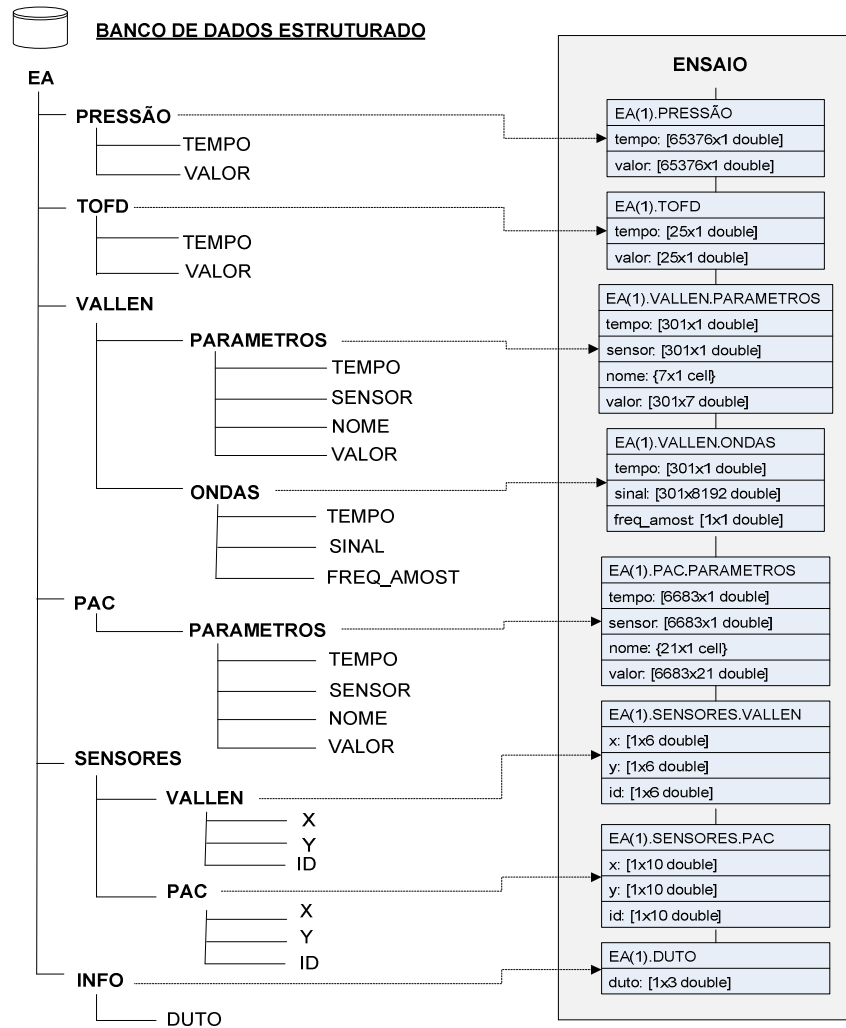


Figura 56 – Estrutura de dados do ensaio.

```
Command Window
-----
UNIVERSIDADE FEDERAL DO RIO DE JANEIRO - UFRJ
INSTITUTO DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA - COPPE
PROGRAMA EM ENGENHARIA ELÉTRICA - PEE
LABORATÓRIO DE PROCESSAMENTO DE SINAIS - LPS
-----
DOUTORADO EM INTELIGÊNCIA COMPUTACIONAL
ESTUDO DE EMISSÃO ACÚSTICA EM DUTOS POR REDES NEURAIAS
AUTOR: ORLANDO GEA
ORIENTADOR: LUIZ PEREIRA CALOBA
COORIENTADOR: ROMEU RICARDO DA SILVA
-----
Site: https://sites.google.com/site/emissaoacustica/
-----

Programa inicializado com sucesso.

Carga de dados dos ensaios finalizada

fx Escolha um ensaio para processar:
```

Figura 57 – Tela inicial do programa de análise.

O ensaio hidrostático foi realizado em corpo de prova (segmentos de dutos de aço especificação API-XL 60) com costura, diâmetro nominal 20 polegadas (50,8cm), comprimento de 2,0m, espessura de parede 14,5mm e com extremidades usinadas para montagem de dois flanges para contenção do fluido de pressurização (vedação com *o-rings* de borracha).

Uma trinca externa foi usinada no centro do duto com a realização posterior de fadiga via ciclos de carregamentos para promover um defeito de formato semi-elíptico de 160mm de comprimento e 7,33mm de profundidade (relação em torno de 20:1) e 1,1mm de largura.

Em seguida, o duto foi cortado, usinado e adaptado para as condições indicadas para o ensaio hidrostático. Uma vez montado o sistema, o duto foi instrumentado com sensores de Emissão Acústica e ToFD³². Adicionalmente foram inseridos extensômetros de resistência elétrica e acelerômetros visando às medidas contínuas das variações de deformações e acelerações durante os ciclos de carregamentos.

O comportamento da trinca foi acompanhado através dos sistemas de emissão acústica (VALLEN³³ e PAC³⁴), do ultrassom via ToFD e da Extensometria por

³² ToFD (*Time of Flight Diffraction*) técnica de medição de comprimento de trinca por difração de ondas.

³³ <http://www.vallen.de/>

³⁴ <http://www.physicalacoustics.com/>

resistência elétrica para os registros das dimensões da descontinuidade na trinca durante o ensaio hidrostático.

O sistema de emissão acústica foi constituído por sensores da VALLEN e da PAC posicionados conforme Figura 50. Um limiar para detecção de 45dB foi fixado no PAC com sensores ressonantes em 150kHz. Para o VALLEN foi fixado um limiar de detecção de 65dB para os sensores ressonantes em 150kHz com uma taxa de amostragem de 1MHz e 200 amostras de *pré-trigger*.

O ultrassom via ToFD foi realizado com cabeçotes de 10MHz, sapatas de 60° e taxa de aquisição de 1Hz.

Todos os elementos supracitados estão representados no esquema ilustrado na Figura 58 e o posicionamento dos sensores com relação a trinca – origem (0,0) – apresentado na Figura 59.

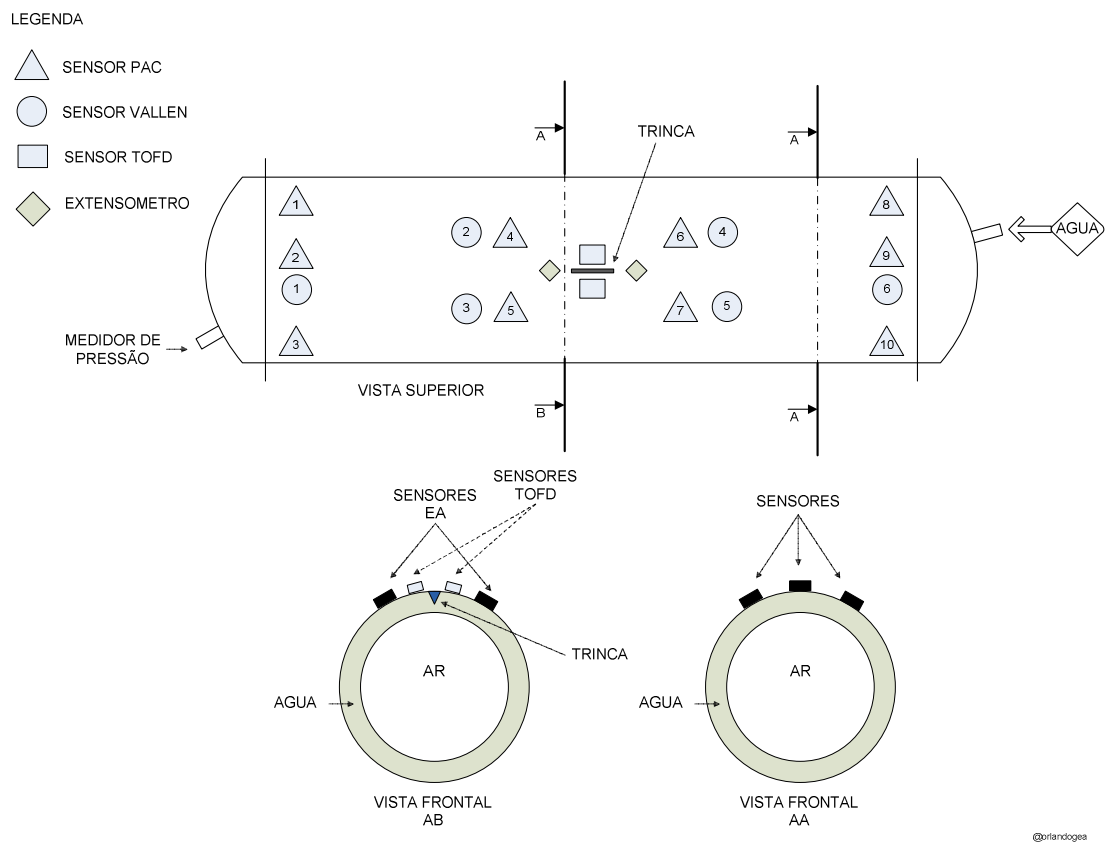


Figura 58 – Estrutura do corpo de prova no ensaio hidrostático.




Figura 59 – Coordenadas dos sensores considerando a trinca na origem (0,0).

O corpo de prova foi submetido a uma carga por meio da variação da pressão interna conforme curva de carregamento (Figura 60) até o ponto equivalente a 90% do limite de escoamento do material de acordo com especificação técnica operacional.




Figura 60 – Variação de Pressão e Profundidade da Trinca medida pelo ToFD.

Os sensores registraram parâmetros conforme ilustrado pelos gráficos nos Apêndices A, B e C. Pelos quais, observa-se que cada ponto representa um sinal de emissão acústica registrado:

- a) Apêndice A: Gráficos para comparação dos parâmetros comuns em ambos os equipamentos (VALLEN e PAC).
- b) Apêndice B: Gráfico dos parâmetros registrados pelo equipamento VALLEN.
- c) Apêndice C: Gráficos dos parâmetros registrados pelo equipamento PAC³⁵.

Observa-se pelas figuras do Apêndice A que os mesmos os parâmetros registrados (Amplitude, Tempo de Subida, Energia, Contagem e Duração) por ambos os equipamentos (VALLEN e PAC) apresentam distribuição distintas, o que dificulta a visualização de possíveis regiões de propagação da trinca.

Os demais parâmetros calculados pelos equipamentos também não permitem também uma distinção de possíveis regiões sem o uso de outras técnicas de análises – por exemplo, resultados apresentados nas figuras do Apêndice C.

Durante um ciclo de pressurização do ensaio foram programados patamares de pressão, nos quais a pressão foi mantida constante por um tempo mínimo de 10 minutos e o último com tempo mínimo de duração de 60 minutos. As taxas médias incrementais de pressão durante o carregamento foram de 10,0bar/min até o 1º patamar e de 2,5bar/min nas demais até atingir a pressão nominal igual à pressão referente a 90% do limite de escoamento do material do duto prevista para o último patamar. A ruptura total do duto ocorreu no final do último patamar do 1º ciclo de carregamento, não sendo possível a realização de um 2º ciclo de carregamento como planejado.

A Figura 67 apresenta a curva de pressão, a profundidade da trinca durante o ensaio hidrostático e os registros de sinais de emissão acústica registrados.

³⁵ Os parâmetros PAC são descritos na Tabela 1. Em estudos referenciados no capítulo 2 são utilizados os parâmetros PAC, pois o equipamento da VALLEN, apesar de registrar parâmetros, possui como principal produto os registros das formas de onda dos sinais de emissão acústica.

Os primeiros 124 sinais – EA(1) até EA(124) – foram descartados na análise, pois foram considerados sinais espúrios devidos a estabilização do corpo de prova no início do ensaio hidrostático. Observa-se que, durante o tempo de ocorrência destes sinais, a trinca não sofre alteração de dimensões e os eventos ocorrem com um intervalo significativo antes dos demais registros.

O gráfico da Figura 61 ilustra a dinâmica ocorrida durante o ensaio hidrostático apresentando a evolução da pressão e da profundidade da trinca (ToFD) comparados com os momentos de registros de sinais EA pelo equipamento VALLEN.




Figura 61 – Distribuição dos sinais EA, da pressão e da dimensão da trinca durante o ensaio hidrostático.

Com o objetivo de comparar a taxa de crescimento da trinca e auxiliar a identificação das fases dos estados (classes), apresenta-se por meio da Figura 62, a variação dos pontos das medições do ToFD pela variação em pontos relativos dado pela Equação 48:

$$Var_ToFD(t) = \frac{ToFD(t)}{ToFD(t-1)} - 1,0 \quad (48)$$

Nota-se então a variação da taxa de crescimento entre os registros das medições do ToFD e com isso uma possível identificação dos momentos de transição do comportamento da trinca com a evolução da pressão.

Portanto, a Figura 62 representa o gráfico anterior – Figura 61 – identificando os impulsos³⁶ (incrementos) ocorridos nas medições da profundidade da trinca via ToFD. Ou seja, os impulsos representam os momentos em que a trinca sofre o acréscimo de comprimento (avanço da trinca).

³⁶ O termo também conhecido como função delta de Dirac, uma distribuição na reta real, a qual vale infinito no ponto zero e é nula no restante da reta.




Figura 62 – Distribuição dos sinais EA, da pressão e dos impulsos ocorridos na medição da trinca durante o ensaio hidrostático.

As classes de propagação da descontinuidade foram definidas com base no comportamento entre a variação da profundidade da trinca e a variação de pressão interna:

- i. Sem Propagação (SP): A trinca sofre pequenas alterações na dimensão para grandes variações de pressão (*acomodação metalúrgica*).
- ii. Propagação Estável (PE): A trinca sofre alterações na dimensão para variações de pressão (*deformação elástica*).
- iii. Propagação Instável (PI): A descontinuidade da trinca sofre significativas alterações na dimensão para pequenas ou nenhuma variação de pressão (*deformação plástica*).

Admite-se a priori baseado nestas premissas que:

- i. No intervalo de 0 a 6.10^3 segundos a trinca apresenta crescimentos de 0% a 0,5% caracterizando a classe *Sem Propagação (SP)*;
- ii. No intervalo de 6.10^3 a 12.10^3 segundos, apresentam-se crescimentos de 0% a 4,5% caracterizando a classe *Propagação Estável (PE)*;
- iii. No intervalo partir de 12.10^3 segundos, a trinca entra em colapso e o duto rompe caracterizando a classe *Propagação Instável (PI)*.

Conforme estudo da curva PoP [39] (Figura 11), os sinais EA(125) a EA(158) indicados na Figura 62 seriam classificados na região de PE (Propagação Estável), pois estariam entre a faixa de transição das curvas.

A Figura 63 ilustra a sequência de sinais EA registrados pelos canais (sensores) durante o ensaio, onde a trinca se localiza no centro e os sensores estão representados conforme sua posição em relação à trinca (Figura 59). A Figura 63(a) apresenta a distribuição vetorial dos sinais de emissão acústica, onde a direção do vetor indica o canal (sensor) que registrou o sinal e o tamanho do vetor indica o tempo de registro. A

Figura 63(b) apresenta a região central da Figura 63(a) ampliada para visualizar o ocorrido no início do ensaio.

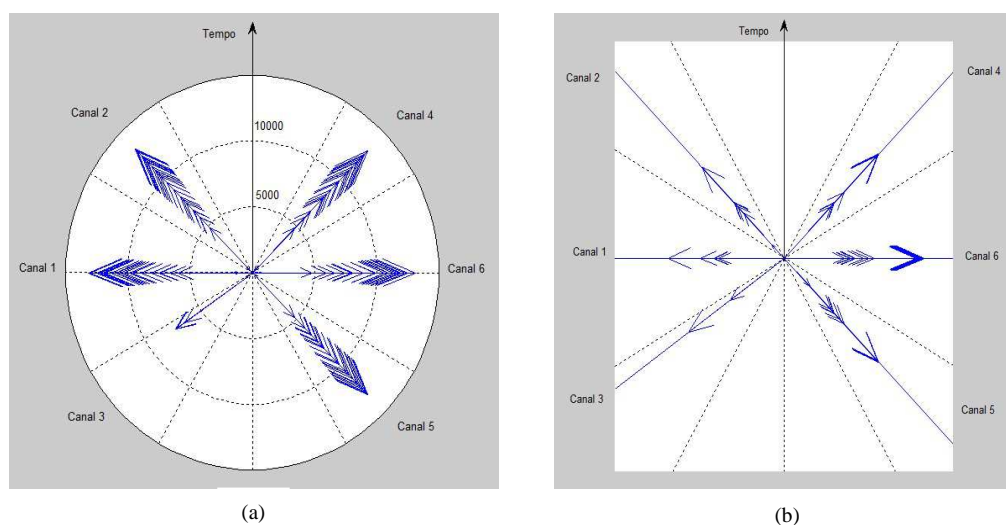


Figura 63 – Distribuição dos sinais EA pelos canais durante o ensaio hidrostático.

Em suma, assume-se que todos os registros de sinais de emissão acústica foram oriundos da trinca – origem da Figura 63(a) e 63(b) –, para o eixo radial representar o tempo do ensaio e cada seta um sinal EA emitido pela trinca. Percebe-se que o sensor (canal) 3 está com defeito por possuir uma distribuição que difere significativamente dos demais sensores.

A análise destas fases ocorre com um número reduzido de registros medidos pelo ToFD. Observa-se que no intervalo $[6.10^3\text{s} , 8.10^3\text{s}]$ ocorreram 2 (dois) patamares de pressão, porém apenas uma medição do ToFD no instante 6.000 s e outra no instante 8.000 s.

No intervalo por seguinte da classe de Propagação Estável (PE), a pressão tende a ser constante com as seguintes constatações: no intervalo $[8.10^3\text{s} , 10.10^3\text{s}]$ a taxa de crescimento³⁷ se mantém constante e no intervalo $[10.10^3\text{s} , 12.10^3\text{s}]$ há uma alteração na taxa³⁸, mas em ambos os casos para uma variação praticamente nula da pressão nestes dois intervalos (Figura 62).

³⁷ A taxa de crescimento é a variação em pontos relativos (reflete o coeficiente angular da reta no intervalo e portando a derivada).

³⁸ A constatação da alteração da taxa de crescimento no intervalo $[10. 10^3\text{s} , 12. 10^3\text{s}]$ foi possível por um registro dentro do intervalo enquanto que no intervalo $[8. 10^3\text{s} , 10. 10^3\text{s}]$ não houve medição (Figura 68).

Portanto, estima-se a viabilidade de caracterização de duas sub-regiões na classe PE conforme apresentado pela Tabela 2:

- 1ª sub-região: $[6. 10^3 \text{ s} , 8. 10^3 \text{ s}]$ na qual sob uma variação de pressão há uma resposta da trinca. Alta correlação entre os níveis de crescimentos (variações das variáveis).
- 2ª sub-região: $[8. 10^3 \text{ s} , 12. 10^3 \text{ s}]$ na qual sob um nível de pressão tendendo a ser constante há uma resposta da trinca. Baixa correlação entre os níveis de crescimentos (variações das variáveis).

Tabela 2 – Características das sub-regiões da classe PE.

Intervalo	Varição de Pressão	Varição do ToFD	Taxa de Crescimento	Sub-região PE
$[6.10^3 \text{ s} , 8.10^3 \text{ s}]$	14,89 %	0,69 %	$0,69.10^{-2}$	1ª
$[8.10^3 \text{ s} , 10.10^3 \text{ s}]$	2,50 %	3,56 %	$2,87.10^{-2}$	2ª
$[10.10^3 \text{ s} , 12.10^3 \text{ s}]$	1,59 %	8,65 %	$1,03.10^{-2}$	

A Figura 64 apresenta graficamente o conteúdo da Tabela 2 para ilustrar o comportamento da trinca na classe de Propagação Estável (PE).




Figura 64 – Representação gráfica da Tabela 2.

A faixa crítica ocorre na transição das classes de propagação estável (PE) e propagação instável (PI). Uma vez que esta transição representa o risco de uma decisão limite durante a operação do duto, pois abrange uma região de possível iminência de fratura.

Os sensores VALLEN distribuídos no corpo de prova registraram as formas de ondas dos sinais de emissão acústica durante o ensaio conforme distribuições ilustradas na Figura 65 e pela Tabela 3. A discrepância de registros na região de classificação de SP (Sem Propagação) no canal (sensor) 6 é devida a sinais espúrios comentados anteriormente.

Tabela 3 – Estatísticas nos intervalos de tempo das classes de propagação

	Intervalo de Tempo ($\cdot 10^3$ s)		
	[02;06]	[06;12]	[12;14]
Varição da trinca	0,34%	13,29%	35,40%
Varição da pressão	59,87%	19,63%	0%
Quantidade de sinais (centro do duto)	7	65	40
Quantidades de sinais (extremidades)	3	40	22




Figura 65 – Quantidades de sinais EA por canal (sensor).

A Figura 66 apresenta o comportamento do ensaio hidrostático em relação aos registros de sinais de emissão acústica pelos equipamentos (VALLEN e PAC). Cada ponto identificado representa um sinal de emissão acústica captado pelos equipamentos e por consequência os parâmetros destes sinais são calculados conforme apresentado nas Figuras nos Apêndices. No entanto, somente o equipamento da VALLEN registrou formas de ondas registradas no domínio do tempo.

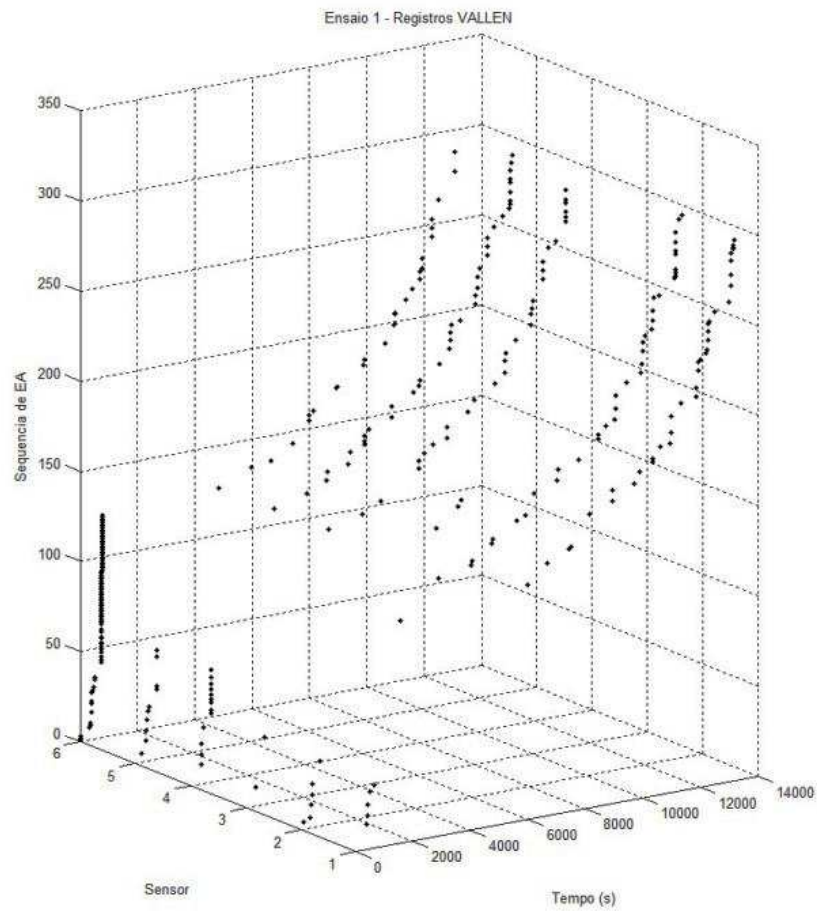
A Figura 66 apresenta a distribuição de sinais de emissão acústica por sensor durante o ensaio. A Figura 66(a) representa os registros de sinais captados pelo equipamento da VALLEN, pela qual se observa o crescimento exponencial em todos os sensores. A Figura 66(b) apresenta os registros de sinais pelo equipamento da PAC, neste há a indicação de uma série de registros do canal 4 não compatível com o comportamento dos demais canais. Portanto, estes não foram utilizados na análise e classificados como anomalia.

Desta forma, o sensor 4 do PAC estava próximo ao sensor 2 do VALLEN (Figuras 58 e 59), no entanto apresentam comportamentos distintos, inclusive em comparação aos outros sensores PAC. Isso caracteriza uma anomalia durante o ensaio e respectivos dados descartados.


As Figuras 67, 68 e 69 apresentam a distribuição de sinais em planos distintos da Figura 66 e observa-se que a quantidade de sinais registrados como EA em ambos os equipamentos diferentes.

A Figura 67(a) ilustra a sequência de registros de sinais durante o ensaio por canal pelo equipamento da VALLEN enquanto a Figura 67(b) ilustra o mesmo para o equipamento da PAC. Por ambas, os sinais classificados como anomalias (espúrios) ficam confirmados pelo comportamento distinto aos demais nos períodos de ocorrência.

As Figuras 68(a) e 69(a) apresentam outros planos de visualização das distribuições de registros pelo equipamento da VALLEN, enquanto as Figuras 68(b) e 69(b) para o equipamento da PAC.




(a)




(b)

Figura 66 – Distribuição dos sinais EA registrados no tempo por sensor.




(a)




(b)

Figura 67 – Plano XY (Tempo versus Sensor) da Figura 66.

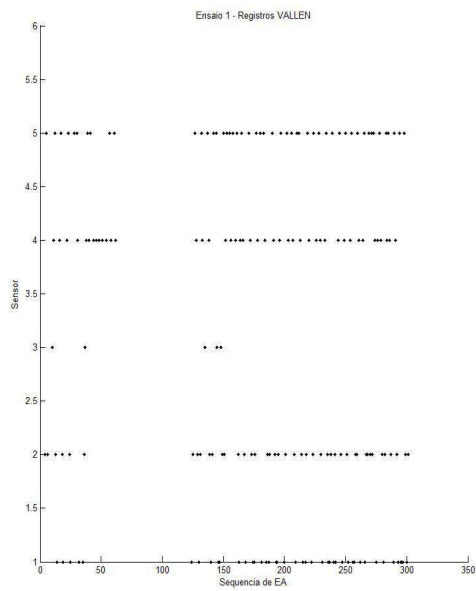


(a)




(b)

Figura 68 – Plano XZ (Tempo versus Sequencia EA) da Figura 66.



(a)



(b)

Figura 69 – Plano YZ (Sensor versus Sequencia EA) da Figura 66.

5 RESULTADOS NUMÉRICOS

Os dados coletados durante os ensaios hidrostáticos foram analisados e as formas de ondas dos sinais de emissão acústica aplicadas a rede neural híbrida sem a identificação prévia de classificação em classes de propagação.

Uma vez que a classificação referida é uma função dos classificadores não lineares a partir dos parâmetros disponibilizados pela rede neural híbrida. A classificação apresentada por estes foi confrontada com a realizada pelos técnicos da área para avaliação do percentual de acertos da metodologia. Essa classificação dos técnicos foi baseada nas figuras apresentadas no capítulo anterior.

A Figura 70 apresenta um subconjunto de sinais da classe de propagação PE. Os seis sinais representados pelo conjunto de EA(129) a EA(135) pertencem a uma região de classificação a priori (prévia) de Propagação Estável (PE) conforme análise da Figura 62.




Figura 70 – Subconjunto de sinais EA contido na classe de propagação PE.

A Figura 71 apresenta um subconjunto de sinais da classe de Propagação Instável (PI) representados pelos sinais de EA(185) a EA(189) conforme análise da Figura 62.




Figura 71 – Subconjunto de sinais EA contido na classe de propagação PI.

Os sinais amostrados de emissão acústica coletados durante o ensaio hidrostático foram submetidos à análise estatística, por exemplo, média – valor esperado – e variância, conforme apresentada pela Figura 72.

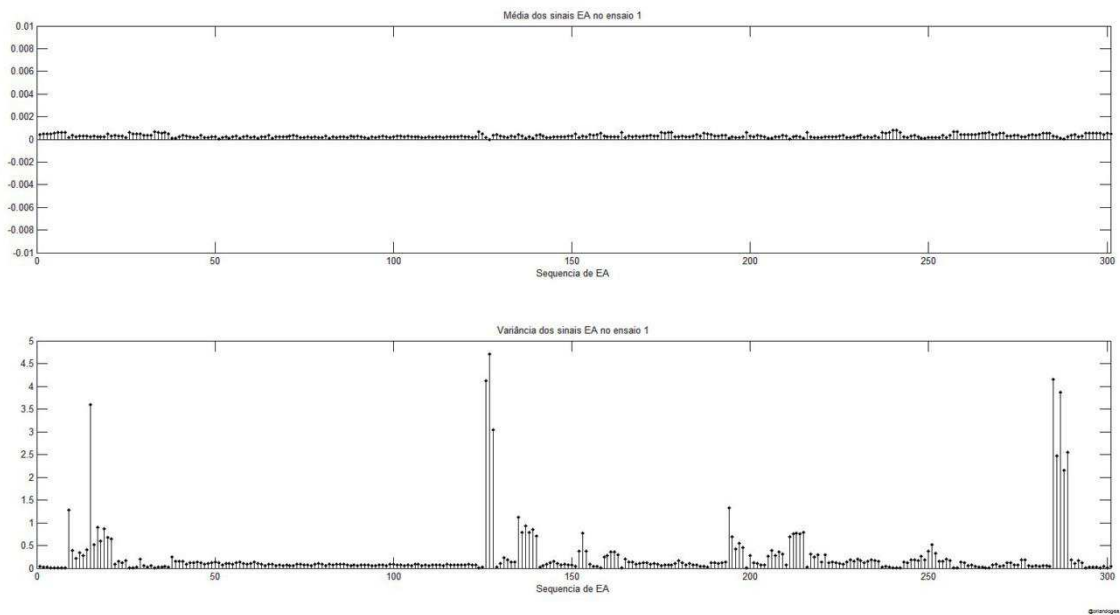


Figura 72 – Média e Variância dos sinais EA.

Os sinais de emissão acústica foram analisados no domínio da frequência em grupos (elementos das classes PE e PI) conforme os exemplos ilustrados nas Figuras 73 e 74 com o intuito de determinar o tamanho da janela de corte no sinal de emissão acústica original.

Um sinal de emissão acústica amostrado possui 8.192 pontos conforme apresentado na Figura 56 e o mesmo possui as características típicas apresentadas pela Figura 7.

Desta forma, o janelamento do sinal amostrado de emissão acústica para a utilização da rede neural híbrida foi necessário para não distorcer o treinamento da rede.

Sendo assim, o tamanho da janela de corte ($\Delta t = 2 \times \text{tempo de pico}^{39}$) foi realizado para melhorar o resultado do treinamento da rede neural híbrida, uma vez que mais de 50% do sinal poderia ser desconsiderado prevalecendo praticamente o contorno do espectro principal e assumindo como ruído a parte suprimida (Figuras 75 a 78).

Este critério foi estabelecido com a premissa de minimizar a distorção do espectro original, dado que o sinal de emissão acústica possui característica de ruído.

Para fins de ilustração deste procedimento, as Figuras 75 e 76 apresentam sinais de emissão acústica – EA(135) e EA(137) – da região de Propagação Estável (PE) respectivamente. Enquanto, as Figuras 77 e 78 ilustram o procedimento para os sinais EA(183) e EA(184) respectivamente da região de Propagação Instável (PI).

Este procedimento está baseado pelo fato de que em estudos [6,7-11,39] os principais componentes espectrais possuem alta relevância da classificação de sinais de emissão acústica.

³⁹ Em analogia à Figura 7




Figura 73 – Espectros de Frequências do subgrupo de sinais EA na classe de propagação PE representados na Figura 70.




Figura 74 – Espectros de Frequências do subgrupo de sinais EA na classe de propagação PI representados na Figura 71.

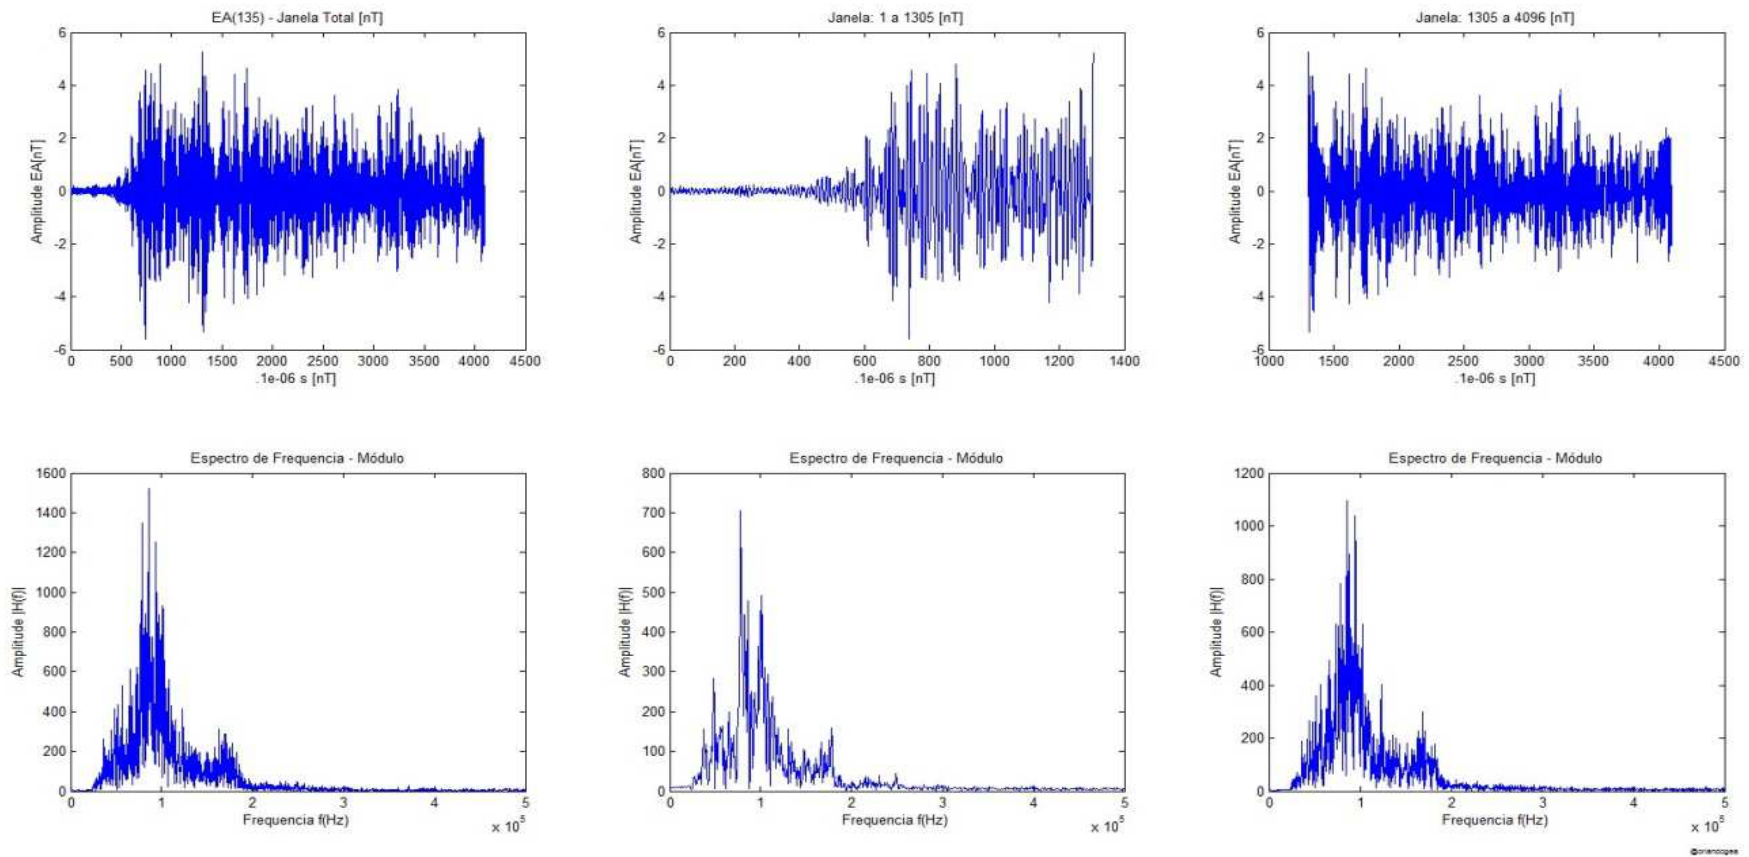


Figura 75– Sinal no dom3nio do tempo e da freqüência - Exemplo de sinal na classe de propagaç3o PE (Sinal Completo, Parte do Sinal selecionado pela Janela e Parte do Sinal Suprimida).

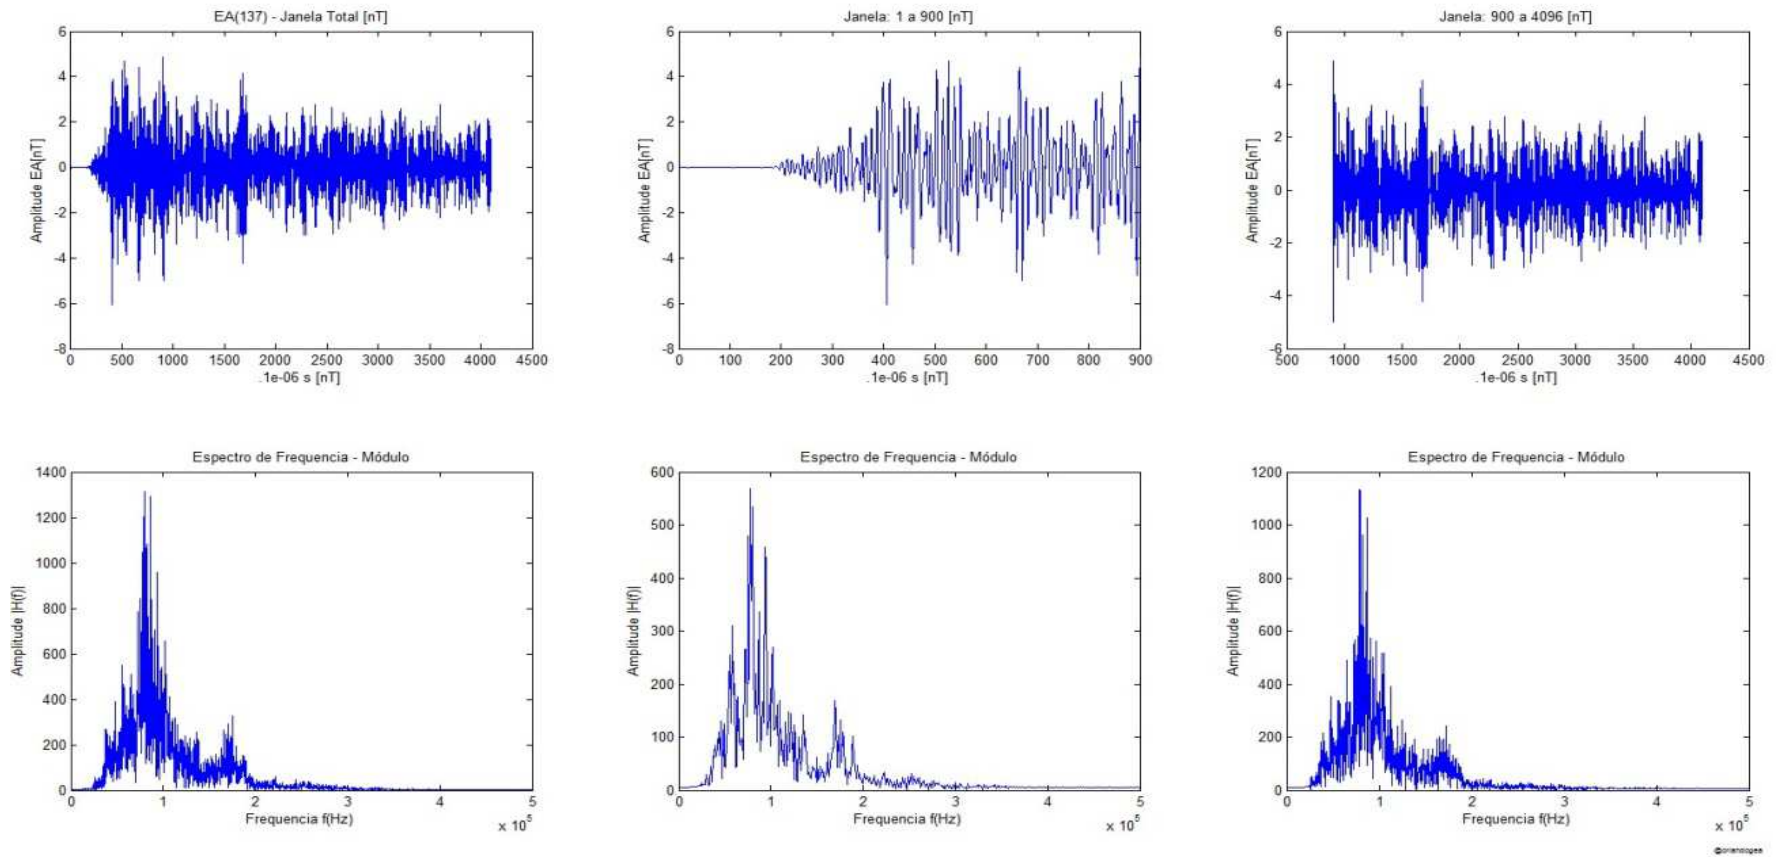


Figura 76 – Sinal no domínio do tempo e da frequência - Exemplo de sinal na classe de propagação PE.
(Sinal Completo, Parte do Sinal selecionado pela Janela e Parte do Sinal Suprimida)

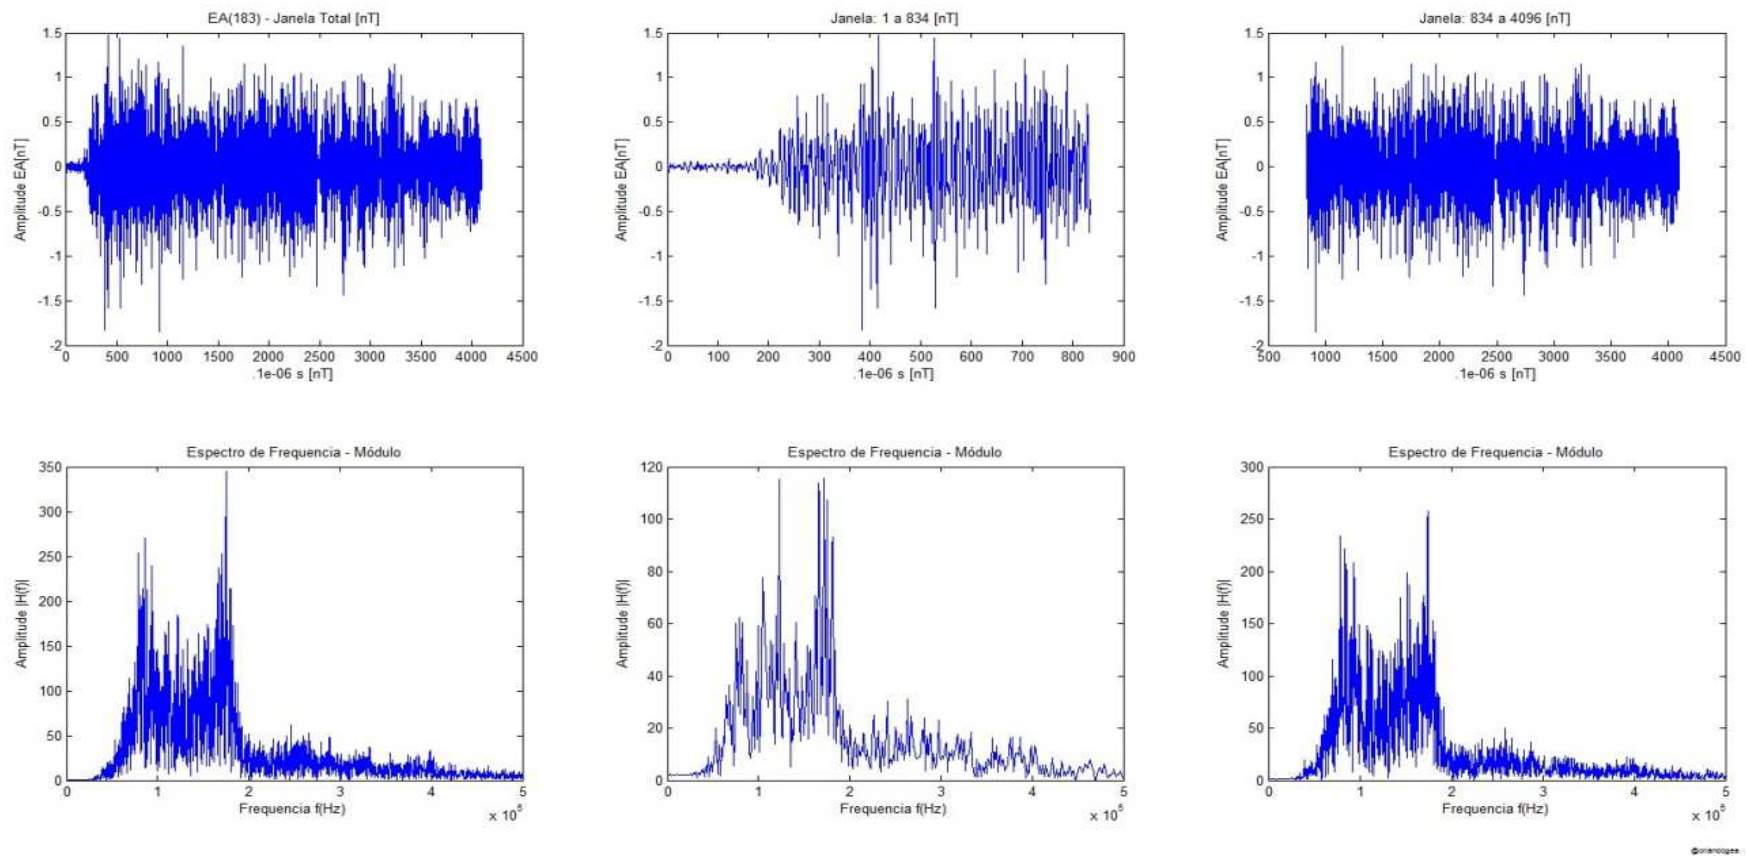


Figura 77 – Sinais no domínio do tempo e da frequência - Exemplo de sinal na classe de propagação PI. (Sinal Completo, Parte do Sinal selecionado pela Janela e Parte do Sinal Suprimida).

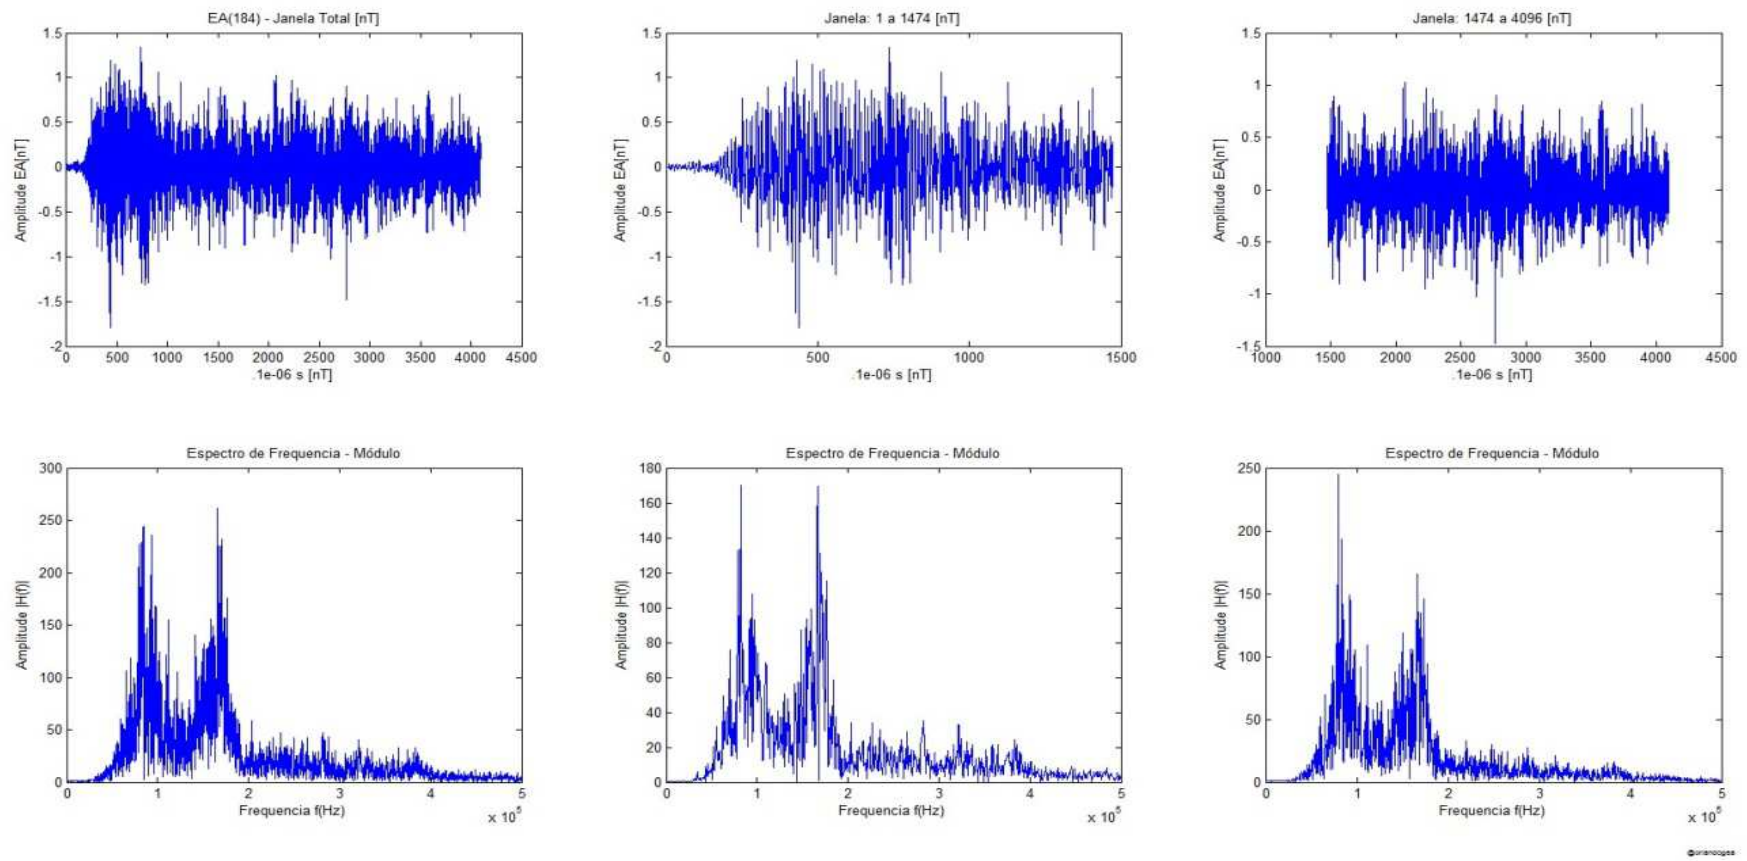


Figura 78 – Sinais no domínio do tempo e da frequência - Exemplo de sinal na classe de propagação PI.
(Sinal Completo, Parte do Sinal selecionado pela Janela e Parte do Sinal Suprimida)

A rede híbrida foi treinada (treinamento supervisionado) com os sinais de emissão acústica para disponibilizar o conjunto de parâmetros das portadoras que compõem cada sinal registrado, os quais apresentam a dinâmica dos sinais nas regiões de Propagação Estável (PE) e de Propagação Instável (PI).

A Figura 79 apresenta a evolução do erro médio quadrático durante o treinamento da rede neural híbrida para um sinal de emissão acústica.




Figura 79 – Curva de erro durante o treinamento.

Após o treinamento as sinapses da rede neural híbrida fornecem os parâmetros das portadoras – representados pelos dos elos de comunicações nas Equações 42 a 45.

A partir do conjunto de parâmetros de portadoras para cada sinal de emissão acústica registrado durante o ensaio hidrostático foram aplicadas técnicas de aprendizagem não supervisionada para concluir a identificação de padrões entre as classes de propagação da descontinuidade na trinca conforme ilustrado pela Figura 43. Pois, esta estratégia consiste em deixar a própria rede se auto-organizar em relação às particularidades existentes entre os elementos do conjunto de entrada identificando subconjuntos (clusters).

As seguintes técnicas não supervisionadas foram utilizadas os sinais das classes PE e PI:

- a) Método *K-means*: o algoritmo do *K-means* é um método utilizado para encontrar grupos e os centros de grupos a partir de um conjunto de dados sem classificação prévia. Com o objetivo de particionar um conjunto de dados em grupos separados, onde a distância Euclidiana entre os vetores de atributos e os representantes das classes é utilizada como medida de dissimilaridade.
- b) Mapa Auto-Organizável: método particularmente útil quando existe um mapeamento não linear inerente ao próprio problema. Permite transformar um padrão de entrada de dimensão arbitrária em um mapa discreto de duas dimensões de forma topologicamente adaptativa.

A rede SOM foi projetada para trabalhar com vetores normalizados, desta forma os vetores das sinapses se encontram no interior da mesma esfera unitária. Isso permite a visualização dos ângulos em coordenadas esféricas destes vetores como uma caracterização do mapa.

As simulações foram realizadas para uma grade quadrada de neurônios assumindo o processo competitivo em função do produto vetorial e produto escalar para determinação do neurônio vencedor.

O Processo Cooperativo é desenvolvido a partir de uma função de vizinhança gaussiana entre o neurônio vencedor i e outro da grade j :

$$h_{j,i}(n) = \exp\left(-\frac{d_{j,i}^2}{2\sigma^2(n)}\right), n = 0,1,\dots,N \quad (49)$$

Sendo a largura efetiva da vizinhança topológica dada por:

$$\sigma(n) = \sigma_0 \cdot \exp\left(-\frac{n}{\tau_1}\right) \quad n = 0,1,\dots,N \quad (50)$$

Com constante de tempo proposta de:

$$\tau_1 = \frac{N}{2 \cdot \log(2)} \quad (51)$$

A distância entre os neurônios é dada por:

$$d_{j,i} = \|r_j - r_i\| \quad (52)$$

O processo de Adaptativo é composto pela atualização das sinapses:

$$\Delta \bar{w}_j = \mu(n) \cdot h_{j,i}(n) \cdot (x - \bar{w}_j) \quad (53)$$

Para um parâmetro de aprendizado:

$$\mu(n) = \mu_0 \cdot \exp\left(-\frac{n}{\tau_2}\right) \quad n = 0, 1, \dots, N \quad (54)$$

A fase de ordenação (auto-organização) é obtida para o parâmetro aprendizado inicial aleatório entre 0,05 e 0,20 escolhido pela simulação e uma constante de tempo do aprendizado igual a:

$$\tau_1 = \frac{N}{4} \quad (55)$$

A Figura 80 ilustra um exemplo de resultado do mapa SOM para os parâmetros da rede neural híbrida. O percentual de ativações indica a intensidade de uma classe perante o grupo de dados.




Figura 80 – Resultado do Mapa SOM.

A Figura 81 ilustra o processo de treinamento, pelo qual a estabilização indica que não há mudança de identificação de classes pela rede.




Figura 81 – Curva de Erro Médio Quadrado e Diferença Vetorial para uma simulação do SOM.

A Figura 82 ilustra a dispersão dos vetores por elevação e rotação (sistema de coordenada esférica) após normalização do processo não supervisionado para um grupo de parâmetros das portadoras que ilustram a formação da classe e a identificação de falsos positivos.




Figura 82 – Dispersão final dos vetores com a indicação de classe.

Observa-se que a maioria dos neurônios cria uma região identificada pelos seus vetores sinápticos como padrão do setor (classe) e a partir desta é apresentado candidatos que tendem a caracterizar desvios ocorridos (não classe).

O efeito das regiões das classes de propagação é também ilustrado no mapa auto-organizável (SOM) – Figura 83. Pela qual, se apresenta um exemplo do mapa auto-organizável com os parâmetros determinados pela rede híbrida como entrada para as classes PE e PI inicialmente estimadas e a caracterização do mapa identifica as referidas regiões.




Figura 83 – Exemplo de mapa resultante dos parâmetros dos sinais EA's

O percentual de erro pelo método de *K-means* está praticamente concentrado na região de transição entre as duas classes PE e PI, 91,2% e 94,3% de acerto respectivamente.

A região de transição entre PE e PI para este estudo foi definida a partir de experiência de profissionais da área de instrumentação, desta forma quaisquer alterações nesta fronteira implicam em novos resultados. Uma vez que neste estudo, ocorreu predominantemente em situação de pressão constante (8ks a 10ks).

Para fins de inspeção metalúrgica com a utilização do método de Emissão Acústica, o principal objetivo do uso da técnica com aplicação conjunta da rede neural é o conhecimento da fase de transição entre as classes PE e PI a partir de novas características. Pois, reduz a probabilidade de ocorrências de dano na integridade do duto pressurizado durante a operação (classe PI).

Em estudos, os parâmetros relacionados a frequências foram os mais relevantes em análises (Figuras 8 a 10) para a classificação das classes de propagação [39]. Os referidos parâmetros, Freq-PP1, Freq-PP2, Freq-PP3, Freq-PP4, C-Frq e P-Frq foram disponibilizados pelo equipamento PAC (Tabela 1).

Diante disso, a Figura 84 apresenta a correlação no domínio da frequência dos sinais durante o ensaio. Observam-se regiões de agrupamentos que evidenciam a relação da variável frequência no estudo das classes pela identificação de grupos (regiões), tendo a reta $y = x$ representando a correlação máxima (correlação do sinal com o próprio). Para fins de comparação a Figura 85 apresenta o a correlação no domínio do tempo.




Figura 84 – Matriz da correlação na frequência de cada sinal em relação ao conjunto de sinais do ensaio hidrostático.




Figura 85 – Matriz da correlação no tempo de cada sinal em relação ao conjunto de sinais do ensaio hidrostático.

Pela análise de ambas, verifica-se a existência de agrupamentos em torno dos sinais EA(150), EA(200) e EA(300). A região próxima do sinal EA(200) representa pontos relevantes (alta correlação) no momento em que a propagação da trinca se encontra classe de propagação PI quando comparado com o gráfico da Figura 60. O mesmo pode-se afirmar do grupo próximo do sinal EA(150) para a classe PE.

A correlação foi calculada a partir da Equação 56 para os todos os sinais de emissão acústica registrados.

$$\rho = \frac{\sum_{i=1}^n (x_i \cdot y_i) - \frac{\sum_{i=1}^n x_i \cdot \sum_{i=1}^n y_i}{n}}{\sqrt{\left(\sum_{i=1}^n x_i^2 - \frac{(\sum_{i=1}^n x_i)^2}{n}\right) \left(\sum_{i=1}^n y_i^2 - \frac{(\sum_{i=1}^n y_i)^2}{n}\right)}} \quad (56)$$

A correlação no domínio do tempo foi determinada com o vetor que representa o sinal de emissão acústica no tempo – por exemplo, ilustrado Figuras 70 e 71 – e a correlação no domínio da frequência a correlação do vetor que representa a Análise de Fourier do sinal – por exemplo, ilustrado Figuras 73 e 74.

Com o objetivo de avaliar a distribuição da energia dos sinais de emissão acústica pela frequência, os gráficos de correlação de energia (Figuras 86 e 87) apresentam a correlação do percentual de energia por frequência para toda a faixa de frequência com a classificação do sinal quanto à classe de propagação.

Em ambos gráficos, a correlação da fração de energia pela frequência classificada (*clusters*) para as classes PE e PI é realizada a partir da criação para cada sinal EA no domínio da frequência de um vetor **E** associado. Cada componente deste vetor foi calculado conforme Equação 57:

$$E(f_k) = \frac{a^2(f_k)}{\sum_{i=1}^n a^2(f_i)} \quad (57)$$

Sendo $a(f_k)$ a amplitude do espectro de frequência para a frequência f_k e f_1 a f_n a faixa total do espectro de frequência.

Cada componente foi associado a um conjunto para classificação (*clusters*) cujo elemento é "+1" se o ponto está associado a um sinal na classe de propagação PE (*cluster +1*) e "-1" se associado a um sinal na classe de propagação PI (*cluster -1*).

O gráfico da Figura 86 apresenta a distribuição da correlação em frequência relativa de dois grupos (PE e PI) e a Figura 87, o gráfico das médias móveis (janela de 50 e 100 pontos) da curva da Figura 86.




Figura 86 – Correlação da Energia Relativa.




Figura 87 – Médias Móveis para a distribuição da Figura 86.

Os elementos selecionados para compor os grupos para avaliação correspondem aos sinais EA(125) a EA(151) para a classe de propagação estável (PE) e os sinais EA(217)

a EA(248) para a classe de propagação instável (PI). Corresponde a regiões típicas, o 1º grupo ocorre com pressão em ritmo crescente e com pouca variação da propagação da trinca enquanto o 2º grupo ocorre em pressão constante com um pico de crescimento da trinca – ilustrado pela Figura 88.

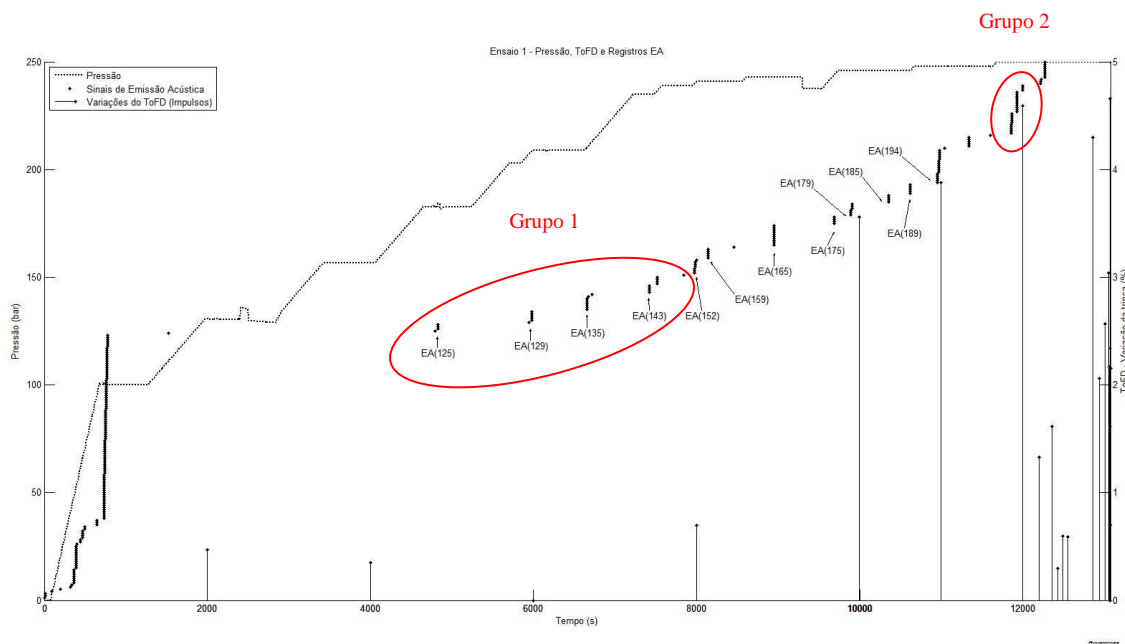


Figura 88 – Destaque dos grupos para análise da energia.

Com base na Figura 88, a Tabela 4 apresenta algumas faixas de frequências com os respectivos níveis de correlação.

Tabela 4 – Faixas de Frequências e Correlações.

Faixa (10^5 Hz)	Correlação
0,4 a 0,6	+ 0,3525
0,4 a 0,9	+ 0,3484
0,8 a 0,9	+ 0,3428
1,6 a 4,2	- 0,0879
2,0 a 2,4	- 0,3914

Os gráficos das Figuras 89 a 93 representam a análise das faixas selecionadas (Tabela 4), onde a variável Z representa a energia relativa e a variável Y a classe (*cluster*) correspondente (PE ou PI).

As seguintes figuras são compostas pelos seguintes gráficos:

- a) Gráfico superior à esquerda: apresenta cada para (Z, Y) para ilustrar a dispersão dos pontos por cluster.
- b) Gráfico superior à direita: apresenta as correlações na faixa de frequência.
- c) Gráfico inferior: gráfico superior à esquerda (a) com o eixo horizontal em logaritmo e o raio proporcional à grandeza do elemento no grupo Z.

Na Figura 89 apresenta que para a faixa de frequência de $0,4 \cdot 10^5 \text{ Hz}$ a $0,9 \cdot 10^5 \text{ Hz}$ que a classe de propagação estável (PE) possui maior variação entre seus elementos quando comparada a classe de propagação instável (PI) e ainda que esta classe está concentrada no início da faixa. O mesmo comportamento foi verificado na faixa de $0,4 \cdot 10^5 \text{ Hz}$ a $0,6 \cdot 10^5 \text{ Hz}$ e na faixa $0,8 \cdot 10^5 \text{ Hz}$ a $0,9 \cdot 10^5 \text{ Hz}$ como apresentado pela Figura 96 e 97 respectivamente.

No entanto, nas faixas de frequências de $1,6 \cdot 10^5 \text{ Hz}$ a $4,2 \cdot 10^5 \text{ Hz}$ e de $2,0 \cdot 10^5 \text{ Hz}$ a $2,4 \cdot 10^5 \text{ Hz}$ como ilustrado pelas Figuras 92 e 93 respectivamente o comportamento em dois aspectos: não há variação significativa entre as grandezas dos elementos nas classes de propagação e a classe de propagação instável (PI) possui maior presença na faixa quando comparada com as faixas iniciais apresentadas.

Desta forma, observa-se nas duas últimas faixas não ocorrem mudanças significativas, no entanto para as três primeiras faixas a classe PE possui um aumento relativo significativo da energia pela frequência relativa.






Figura 89 – 1ª faixa ($0,4 \cdot 10^5$ Hz a $0,9 \cdot 10^5$ Hz).



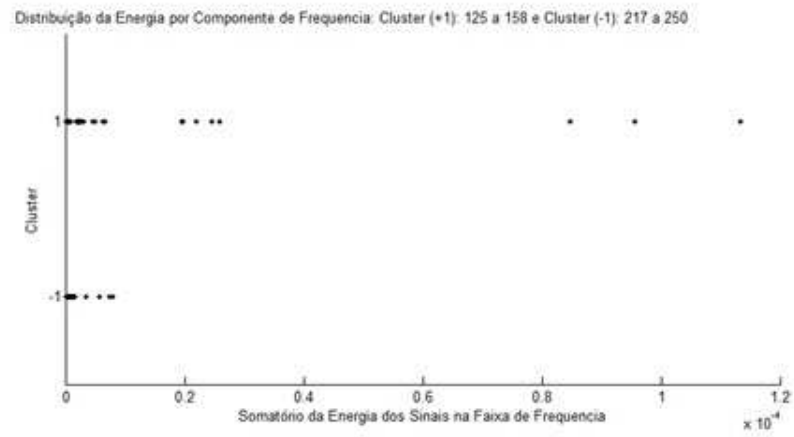


Figura 90 – 2ª faixa ($0,4 \cdot 10^5$ Hz a $0,6 \cdot 10^5$ Hz).






Figura 91 – 3ª faixa ($0,8 \cdot 10^5$ Hz a $0,9 \cdot 10^5$ Hz).





Figura 92 – 4ª faixa ($1,6 \cdot 10^5$ Hz a $4,2 \cdot 10^5$ Hz).





Figura 93 – 5ª faixa ($2,0 \cdot 10^5$ Hz a $2,4 \cdot 10^5$ Hz).

A análise supracitada relativa à "Energia Relativa na Frequência" (Equação 57) foi reavaliada para o aspecto da "Energia Absoluta na Frequência", ou seja, por meio da Equação 58:

$$E(f_k) = a^2(f_k) \quad (58)$$

sendo $a(f_k)$ a amplitude do espectro de frequência para a frequência f_k em toda a faixa do espectro de frequência.

A Tabela 5 apresenta o percentual de acertos quando utilizado as energias para classificação por *k-means*.

Após a determinação do 1º nível de separação para $k=2$ (PE e PI), foi aplicado *k-means* para os novos grupos de acordo com o resultado no 1º nível disponibilizando o 2º nível de classificação (PE 1.1 e PE 1.2 para o PE 1; PE 2.1 e PE 2.2 para o PE 2 e PI 1.1 e PI 1.2 para o PI 1).

Tabela 5 – Percentual de acertos pela classificação por *k-means*.

	PE				PI		
	PE 1		PE 2		PI 1		PI 2
Clusters	PE 1.1	PE 1.2	PE 2.1	PE 2.2	PI 1.1	PI 1.2	PI 2
Energia Relativa	10/13	5/6	10/11	1/4	9/13	17/18	2/3
Energia Absoluta	2/3		23/25	5/6	2/3	28/29	1/2

O gráfico da Figura 94 apresenta a distribuição da energia total (absoluta) dos sinais dos sinais de emissão acústica nas classes de propagação. Pela qual se observa que as variações ocorrem durante as primeiras classes de propagação.

Uma vez que elas apresentariam as descontinuidades que se tornam ativas acusticamente pelo incremento da pressão interna de operação do duto o que não ocorreu com relevância durante a classe PI.




Figura 94 – Distribuição da Energia por Classe de Propagação.

6 CONCLUSÃO E TRABALHOS FUTUROS

6.1 *Conclusões*

Em uma rede neural com uma arquitetura específica, a representação do conhecimento do meio ambiente é definida pelos valores assumidos pelos parâmetros livres da rede neural (pesos sinápticos e bias).

A metodologia do presente trabalho é dividida em duas partes: uma rede supervisionada para extração de características e uma rede não supervisionada para classificação. Os resultados foram satisfatórios inclusive tanto para o teste controlado do modelo (com sinais determinísticos aplicados à rede) quanto para os sinais de emissão acústica (sinais estocásticos) apresentados à rede neural híbrida.

A rede neural híbrida representou um circuito neural estruturado em blocos funcionais (redes neurais) com influência direta e indireta entre os mesmos devido à segregação de atividades por bloco neural. A rede apresentou resultados para os sinais de contexto, tanto pela análise de transição (comparação com o sinal anterior) quanto pela análise com base num sinal determinístico (comparação com um sinal determinado). Ou seja, em ambos os casos a rede neural híbrida fornece os parâmetros das portadoras via sinapses (elos de comunicação).

A decomposição do sinal em outras três formas de ondas modeladas pelas portadoras das modulações analógicas permite a visualização de características do fenômeno pela transição entre os elementos de um conjunto de sinais. Neste caso, pela mudança dos padrões entre os parâmetros das modulações analógicas.

Em suma, qualquer modelo pode ser representado por uma rede neural híbrida (rede neural especializada) para simular partes através de redes neurais menores. Se uma característica é importante então a representação da mesma será realizada por um número maior de neurônios envolvidos na rede neural.

A modulação e a demodulação são normalmente realizadas por meio de técnicas complexas de circuitos eletrônicos, entretanto a rede neural híbrida apresentou uma solução prática e eficiente para a aplicação desta técnica utilizada em telecomunicações

e em processamento de sinais. A modulação AM apresenta a caracterização da amplitude do fenômeno numa nova forma de onda. Enquanto que o mesmo princípio é identificado pelas modulações PM e FM quanto aos requisitos fase e frequência respectivamente.

Através da incorporação do tempo na operação de uma rede neural que esta se torna capacitada a perceber as variações estatísticas em processos não estacionários. A representação implícita do tempo permite uma rede neural estática (*perceptron* de múltiplas camadas) propriedades dinâmicas – possuir memória de curto prazo. Sendo assim, uma abordagem para um sistema dinâmico não linear, na qual a rede estática é responsável pela não linearidade e a memória pelo tempo.

A metodologia pode ser aplicada em qualquer família de série de sinais amostrados para dois tipos de análise: a utilização de sinais consecutivos para avaliação da transição entre os sinais por meio das portadoras analógicas – método utilizado neste estudo – ou a utilização de um sinal de referência e avaliação dos sinais em relação a este por meio das modulações – método realizado em sinais determinísticos, por exemplo.

6.2 Trabalhos Futuros

A análise dos sinais captados em dutos longos (Figura 95) – que fazem parte do projeto – captados com os equipamentos comerciais em conjunto por sensores na forma de *streaming* (Figura 96). Desta forma, as ondas dos sinais de emissão acústica foram registradas na forma mais realista – com o menor número de interferências durante os registros pelos equipamentos (VALLEN e PAC).

Nesta fase de registros em "*streaming*" do sinal, é necessária a avaliação de filtros para diminuir o aspecto ruidoso do sinal e da "melhor" janela antes de utilizar a metodologia para avaliar o desempenho da rede supervisionada por meio da classificação posterior por métodos não supervisionados.

Recomenda-se a análise dos sinais com a premissa da redução da parcela de ruído e a verificação conjunta por outras técnicas a decomposição dos sinais para comparação

durante a classificação não supervisionada – principalmente na transição entre as classes de propagação estável e propagação instável.

Por último, avaliar a atenuação das ondas entre os sensores para avaliar distâncias de confiabilidade de medições durante os ensaios hidrostáticos.



Figura 95 – Ensaio hidrostático experimental para dutos longos
(coluna esquerda: visão do corpo de provas de 40 metros – coluna direita: trinca, trinca e ToFD e trinca após o ruptura:

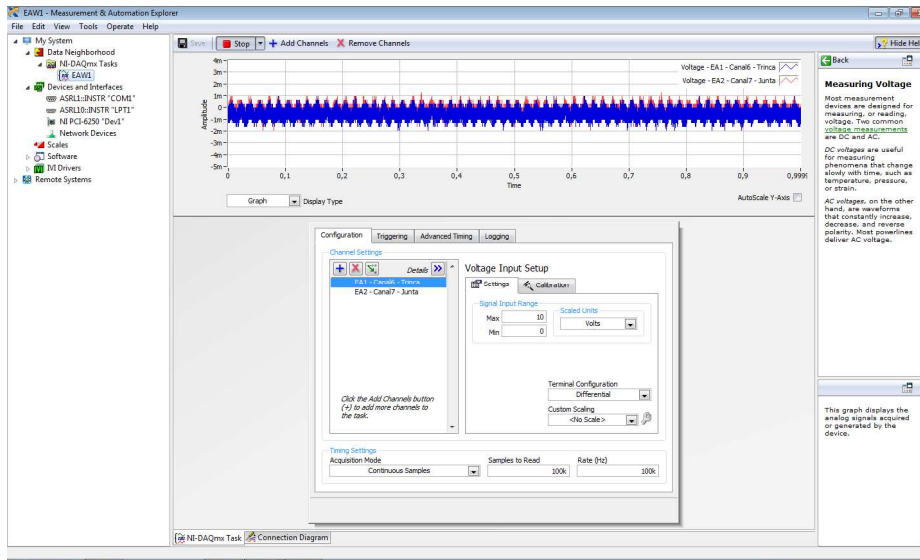


Figura 96 – Sistema de aquisição *streaming*

7 REFERÊNCIAS BIBLIOGRÁFICAS

- [1] JACQUES, R. C., 2009, *Avaliação de Parâmetros de Emissão Acústica para monitoramento de Risers Flexíveis*, Tese de doutorado, PPGEM/UFRGS, Porto Alegre, RS, Brasil.
- [2] SOARES, S. D., RABELLO, J. M. A., 2005, *Análise do banco de dados de resultado dos ensaios de emissão acústica realizados no sistema Petrobras*, www.cnea.gov.ar.
- [3] SILVA, M. A. C. 2010. *Caracterização do Sinal Gráfico de Emissão Acústica (EA) para Avaliação de Integridade Estrutural do Aço ASTM A 516 / A 516 M - Grau 60*, Dissertação de Mestrado., PUC, Rio de Janeiro, RJ, Brasil.
- [4] 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 Doutorado, COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.
- [5] DA SILVA, R. R., 2003, *Reconhecimento de Defeitos de Soldagem em Radiografias Industriais*, Tese de Doutorado, COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.
- [6] PINTO, C. F. C., 2011, *Monitoração de Defeitos em Dutos Rígidos por Emissão Acústica e Redes Neurais*, Dissertação de Mestrado, COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.
- [7] PINTO, C. F. C., SILVA, R. R., CALOBA, L. P., SOARES, S. D., CLARKE, T., 2011, *New Approach in Automatic Detection of Defects Propagation in Pipelines*, Pan-American Conference for Nondestructive Testing (PANNDT).
- [8] SILVA, R. R., SOARES, S. D., CALOBA, L. P., 2006, *Detection of the Propagation of Defects in Pressurized Pipes through the Acoustic Emission Technique Using Artificial Neural Networks*, Pan-American Conference for Nondestructive Testing (PANNDT).
- [9] SILVA, R. R., SOARES, S. D., MERY, D., 2007, *Evaluation of Acoustic Emission Signal Parameters for Identifying the Propagation of Defects in Pressurized Tubes*, Pan-American Conference for Nondestructive Testing (PANNDT).
- [10] SILVA, R. R., SOARES, S. D., CALOBA, L. P., SIQUEIRA, M. H. S., REBELLO, J. M. A., 2006, *Detection of the propagation of defects in pressurized pipes by means of the acoustic emission technique using artificial neural networks*, Insight Vol.48 No. 1 pp. 45-51, January 2006
- [11] PINTO, C. F. C., SILVA, R. R., CALOBA, L. P., SOARES, S. D., 2011, *Uso de Redes Neurais na Detecção de Propagação de Defeitos em Dutos Rígidos*, Artigo técnico ABENDI (www.abendi.org.br).

- [12] KANJI ONO, 2007. *Structural integrity evaluation using acoustic emission*. J. Acoustic Emission, 25, 1–20.
- [13] M.A. TORRES-ARREDONDO AND C.-P. FRITZEN, 2012. *Characterization and classification of modes in acoustic emission based on dispersion features and energy distribution analysis*. Shock and Vibration, 19, 825–833.
- [14] KANJI ONO, HIDEO CHO and M. TAKUMA, 2005. *The origin of continuous emissions*. J. Acoustic Emission, 23, 206–214.
- [15] MACHADO, R.O., 2011. *Análise de Criticidade de Descontinuidade em um Bocal de Vaso de Pressão*, Dissertação de Mestrado, PPGEM/UFRGS, Porto Alegre, RS, Brasil.
- [16] MACHADO, R. O., 2011. *Análise de Criticidade de Descontinuidade em um Bocal de um Vaso de Pressão*, Dissertação de Mestrado, UFRGS, Porto Alegre, RS, Brasil.
- [17] SOARES, S. D., 2003. *A Conservative approach to the acoustic emission technique applied to equipment subject to internal pressure*, Documento Interno CENPES-PETROBRAS, Rio de Janeiro, RJ, Brasil.
- [18] SOARES, S. D., 2003. *Monitoração de teste hidrostático de tubos com descontinuidades artificiais empregando as técnicas de emissão acústica e ultra-som*, Rio Pipeline Conference & Exposition, Rio de Janeiro, RJ, Brasil.
- [19] ADUTWUMMARFO, YING LUO, AND CHEN ZHONG-NA, 2013. *Quantitative Acoustic Emission Fatigue Crack Characterization in Structural Steel and Weld*. Hindawi Publishing Corporation Advances in Civil Engineering Volume 2013, Article ID 461529, 6 pages.
- [20] YINGXUE YAO, XIAOLI LI, ZHEJUN YUAN, 1999. *Tool wear detection with fuzzy classification and wavelet fuzzy neural network*. International Journal of Machine Tools & Manufacture, 39, 1525–1538.
- [21] WENXIU LU AND FULEI CHU, 2011. *Shaft crack identification based on vibration and AE signals*. Shock and Vibration 18, 115–126.
- [22] ZHEN WANG, PETER WILLET, PAULO R. DEAGUIAR, JOHN WEBSTER, 2001. *Neural network detection of grinding burn from acoustic emission*. International Journal of Machine Tools & Manufacture 41, 283–309.
- [23] ZHEN-LONG HU, GONG-TIAN SHEN, GUAN-HUA WU, SHI-FENG LIU, ZHAN-WEN WU, 2011. *Pattern recognition study of acoustic emission signals of aircraft fatigue cracking based on waveform analysis and artificial neural networks*. J. Acoustic Emission, 29, 309–316.
- [24] M. H. EL-GHAMRY, R. L. REUBEN AND J. A. STEEL, 2003. *The development of automated pattern recognition and statistical feature isolation. Techniques for the diagnosis of reciprocating machinery faults using acoustic emission*. Mechanical Systems and Signal Processing 17(4), 805–823.

- [25] ATHANASIOS ANASTASOPOULOS, 2005. *Pattern recognition techniques for acoustic emission based condition assessment of unfired pressure vessels*. J. Acoustic Emission, 23, 318–330.
- [26] N. F. INCE, CHU-SHU KAO, M. KAVEH, A. TEWFIK, J. F. LABUZ, 2009. *Crack growth monitoring with hierarchical clustering of AE*. J. Acoustic Emission, 27, 176–185.
- [27] LUCIO BONACCORSI, LUIGI CALABRESE, GIUSEPPE CAMPANELLA, EDOARDO PROVERBIO, 2012. *Artificial Neural Network Analyses of AE Data during Long-Term Corrosion Monitoring of a Post-Tensioned Concrete Beam*. J. Acoustic Emission, 30, 40–53.
- [28] M. BLAHACEK, Z. PREVOROVSKY, J. KROFTA, M. CHLADA. *Neural network localization of noisy ae events in dispersive media*. Institute of Thermomechanics AS CR, Prague, Czech Republic.
- [29] VERA BARAT, SERGEY ELIZAROV, IRINA BOLOKHOVA AND EVGENIY BOLOKHOV, 2012. *Application of ICI Principle for AE Data Processing*. J. Acoustic Emission, 30, 124–136.
- [30] J. BLOM, J.WASTIELS, AND D. G. AGGELIS, 2014. *Application of Acoustic Emission on the Characterization of Fracture in Textile Reinforced Cement Laminates*. Hindawi Publishing Corporation The Scientific World Journal Volume 2014, Article ID 178020, 7 pages.
- [31] VAHID EMAMIAN, MOSTAFA KAVEH, AHMED H. TEWFIK, ZHIQIANG SHI, LAURENCE J. JACOBS, JACEK JARZYNSKI, 2003. *Robust Clustering of Acoustic Emission Signals Using Neural Networks and Signal Subspace Projections*. EURASIP Journal on Applied Signal Processing 2003:3, 276–286.
- [32] L. CALABRESE, G. CAMPANELLA and E. PROVERBIO, 2010. *Use of cluster analysis of acoustic emission signals in evaluating damage severity in concrete structures*. J. Acoustic Emission, 28, 129–141.
- [33] YIBO LI, YUXIANG ZHANG, HUIYU ZHU, RONGXIN YAN, YUANYUAN LIU, LIYING SUN, AND ZHOUMO ZENG, 2015. *Recognition Algorithm of Acoustic Emission Signals Based on Conditional Random Field Model in Storage Tank Floor Inspection Using Inner Detector*. Hindawi Publishing Corporation Shock and Vibration Volume 2015, Article ID 173470, 9 pages.
- [34] ZACHARY KRAL, WALTER HORN AND JAMES STECK, 2013. *Crack Propagation Analysis Using Acoustic Emission Sensors for Structural Health Monitoring Systems*. Hindawi Publishing Corporation The ScientificWorld Journal Volume 2013, Article ID 823603, 13 pages.
- [35] GANG YAN AND JIANFEI TANG, 2015. *A Bayesian Approach for Localization of Acoustic Emission Source in Plate-Like Structures*. Hindawi Publishing Corporation Mathematical Problems in Engineering Volume 2015, Article ID 247839, 14 pages.

- [36] MAREK BALAZINSKI, ERNEST CZOGALA, KRZYSZTOF JEMIELNIAK, JACEK LESKI, 2002. *Tool condition monitoring using artificial intelligence methods*. Engineering Applications of Artificial Intelligence ,15, 73–80.
- [37] STROHAECKER, T. D., 2006, *Desenvolvimento de Procedimentos de Monitoração de Defeitos em Dutos Rígidos para a Indústria Petrolífera*. Plano de Trabalho do Projeto PETROBRAS - UFRGS, Porto Alegre, RS, Brasil.
- [38] STROHAECKER, T. D., SOARES, S. D., 2010, *Desenvolvimento de Procedimentos de Monitoração de Defeitos em Dutos Rígidos para a Indústria Petrolífera*. 3º Relatório de Projeto PETROBRAS - UFRGS, Porto Alegre, RS, Brasil.
- [39] PINTO, C. F. C., 2014, *Monitoração de Defeitos em Dutos Rígidos por Análise dos Parâmetros de Emissão Acústica utilizando Redes Neurais*, Tese de Doutorado, COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.
- [40] STROHAECKER, T. D., SOARES, S. D., 2010, *Desenvolvimento de Procedimentos de Monitoração de Defeitos em Dutos Rígidos para a Indústria Petrolífera*. 2º Relatório de Projeto PETROBRAS - UFRGS, Porto Alegre, RS, Brasil.
- [41] ASHBY, M., SHEECLIFF, H., CEBON, D., *Materiais: Engenharia, Ciência, Processamento e Projeto*. Ed. Campus, Rio de Janeiro, RJ, Brasil, 2012.
- [42] RESENDE, S. M., *A Física de Materiais e Dispositivos Eletrônicos*, Recife, PE, Brasil, Ed. Universitária da UFPE, 1996.
- [43] HAYKIN, S., VEEN, B. V., *Sinais e Sistemas*, São Paulo, SP, Brasil, Ed. Bookman, 2001.
- [44] LATHI, B.P., DING, Z., *Sistemas de Comunicações Analógicos e Digitais Modernos*., Rio de Janeiro, RJ, Brasil, Ed. LTC, 2012.
- [45] SILVA I. N., SPATTI, D. H., FLAUZINO, R. A., *Redes Neurais para engenharia e ciências aplicadas*, São Paulo, SP, Brasil, Ed. Artliber Editora Ltda., 2010.
- [46] HAYKIN, S., *Redes Neurais: princípios e prática*, Porto Alegre, RS, Ed. Bookman, 2008.
- [47] STROHAECKER, T. D., SOARES, S. D., 2010, *Desenvolvimento de Procedimentos de Monitoração de Defeitos em Dutos Rígidos para a Indústria Petrolífera*. 1º Relatório de Projeto PETROBRAS - UFRGS, Porto Alegre, RS, Brasil.
- [48] JACQUES, R.C., CLARKE, T.R. LIMA, T.R.S., 2011, *Desenvolvimento de Procedimentos de Monitoração de Defeitos em Dutos Rígidos para a Indústria Petrolífera*. Relatório de Projeto PETROBRAS - UFRGS, Porto Alegre, RS, Brasil.
- [49] JACQUES, R.C., CLARKE, T.R. LIMA, T.R.S., SOUZA, R.R., 2010, *Acompanhamento de crescimento da trinca*. Relatório de Ensaio do Projeto PETROBRAS - UFRGS, Porto Alegre, RS, Brasil.



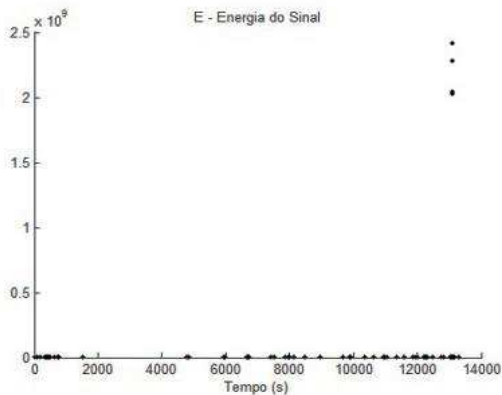



[50] JACQUES, R.C., CLARKE, T.R. LIMA, T.R.S., WU, F., 2010, *Acompanhamento de crescimento da trinca*. Relatório de Ensaio do Projeto PETROBRAS - UFRGS, Porto Alegre, RS, Brasil.

[51] MARTINS, C. O. D., 2009, *Inspeção de Dutos Rígidos*. Relatório de Atividade Específica do Projeto PETROBRAS - UFRGS, Porto Alegre, RS, Brasil.







[52] MARTINS, C. O. D., 2009, *Caracterização Metal-Mecânica*. Relatório de Atividade Específica do Projeto PETROBRAS - UFRGS, Porto Alegre, RS, Brasil.

[53] MARTINS, C. O. D., 2009, *Caracterização dos defeitos pré-existentes nos segmentos de dutos*. Relatório de Atividade Específica do Projeto PETROBRAS - UFRGS, Porto Alegre, RS, Brasil.

APÊNDICE A – GRÁFICOS DOS PARÂMETROS COMPARATIVOS

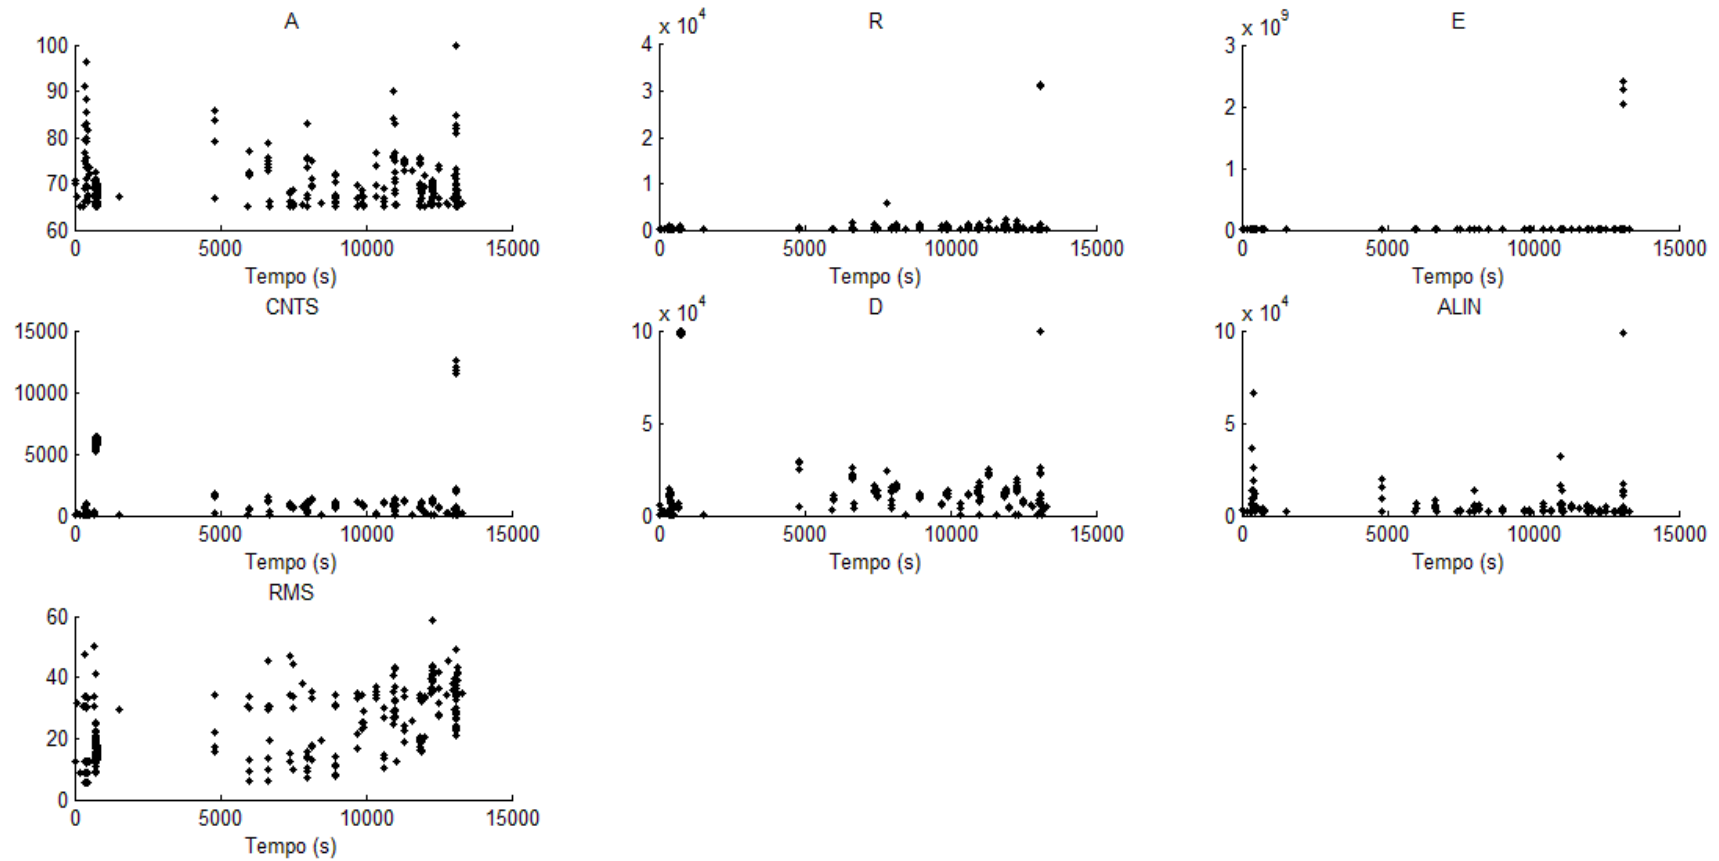


Parâmetros comuns fornecidos pelos equipamentos VALLEN




Parâmetros comuns fornecidos pelos equipamentos PAC.

APÊNDICE B – GRÁFICOS DOS PARÂMETROS VALLEN









Parâmetros fornecidos pelo equipamento VALLEN.







APÊNDICE C – GRÁFICOS DOS PARÂMETROS PAC



Parâmetros fornecidos pelo equipamento PAC.



Parâmetros fornecidos pelo equipamento PAC.



©Branco

Parâmetros fornecidos pelo equipamento PAC.

APÊNDICE D – ARTIGO

Artigo: *Analysis of the Waveforms of Acoustic Emission Signals via Analogue Modulations with Neural Networks*

Revista: Insight - Non-Destructive Testing & Condition Monitoring

Editora: The British Institute of Non-Destructive Testing

Endereço: <http://www.bindt.org/publications/insight-journal/>

Manuscript ID: INSI-11-2015-OA-0121

Analysis of the Waveform of the Acoustic Emission Signal via Analogue Modulations with Neural Networks

O Gea, L P Caloba, R R Silva, S D Soares

The acoustic emission (AE) technique is a non-destructive testing technique applied to pressurized rigid pipelines in order to identify metallurgical discontinuities. This study analyses the dynamic behaviour of the propagation of discontinuities in cracks via AE, in the following propagation classes: no propagation (NP), stable propagation (SP), and unstable propagation (UP). The methodology involves applying the concept of modulation of analogue signals, which are used in signal transmission in telecommunications, for the development of a neural network in order to determine new parameters for the AE waveform. The classification of AE signals into propagation classes occurs, therefore, through the extraction of information related to the dynamics of AE signals, by means of the parameters of the analogue carriers of the modulations (in amplitude and in angle) that make up the AE signal. This set of parameters enables an efficient classification (average of 90%) through the identification of patterns from the AE signals in the classes for monitoring the state of the discontinuity, through the use of computational intelligence techniques (artificial neural networks and non-linear classification).

Key words: non-destructive testing, acoustic emission, analogue modulation, neural network.

1. Introduction

Detection of the propagation of metallurgical defects in pressurized pipelines by means of the non-destructive acoustic emission (AE) testing technique is important in preventive inspection. However, the operational difficulty is in the classification of the AE signals into the different states of the crack (propagation classes). The study of

artificial neural networks is done in order to improve identification of the behaviour of crack discontinuity in terms of its influence on the integrity of the structure subjected to the internal pressure [1–5].

The discontinuity, when subjected to a load, may become a defect-carrying area, and thus an area of stress concentration which, due to stimulation, leads to a redistribution of localized stresses, with the quick release of mechanical stress waves, which are located internally in the material in the form of transient mechanical waves.

Thus, the biggest contribution of the technique is the analysis of the dynamic behaviour of the discontinuities, which enables the inspection of in-service equipment in order to evaluate the presence of discontinuities that could compromise the equipment's integrity.

Neural networks can be applied to systems modelling and pattern recognition, due to the process of learning by parallel and distributed processing. Thus, the learning of complex input-output mappings is made possible, due to the ability to learn from data with or without a teacher (supervised and unsupervised training). Knowledge is acquired from its environment via the learning process and it is stored in the neural connections (synapses or synaptic weights).

The main motivation of this work is the modelling of the AE phenomenon as a response of a dynamic system consisting of modulated signals (analogue modulations) determined by a neural network to provide, as a result, the classification into one of the three possible propagation classes for the crack: no propagation (NP), stable propagation (SP), and unstable propagation (UP).

In telecommunications, the modulation is used from communication systems by carriers to shift the frequency spectrum of a signal, because modulation consists of the process by which certain characteristics of the carrier are modified by a waveform, known as a modulator, $m(t)$. In the case of the carrier being sinusoidal — $\beta(t)\cos[\alpha(t)]$ — the modulation is the continuous wave (CW) type — see Figure 1.




Figure 97. Modulation process.

Analogue modulation can be classified by amplitude (linear), if the parameter in question is the amplitude of the signal, $\beta(t)$; or by angle (non-linear), if the parameters in question are the frequency (FM) and/or the phase (PM) of the signal, $\alpha(t)$. Thus, the modulations cause the linear variation of the synodic parameters (amplitude, frequency, and phase), in accordance with the modulating signal, and in turn as per the modulation type (Figure 2).




Figure 98. (a) linear modulation (AM) and (b) non-linear modulation (PM and FM) for the signal $m(t) = \cos(2\pi t)$

Visualization of the AE signal as the envelope of a composite signal — superposition of modulated signals by carriers of the analogue modulation processes of a given modulating signal — introduces a set of new features for analysis of the parameters which constitute the carriers and the modulating signal. These parameters represent the transition between the AE signals during the hydrostatic testing and used as inputs for neural networks, with the objective of identifying patterns among the propagation classes of discontinuities (NP, SP, and UP). The provision of the information regarding the propagation classes becomes an important aid in the non-destructive mechanical tests for the inspection of rigid pipes via AE.

2. Modelling

Modulation changes the format of a signal, based on another, by the variation of defining characteristics. In an amplitude modulation (AM), the signal to be transmitted (modulating), $m(t)$, influences the amplitude of a frequency carrier, f_{am} , so that the carrier's amplitude varies directly proportional to the amplitude of the signal. In phase modulation (PM) or frequency modulation (FM), the variation of the phase or frequency of the frequency carriers — f_{pm} and f_{fm} , respectively — is directly proportional to the amplitude of the modulating signal.

The following equations illustrate the concept for the modulations, in which $S_m(t)$, K_{am} , K_{pm} , and K_{fm} represent the modulated signal and the modulation constants for AM, PM, and FM, respectively [6,7].

- Amplitude Modulation (AM)

$$S_m(t) = (K_{am} + m(t)) \cdot \cos(2\pi \cdot f_{am} \cdot t) \quad (1)$$

- Phase Modulation (PM)

$$S_m(t) = A_{pm} \cdot \cos(2\pi \cdot f_{pm} \cdot t + K_{pm} \cdot m(t)) \quad (2)$$

- Frequency Modulation (FM)

$$S_m(t) = A_{fm} \cos [2\pi(f_{fm} \cdot t + K_{fm} \int_{-\infty}^t m(\alpha) d\alpha)] \quad (3)$$

Given the above information, Figure 3 illustrates the principle of the model.




Figure 99. Principal of the model.

Thus, the resulting signal, $F(t)$, can be defined as a composition of $S_{m(i)}(t)$, with a_0 , a_1 , a_2 , and a_3 constant, and a_0 being the representation of the average of the signal, as can be seen in Equation 4:

$$F(t) = a_0 + a_1 S_{m(am)}(t) + a_2 S_{m(pm)}(t) + a_3 S_{m(fm)}(t) \quad (4)$$

Due to the AE signal being a physical signal (causal signal), it only occurs for $t \geq 0$ ($u(t)$ is a step function), as can be seen in Equation 5:

$$\begin{aligned} EA(t) &\cong F(t) \cdot u(t) \cong \\ &\cong a_0 + a_1 [K_{am} + m(t)] \cos(2\pi f_{am} t) + a_2 A_{pm} \cos[2\pi f_{pm} t + K_{pm} m(t)] + \\ &\quad + a_3 A_{fm} \cos\left[2\pi \left(f_{fm} t + K_{fm} \int_0^t m(\alpha) d\alpha\right)\right] \end{aligned} \quad (5)$$

Therefore, the function representing the AE signal will be a parametric function, as shown in Equation 6:

$$EA(t) \cong a_0 + a_1 F[K_{am}, f_{am}, m(t)] + a_2 F[K_{pm}, f_{pm}, m(t)] + a_3 F[K_{fm}, f_{fm}, m(t)] \quad (6)$$

The neural network was developed with the objective of estimating the constants of the parametric function (constants K and f of Equation 6), since the independent variable is time (t). This estimate of the neural network results in the identification of the signal's behaviour in relation to its dynamics, through the amplitude, through the frequency, and through the phase in the transition between the AE signals recorded. This presents a new visual perspective of the phenomenon.

Figure 4 presents the functional description of the elements which constitute the signal flow graph model of Equation 5 — the basic internal structure of the neural network developed. Figure 5 presents, based on signal flow (Figure 4), the structure of the modulations in functional blocks in the hybrid neural network.

The term a_0 of the equations (4, 5, and 6) is disregarded in the structuring of the neural network, because in the studies of the AE signals captured, the average (expected value) approaches zero.

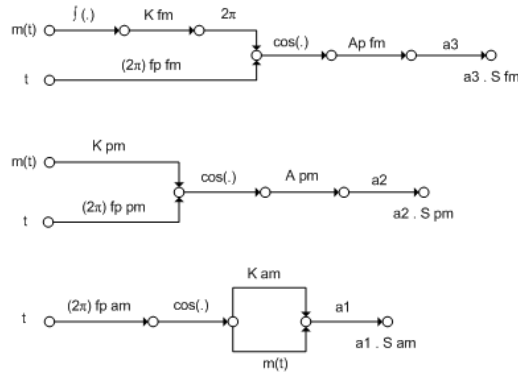


Figure 100. Graph of signal flow.

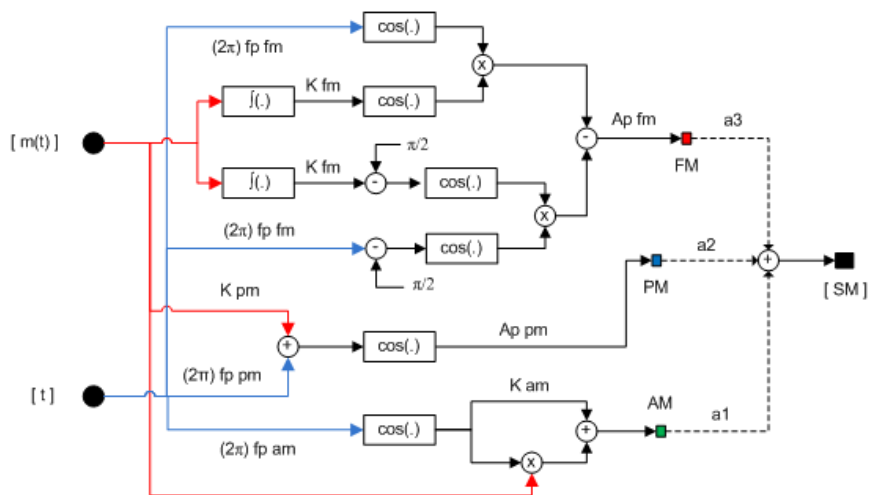


Figure 101. Structure of the hybrid neural network with the pathways of the modulations for $F(t)$.

In the neural network, multiple neurons are interconnected to form a distributed network. The configuration of these interconnections in the hybrid neural network was structured based on the graph and directed towards the definition of the topology. In the hybrid neural network, each neural block becomes responsible for a load of the processing (internal parts of the hybrid network structure). This allows the output of each block to exhibit the function that the functional block represents. This strategy is based on the fact that a neural network does not necessarily achieve data symmetry, and

the topological specification aspect of the network has, as a basis, the universal approximation theorem (Kolmogorov theorem), which provides the necessary premise for defining the structural settings of the neural blocks as "functional" in the hybrid network (approximation of analytical functions).

The hybrid neural network can be considered to be a four-layered network with characteristics of a network with time-delayed inputs. The algorithm was structured in accordance with the functioning principle of the Feedforward Neural Networks (Multilayer Perceptron Networks), in which each neuron is composed of two parts: activation potential function and activation function. The activation potential function determines how the inputs of the network are combined within the neuron in accordance with the synaptic weights, while the activation function provides the output of the neuron [8–11].

The implementation of the backpropagation training algorithm (descending gradient) is done across the hybrid network by pathways that represent each modulation (Figure 5). After the training, the synapses of the hybrid network supply the parameters of the carriers that make up the signal, by means of the connection mesh (synapses). It can be seen that the hybrid neural network is asymmetric compared to the typical structures of neural networks; therefore, the training is done internally in each neural network that constitutes a functional block (as in the whole hybrid network) through the local gradient function applied to each internal and external layer of the neural block and the hybrid network, respectively.

The characterization of the carriers by the neural network highlights behaviours that can help to understand the phenomena, because analysis by means of these carriers distributes information on aspects relevant to the modulations, in accordance with their relevance. In this type of neural network, the desired information is not in the output of the network, but in its structure in the form of synaptic weights that represent the parameters of the carriers. The hybrid neural network offers the best combination of AM, PM, and FM in the learning, through the reduction of the mean squared error (supervised training).

3. Experimental Test

The hydrostatic tests were performed on API-XL 60 specification steel specimens (pipeline segments) with seams, a nominal diameter of 20 inches (50.8 cm), length of 2.0 m, and 14.5 mm thick walls. Their ends were machined to enable the assembly of two flanges for containment of the pressurization fluid (sealing with rubber o-rings). An external crack was machined at the centre of the pipe, and fatigue was subsequently introduced, via load cycles, in order to cause a semi-elliptical defect 160 mm long, 7.33 mm deep (ratio of around 20:1), and 1.1 mm wide.

The specimen was considered to be a thin-walled reservoir, because the ratio between the thickness of the wall and the radius of the pipe was less than 0.1. The specimen was submitted to a load by means of variation of the internal pressure, in accordance with the loading curve, up to the point equivalent to 90% of the yield strength of the material.

The behaviour of the crack was accompanied through the AE systems (VALLEN⁴⁰ and PAC⁴¹), the ultrasound was accompanied via time of flight diffraction

⁴⁰ <http://www.vallen.de/>

⁴¹ <http://www.physicalacoustics.com/>

(ToFD), while the extensometry was monitored via electrical resistance for recordings of the dimensions of the discontinuity in the crack during the hydrostatic testing. The AE system consisted of VALLEN and PAC sensors positioned as shown in Figure 6. A detection threshold of 45dB was fixed in the PAC with resonant sensors at 150 kHz. For the VALLEN, a detection threshold of 65dB was fixed for the resonant sensors at 150 kHz, with a sampling rate of 1 MHz and 200 pre-trigger samples. The ultrasound via ToFD was done with wedges of 10 MHz, transducers of 60°, and an acquisition rate of 1Hz.

The VALLEN sensors distributed in the specimen recorded the AE signal waveforms during the test in accordance with the time distribution by sensor (Figure 6). The test behaviour (testing time, internal pressure, AE signals recorded by the VALLEN equipment, and the depth of the crack) is demonstrated by the graphs in Figures 7 and 8.

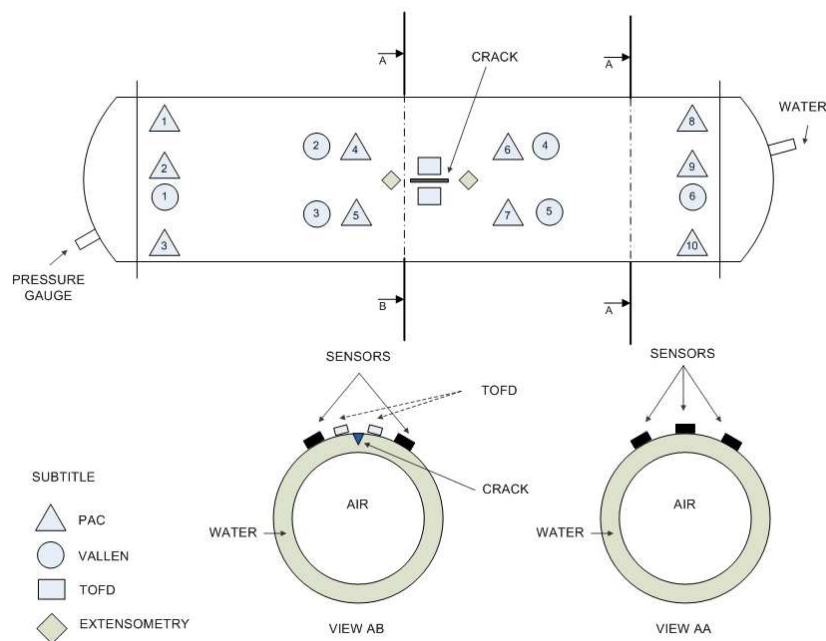


Figure 102. Structure of the specimen

Figure 7 shows the pressure curve, the depth of the crack during the hydrostatic testing, and the recordings of AE signals captured. Pressure levels were programmed during the pressurization cycle in the test. At these levels, the pressure was kept constant for a minimum of 10 min; however, the last level was maintained for a minimum of 60 min. The average incremental pressure rates during loading were 10.0 bar/min until the first level, and 2.5 bar/min at the other levels until reaching the nominal pressure equal to 90% of the yield strength of the pipe material planned for the last level.

The total rupture of the pipe occurred at the end of the last level of the first loading cycle, so it was not possible to perform the second loading cycle.




Figure 103. Pressure distribution, ToFD, and AE recorded during the hydrostatic test (1 bar = 0.980 kgf/cm²).




Figure 104. AE recordings by sensor during the hydrostatic testing with the VALLEN and PAC equipment.

The high number of signals (spurious signals) recorded at the beginning of the test (up until 2.10^3 s) — 25% coming from sensors near the crack and 75% from sensors at the extremities of the specimen — was due to the adjustment of the sealing system and the entry of the water at the beginning of the pressurization.

The propagation classes of the discontinuity were defined based on the behaviour in the variation of the crack in accordance with the internal pressure variation (Table 1):

- No propagation (NP): The discontinuity of the crack undergoes minor changes in size for large pressure variations (metallurgical adjustment).
- Stable propagation (SP): The discontinuity of the crack undergoes changes in size for pressure variations (elastic effect).
- Unstable propagation (UP): The discontinuity of the crack undergoes significant changes in size for little or no pressure variation (inelastic or plastic effect).

Table 1 shows the quantitative distribution of the propagation classes for the discontinuity of the crack in the hydrostatic test.

Table 6. Statistics for the NP, SP, and UP classes.

	Time interval ($\cdot 10^3$ s)		
	[02,06]	[06,12]	[12,14]
Variation of the crack	0.34%	13.29%	35.40%
Pressure variation	59.87%	19.63%	0%
Number of signals (centre of the pipe)	7	65	40
Number of signals (extremities)	3	40	22

The need to study the EA phenomenon via new parameters based on the waveform is important because of the difficulty encountered in identifying patterns, even using the same recorded parameters (amplitude, rise time, energy, and count/duration) for equipment from different manufacturers (VALLEN and CAP), as illustrated in Figures 9 and 10. Currently, the parameters of this equipment are used in the analysis of AE signals in the search for cracks and/or faults in the integrity of rigid pipelines; however, without the characterization of the propagation classes.

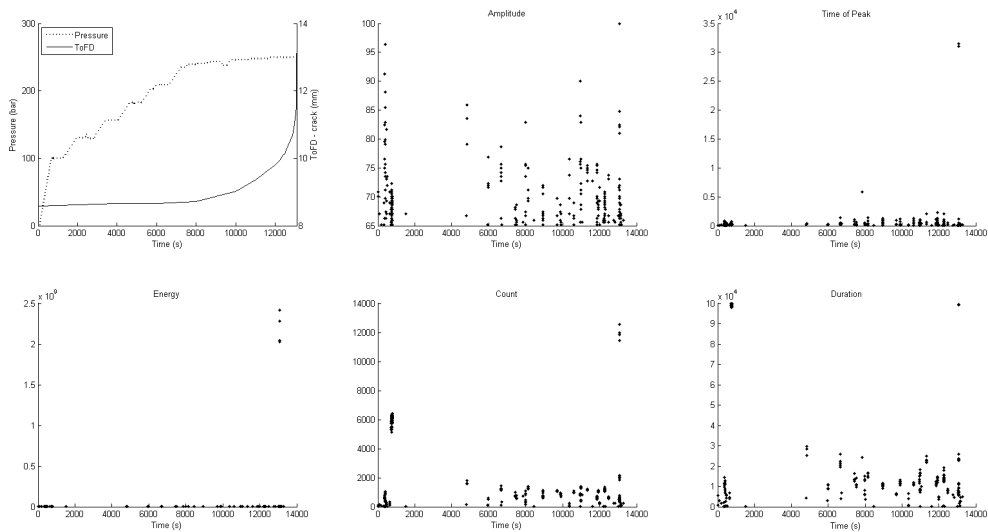


Figure 105. VALLEN parameters

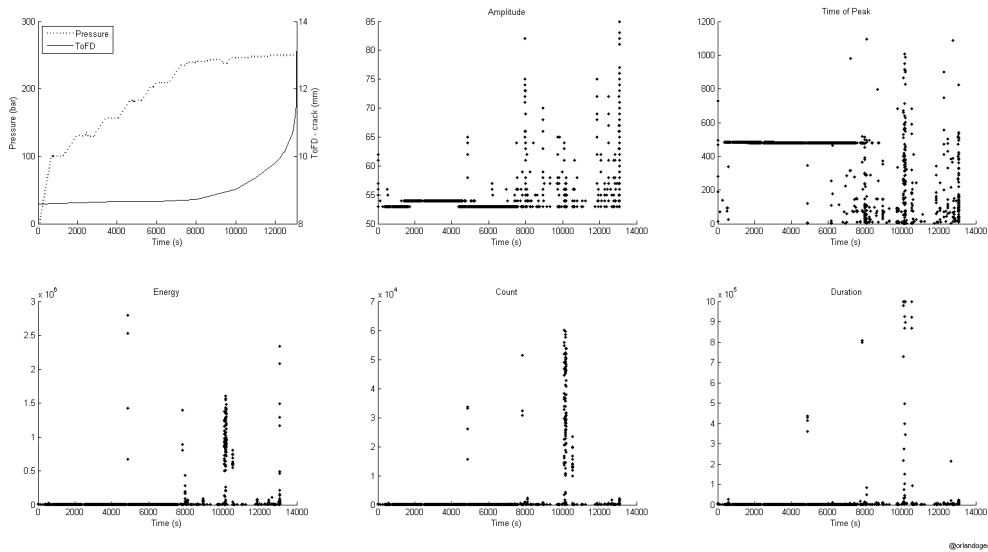


Figure 106. PAC parameters.

Works using these parameters have been done using neural networks for the identification of the propagation classes [2–4].

The difference between the distributions for the same parameters, measured by different equipment, results in inaccurate conclusions regarding the possible propagation regions of the discontinuity. Thus, analysis of the carrier parameters that make up the AE signal is important for the categorization of the states of the discontinuity in the crack, because they illustrate the transition phenomenon in the AE signals.

4. Application of the Methodology in the Testing

Usage based on the signal decomposition technique aims for the identification of different classes in accordance with the behaviour of the crack's propagation: no propagation (NP), stable propagation (SP), and unstable propagation (UP).

The AE signals from the testing consist of a set of observations, $\{Z[Y_i], i \in N\}$, in which the signal is a set — $\{Y(t), t \in T\}$ — and $T = \{t: t_1 < t < t_2\}$, as can be seen in Figures 11 and 12. The objective becomes, therefore, to understand the differences between the signals, and this enables the classes and their elements to be presented.




Figure 107. Examples of AE signals in the SP class.




Figure 108. Example of the AE signals in the UP class.

The AE signals were analysed in the frequency domain in groups (elements of the SP and UP classes), as per Figures 13 and 14, with a view to determining the size of the cut-off window in the original AE signal. The cut-off was done in order to improve the result of the hybrid neural network training, because more than 50% of the signal could be disregarded, with the boundary of the main spectrum predominating and the suppressed part assumed to be noise (Figure 15).




Figure 109. Frequency spectrum of the AE group in SP (Figure 11)




Figure 110. Frequency spectrum of the AE group in UP (Figure 12)

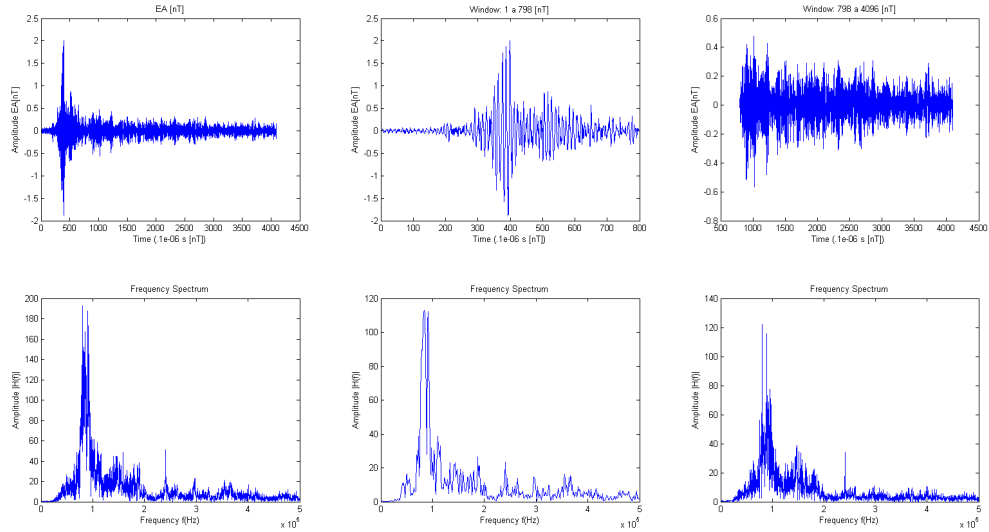


Figure 111. Example of AE signal, cut-off window of the AE signal, and suppressed part (noise), as well as their respective frequency spectra.

The hybrid network was trained (supervised training) with the AE signals in order to provide the set of carrier parameters that make up each recorded signal. These parameters consisted of a new data set, which presented the dynamics of the signals in the SP and UP regions.

From the set of carrier parameters for each AE signal recorded during the hydrostatic testing, unsupervised learning techniques were applied to complete the identification of patterns among the propagation classes for the crack discontinuity:

- **K-means method:** the K-means algorithm is one method used to find groups and the centres of these groups, based on a data set with no prior classification. The idea is to partition a data set into separate groups, in which the Euclidean distance between the attributes vector and the representatives of the classes is used as a dissimilarity measure (Table 2).
- **Self-organizing map:** method that is particularly useful when there is non-linear mapping inherent in the problem itself. Enables the transformation of an arbitrarily-sized input standard into a two-dimensional discrete map, in a topologically adaptive manner (Figure 16).

Table 7. Average percentage of hits with k-means, for classification of the AE signals based on the carrier parameters.

SP	UP
91.2%	94.3%




Figure 112 . Example of map resulting from the parameters of the signals in the SP class.

The non-supervised techniques were used based on the parameter set established by the hybrid neural network during the supervised training, for the signals of both the SP and UP classes (Table 1). The error percentage via the K-means method is basically concentrated in the transition region between the SP and UP classes (Table 1 and Figure 7). This transition region is also illustrated in the self-organizing map — see Figure 16. The transition region (Table 1) for this study was defined on the basis of the experience of experts in the area of instrumentation. Thus, any changes in this area will bring new results, and, therefore, part of the studies involves the best definition of the transition range [1–4].

For the purposes of metallurgical inspection using the AE method, the main objective of using the technique with the neural network is the knowledge of the transition phase between the SP and UP classes, based on new characteristics, because this reduces the likelihood of damage to the integrity of the pressurized pipe occurring during operation (UP class).

5. Conclusions

The results were satisfactory, including for both the controlled test of the model (with deterministic signals applied to the network) and for the AE signals (stochastic signals) presented to the hybrid network.

The hybrid network represented a neural circuit structured in functional blocks (neural networks), with direct and indirect influence between them due to the segregation of activities by neural block. The network exhibited results for the context signals, both by the transition analysis (compared with the previous signal) and by the analysis based on a deterministic signal (compared with a given signal).

The decomposition of the signal into three other waveforms, modelled by the carriers of analogue modulations, enables the characteristics of the phenomenon to be visualized.

Modulation and demodulation are usually done via complex circuit techniques; however, the hybrid neural network presented a practical and efficient solution for the application of this technique utilized in telecommunications and signal processing. The AM modulation exhibits the characteristics of the phenomenon's amplitude in a new waveform, while the same principle is identified by the PM and FM modulations in relation to the phase and frequency requirements, respectively.

Through the incorporation of time into the operation of a neural network, the network becomes capable of perceiving the statistical variations in non-stationary processes.

The implicit representation of time enables a static neural network (multilayer perceptron) with dynamic properties (with short-term memory). Thus, it is an approach for a nonlinear dynamic system, in which the static network is responsible for the nonlinearity and the memory is responsible for the time.

6. Acknowledgements

Thanks go to: the Carlos Chagas Filho Research Support Foundation of the State of Rio de Janeiro (FAPERJ) and the Coordination for the Improvement of Higher Education Personnel (CAPES), for the financial support via scholarships; the Leopoldo Américo Miguez de Mello Centre for Research and Development (CENPES) of PETROBRAS for enabling the research and development project in partnership with COPPE-UFRJ and UFRGS; and the LAMEF at UFRGS for the technical and operational support in the hydrostatic tests.

7. References

- (1) C F C Pinto, R R da Silva, L P Calôba and S D Soares, 'Probability of defect propagation in pipelines (POP curves)', *Insight*, 56 (4), pp 1-7, 2014.
- (2) R R Silva, L P Calôba, M H S Siqueira, L V S Sagrilo and J M A Rebello, 'Detection of the Propagation of Defects in Pressurized Pipes through the Acoustic Emission Technique Using Artificial Neural Networks', *ECNDT - Poster 1*, pp 1-17, 2006.
- (3) 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.
- (4) 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.
- (5) S D Soares, 'Correlações entre Emissão Acústica de Defeitos e Parâmetros de Mecânica da Fratura na Avaliação da Integridade de Equipamentos Pressurizados', D.Sc. thesis, Universidade Federal do Rio de Janeiro, Rio de Janeiro, Brazil, 2008
- (6) B. P. Lathi, *Modern Digital and Analog Communication Systems*, Oxford University Press, 1988.
- (7) H. Sizun, *Radio wave propagation for telecommunication applications*, Springer, 2010.

(8) M. H. Hassoum, *Fundamentals of Artificial Neural Networks*, The MIT Press. Cambridge, 1995.

(9) S Haykin, *Neural Networks – A Comprehensive Foundation*, Macmillan College Publishing Inc, USA, 1994.

(10) S. Samarasinghe, *Neural Networks for Applied Sciences and Engineering – From Fundamentals to Complex Pattern Recognition*, Auerbach Publications, USA, 2007.

(11) I. N. da Silva, D. H. Spatti, R. A. Flauzino, *Redes Neurais Artificiais para Engenharia e Ciências Aplicadas*, Artliber Editora Ltda, Brasil, 2010.