

MONITORAMENTO DE DEFEITOS EM DUTOS RÍGIDOS POR PARÂMETROS DE EMISSÃO ACÚSTICA E REDES NEURAIS*

*Luiza Ribeiro Marnet¹
Luiz Rennó Costa²
Carlos Fernando Carlim Pinto³
Francesco Nosedà⁴
Luiz Pereira Calôba⁵*

Resumo

Utilizar os conceitos da indústria 4.0 na análise de trincas em dutos pressurizados é uma forma de tornar este processo independente da análise humana, diminuir custos e perda de tempo com inspeções do equipamento. O método de Emissão Acústica se destaca entre os ensaios não destrutivos pela possibilidade de analisar a integridade de equipamentos durante o seu uso. Utilizar redes neurais para analisar os sinais de emissão acústica provenientes de trincas pode ser uma forma de inspeção em tempo real. Deformações em materiais podem ser classificadas em sem propagação, propagação estável e propagação instável, e é importante corrigi-las antes que a última classe seja alcançada. O objetivo deste trabalho é o uso de redes neurais supervisionadas para determinar os estágios de propagação de trincas utilizando parâmetros de sinais de emissão acústica. Esta pesquisa analisa fissuras em tubos pressurizados com 40 m, sendo uma continuação de um trabalho que analisa fissuras em tubulações com 1,81 m. A rede neural da pesquisa com dutos mais curtos alcançou aproximadamente 91% de sucesso e, até o momento, esse novo trabalho, com dutos mais longos, obteve sucesso de quase 94%, mostrando que a técnica desenvolvida para dutos curtos também pode ser utilizada em dutos longos.

Palavras-chave: Rede Neural; Emissão Acústica; Classificador Supervisionado; Ensaio Não Destrutivo.

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

Abstract

Using industry 4.0 concepts in the analysis of cracks in pressurized pipelines is one way of making this process independent of human analysis, reducing costs and wasting time with equipment inspections. The Acoustic Emission methods stands out among nondestructive testing for the possibility of analyzing the integrity of the equipment during its use. Using neural networks to analyze acoustic emission signals from cracks can be a form of real time inspection. Deformations in materials can be classified into no propagation, stable propagation and unstable propagation, and it is important to correct it before the last class be reached. The objective of this work is the use of supervised neural networks to determine the stages of crack propagation using acoustic emission signal parameters. This research analyses cracks in pressurized pipelines with 40 m, being a continuation of a work that analyses cracks in pipelines with 1.81 m. The neural network of the research with shorter pipelines has reached approximately 91% success and, so far, this new work, with longer pipelines, has succeeded almost 94%, showing that the technique developed for short pipelines can also be used in longer ones.

Keywords: Neural Network; Acoustic Emission; Supervised Classifier; Nondestructive Testing.

- ¹ Engenharia de Controle e Automação, M.Sc., Programa de Engenharia Elétrica, UFRJ, Rio de Janeiro, RJ, Brasil.
- ² Engenharia Eletrônica e de Computação, M.Sc., Programa de Engenharia Elétrica, UFRJ, Rio de Janeiro, RJ, Brasil.
- ³ Engenharia Eletrônica e de Computação, D.Sc., Programa de Engenharia Elétrica, UFRJ, Rio de Janeiro, RJ, Brasil.
- ⁴ Matemática, Ph.D., Instituto de Matemática, UFRJ, Rio de Janeiro, RJ, Brasil.
- ⁵ Engenharia Eletrônica, Dr.Ing., Programa de Engenharia Elétrica, UFRJ, Rio de Janeiro, RJ, Brasil.

1 INTRODUÇÃO

A indústria 4.0, considerada como a quarta revolução industrial, tem como uma de suas características o desenvolvimento de sistemas cyber físicos, que integram sistemas físicos e virtuais [1]. Além disso, como explica Stancioiu [2], esse desenvolvimento industrial permitiu uma nova forma de operar sistemas de produção, permitindo análise de dados em tempo real, monitorando a avaliação dos equipamentos com o auxílio dos sistemas cyber físicos desenvolvidos.

Utilizar os conceitos da indústria 4.0 na análise de trincas em dutos pressurizados é uma forma de tornar este processo independente da análise humana, diminuindo o custo e perda de tempo com paradas desnecessárias na produção.

Uma forma de monitorar em tempo real a formação e propagação de trincas em dutos rígidos pressurizados é utilizar testes de emissão acústica, que são um tipo de ensaio não destrutivo (END), em conjunto com técnicas de análise de dados. Os ENDs são exames, avaliações ou testes realizados em um objeto sem causar qualquer forma de alteração no mesmo. Exemplos de ensaios não destrutivos são testes visuais, penetrantes, de partículas magnéticas, ultrassônicos, de radiografia, de corrente de Foucault, teste infravermelho térmico e de emissão acústica [3]. Esse tipo de ensaio é de fundamental importância dentro da indústria, pois permite a análise da integridade dos materiais, diminuindo o risco de acidentes e, assim, aumentando a segurança dos processos.

Dentre os métodos de ensaio não destrutivo, o de Emissão Acústica (EA) se diferencia dos outros por ser o único em que o material sob inspeção emite sinais quando alguma falha está para acontecer. Este método se baseia no fato de que materiais sólidos emitem sinais acústicos quando sofrem deformações devido à estresses mecânicos ou térmicos. Quando comparado aos outros END, a EA possui como uma de suas vantagens a possibilidade de monitorar os equipamentos em tempo real e sob qualquer condição de operação. Por outro lado, apenas os defeitos em formação ou propagação podem ser identificados por testes de EA [4]. Outra desvantagem da Emissão Acústica é a perda de amplitude que o sinal sofre a medida que o mesmo se propaga ao longo do material que está em teste, se tornando uma possível limitação quanto a distância máxima que o sensor responsável por captar os sinais precisa estar da deformação para que a falha ainda consiga ser identificada [3].

Com o objetivo de monitorar a integridade de equipamentos, diversos pesquisadores desenvolveram trabalhos que utilizam dados de testes de emissão acústica em conjunto com métodos de análise de dados.

Yuki e Homma [5] treinaram uma rede neural artificial com formas de onda simuladas por um sensor piezoelétrico de cerâmica e conseguiram, com esta rede, determinar a forma de onda correta gerada por uma determinada propagação de trica.

Em seus estudos, Kral et al. [6] começaram a pesquisar o desenvolvimento de um sistema de monitoramento da integridade de aeronaves em tempo real possível de ser utilizado durante voos. Os autores treinaram redes neurais *feedforward* capazes

de calcular o comprimento que uma trinca cresce ao sofrer um estresse. Como entrada da rede foi utilizada uma medida desenvolvida pelos pesquisadores que se baseia no histograma das amplitudes dos eventos de emissão acústica ocorridos em uma determinada janela de tempo. Além de conseguirem desenvolver uma rede capaz de medir o crescimento da trinca, os autores também apresentaram fortes indícios de que é possível encontrar a posição da falha em um corpo de prova através da comparação da amplitude de uma mesma onda acústica captada por sensores posicionados em diferentes lugares em relação a trinca.

Dai et al. [7] realizaram uma análise de quais são os parâmetros calculados a partir de sinais provenientes de emissões acústicas gerados por trincas em dutos que são mais relevantes para modelar e treinar uma rede neural *feedforward* capaz de diferenciar sinais provenientes de trincas com propagação dos sinais de trincas que não estão se propagando.

O trabalho de Yang et al. [8] conseguiu desenvolver um classificador capaz de identificar quatro diferentes tipos de trincas em revestimentos de barreira térmica. Para isso, foram obtidos os coeficientes de energia de *wavelet* dos sinais de emissão acústica proveniente das trincas, e utilizou-se esses coeficientes como entrada de uma rede neural treinada pelo algoritmo *backpropagation* com o objetivo de identificar os tipos de trinca.

Para identificar e classificar defeitos formados em peças construídas ou reparadas por deposição de metal a laser Gaja e Liou [9] utilizaram parâmetros de sinais de emissão acústica. Em seu trabalho, puderam observar que o nível dos sinais de ruído gerados nesse tipo de aplicação é muito inferior ao nível dos sinais obtidos devido a formação de defeitos. Após identificar a ocorrência de defeitos através do nível dos sinais, os parâmetros dos sinais identificados como defeitos foram utilizados para desenvolver dois classificadores que deveriam ser capazes de identificar o tipo de defeito associado a cada sinal (poro ou trinca). Um dos classificadores utilizou o método de regressão logística e o outro de rede neural treinada pelo algoritmo *backpropagation*, e ambos foram capazes de identificar o tipo de defeito em questão.

Em suas pesquisas Zhang et al. [10] desenvolveram um classificador para avaliar a condição de trilhos ferroviários utilizando sinais de emissão acústica. Foi desenvolvida uma rede neural convolucional cujos parâmetros de entrada foram características de frequência extraídos de uma Transformada Rápida de Fourier dos sinais de emissão acústica e cuja saída classificava cada entrada como 'estado seguro' ou 'estado não seguro'.

Da Silva et al. [11] desenvolveram um trabalho em que sugerem que o crescimento de trincas em dutos pressurizados pode ser dividido em duas fases: sem propagação e com propagação. Em suas pesquisas, foram analisados parâmetros de emissão acústica gerados em um experimento no qual uma trinca foi inserida em um duto pressurizado. Redes neurais foram treinadas para classificar as fases de propagação do defeito, e se conseguiu obter aproximadamente 92% de sucesso na identificação das classes. Em suas pesquisas Pinto et al. [12] propuseram que a classe com propagação fosse dividida em duas, uma de propagação estável e outra

de propagação instável, e as redes neurais que treinaram chegaram a alcançar até 86% de acerto de classificação.

De acordo com Pinto [13], a propagação de deformações pode ser dividida em três fases: a fase inicial, em que não há propagação, a fase intermediária, em que ocorre uma deformação estável, e a última, na qual ocorre a deformação instável. Em determinados equipamentos, como dutos pressurizados, é importante identificar quando uma deformação instável está para ocorrer, de forma que se interrompa o processo de produção para reparo antes de um defeito entrar nesta fase de propagação, o que causaria um acidente, mas sem pará-lo precocemente, o que geraria uma diminuição desnecessária da produção.

Como já foi demonstrado por Pinto [13], os sinais acústicos emitidos em cada fase de propagação das deformações possuem características diferentes que podem ser identificadas por métodos de análises de dados. Em seus trabalhos, Pinto [12, 13, 14] demonstrou ser possível classificar, através de redes neurais *feedforward* e de mapas neurais auto organizáveis (SOM), as fases de propagação de trincas em dutos pressurizados de pequeno comprimento (1,81 m). No entanto, para saber se estes métodos também poderiam ser aplicados à dutos longos, um trabalho de pesquisa, similar ao realizado por este autor, precisaria ser executado.

O objetivo do projeto aqui descrito é dar continuidade aos estudos da classificação da fase de propagação de defeitos em dutos rígidos pressurizados através da análise dos parâmetros de sinais de Emissão Acústica (EA) por redes neurais [13]. Para isso, foram empregadas metodologias já apresentadas em projetos anteriores, porém, nos estudos anteriores [13] foram utilizados dutos curtos de 1,81m, enquanto no presente projeto foram utilizados dutos longos de 40m.

2 DESCRIÇÃO E ANÁLISE DOS TESTES DE EMISSÃO ACÚSTICA

2.1 Emissão Acústica

Quando um material sólido está se deformando devido à pressão térmica ou mecânica, o mesmo emite emissões acústicas sônicas ou ultrassônicas. É nessa propriedade de emitir pulsos acústicos durante as deformações que os testes de emissão acústica se baseiam, sendo os únicos testes não destrutivos em que o próprio material emite os sinais de que uma falha está ocorrendo. Por outro lado, as emissões acústicas só acontecem durante a deformação, de forma que falhas já existentes, que não estão se propagando, não emitem novos pulsos [4].

Ainda de acordo com Mix [4], após terminar a emissão acústica emitida por um material devido a uma deformação, mesmo que a pressão que causou esta deformação seja removida do material e aplicada novamente, só ocorrerão novas emissões acústicas quando a intensidade da pressão for maior do que a intensidade anteriormente atingida. A esta propriedade é atribuído o nome de efeito Kaiser.

De acordo com Hellier [3], a pressão pode ser calculada pela força aplicada dividida pela área na qual se aplica a mesma, sendo como um campo interno de forças que equilibra as forças externas aplicadas à uma estrutura. Segundo estes autores, como reação à pressão aplicada, uma estrutura tem a sua forma modificada,

podendo ser uma alteração elástica (temporária) ou, caso a pressão seja suficientemente grande, plástica (permanente). Nas deformações, ocorre uma mudança na estrutura atômica do material, e essa mudança gera emissões acústicas.

2.2 Detecção dos Sinais de EA

Os sensores que detectam as emissões acústicas recebem a energia mecânica das ondas elásticas das EAs e a convertem em sinais elétricos, podendo, assim, ser denominados de transdutores [15].

De acordo com Mix [4], os sistemas de emissão acústica, para transformar os sinais detectados em conjuntos de dados, estabelecem níveis limites (*thresholds*), positivos e negativos, que, ao serem ultrapassados, considera-se que houve a ocorrência de uma emissão acústica. Caso os sinais não sejam ultrapassados, considera-se que apenas ocorreram ruídos.

Para se identificar os sinais de emissão acústica ao longo dos sinais elétricos gerados pelos sensores de EA, são necessários os seguintes parâmetros de tempo: *Hit Definition Time* (HDT), *Hit Lockout Time* (HLT) e *Peak Definition Time* (PDT). A Figura 1, a seguir, auxilia no entendimento desses três parâmetros. Um evento de emissão acústica começa a ser detectado quando a voltagem (nível do sinal) ultrapassa pela primeira vez, positiva ou negativamente, o valor de *threshold* predeterminado. Após a primeira ultrapassagem, o tempo definido para PDT começa a ser contado regressivamente. Caso não ocorra nenhum outro pico de sinal com valor maior do que o do primeiro pico após a primeira ultrapassagem do *threshold* dentro dos PDT segundos, o primeiro pico será definido como a amplitude de pico máxima. Caso contrário, a contagem regressiva de PDT recomeça no momento em que o valor do pico máximo for ultrapassado. O parâmetro HDT serve para determinar o final de um evento de emissão acústica. Quando HDT segundos se passarem sem que o sinal ultrapasse novamente o valor do *threshold*, o final do evento de emissão acústica é definido como a última ultrapassagem ocorrida antes do início da contagem de HDT. Por último, para evitar que um evento de reflexão seja detectado como um novo evento de emissão acústica, ao longo de HLT segundos após o final da contagem de HDT segundos, nenhum outro evento é coletado [15].




Figura 1. Parâmetros de Tempo para Detectar Eventos de EA [16].

A Figura 2, abaixo, ajuda a clarear o entendimento de alguns dos parâmetros de emissão acústica retirados dos sinais captados. O valor de pico de amplitude máxima é a 'Amplitude Máxima' apontada na Figura 2. O tempo de chegada é o tempo do teste de emissão acústica em que um determinado evento começa a ser detectado, na Figura 2 este tempo acontece no segundo 0 (zero). Por fim, o número de contagens, ou contagens de pico, é o número de vezes que o valor de *threshold* é ultrapassado ao longo de um evento de EA. No caso da Figura 2 o número de contagens foi igual à 5.




Figura 2. Parâmetros Extraídos dos Eventos de Emissão Acústica [4].

2.3 Dados Do Teste Hidrostático

Os dados utilizados foram obtidos em um ensaio hidrostático realizado no Laboratório de Metalurgia Física (LAMEF) da Universidade Federal do Rio Grande do Sul (UFRGS). Este ensaio fez parte do projeto "Inspeção de Dutos Rígidos", realizado conjuntamente pelo Cenpes (Centro de Pesquisa Leopoldo Américo Miguez de Mello) da Petrobras (Petróleo Brasileiro S.A.) e a UFRGS. A dimensão da trinca ao longo do ensaio foi monitorada por um transdutor de TOFD (transdutor de ultrassom) e para adquirir os parâmetros de emissão acústica foi utilizado o controlador Disp 16C com sensores R151-AST do fabricante PAC (Physical Acoustic). A Figura 3 mostra o gráfico da dimensão da trinca e da pressão aplicada ao longo do tempo do teste hidrostático realizado. Como pode ser observado, a pressão foi elevada aos poucos, com patamares de pressão mantida estável entre cada período de elevação, até a trinca se propagar a ponto de romper o duto.

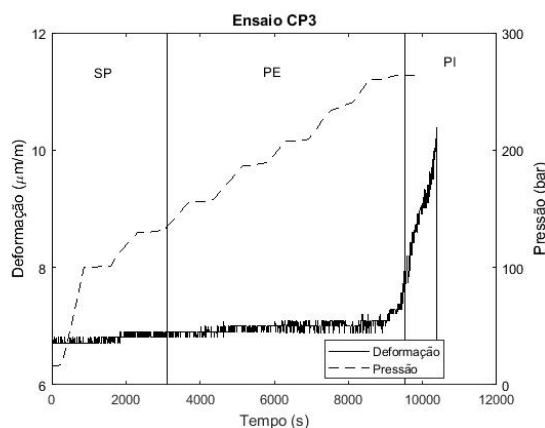


Figura 3. Curvas de Deformação da Trinca e Pressão ao Longo do tempo de Ensaio de Emissão Acústica.

Foi utilizado no experimento um corpo de prova de aço API XL série 60, 20 polegadas de diâmetro 0,0145 m de espessura e 40 m de comprimento, no qual foi inserida uma fissura elíptica nas superfícies interna e externa.

A Tabela 1 descreve os 19 parâmetros extraídos do teste de EA.

Tabela 1. Parâmetros Extraídos dos Eventos de Emissão Acústica [13]

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

3REDES NEURAIS

3.1 Teoria de Redes Neurais Feedforward e Algoritmo Backpropagation

As redes neurais são processadores intensivos de dados que possuem unidades de processamento simples, os neurônios, e se assemelham ao cérebro humano por adquirirem conhecimento acerca de seu ambiente através de processos de aprendizado, que se baseiam na adaptação ordenada de pesos sinápticos que interligam os neurônios [17].

Neste trabalho, decidiu-se por utilizar redes do tipo perceptron multicamadas (Multi Layer Perceptron - MLP). De acordo com Da Silva et al. [18], as redes perceptron multicamadas (MLP) possuem o tipo de arquitetura *feedforward*, ou seja, o fluxo de informação corre sempre adiante, passando dos dados de entrada para a primeira camada intermediária, desta para a seguinte, e assim por diante, até chegar na saída da rede. Assim, a arquitetura original das redes MLP não possui nenhuma forma de realimentação de valores. O autor ainda ressalta que o treinamento das redes MLP se dá pelo algoritmo *backpropagation*, também conhecido como algoritmo de retropropagação do erro ou regra delta generalizada, que é um treinamento supervisionado.

No treinamento supervisionado, de acordo com Haykin[17], é como se existisse um professor que possui conhecimento acerca do ambiente sobre o qual a rede precisa conhecer. Assim, para cada vetor de dados de entrada fornecido para a rede durante o período de treinamento, a mesma dá uma resposta de saída que é comparada com a resposta ideal fornecida pelo professor. A comparação entre a resposta da rede e a ideal gera um erro que é utilizado para alterar as sinapses da rede. Esse treinamento deve ocorrer até que a rede obtenha o máximo de informação possível do professor.

O treinamento *backpropagation*, de acordo com Da Silva et al. [18], ocorre em duas etapas: a etapa de propagação adiante, ou *forward*, e a etapa de propagação reversa, ou *backpropagation*.

Na etapa de propagação adiante, a informação é passada camada a camada da entrada até a saída da rede. Observando a Figura 4, abaixo, $W_{ji}^{(L)}$ representa a sinapse que liga a entrada do neurônio j da camada L à saída do neurônio i da camada $L-1$, $I_j^{(L)}$ é a entrada do neurônio j da camada L e $Y_j^{(L)}$ é a saída do neurônio j da camada L . A camada 1 é a primeira camada escondida de neurônios, a camada 2 a segunda camada de neurônios e assim por diante até a última camada. Também deve-se notar que a saída da rede é igual a saída dos neurônios da camada de saída.




Figura 4. Arquitetura de uma Rede Perceptron Multicamadas.

As equações (1) e (2), a seguir, descrevem como ocorre o treinamento durante essa fase. As equações abaixo descrevem a formulação matemática de $\square_{\square}^{(L)}$ e $\square_{\square}^{(L)}$ [18]:

$$\square_{\square}^{(L)} = \sum_{\square=0}^{\square} \square_{\square}^{(L)} * \square_{\square} \quad (1)$$

$$\square_{\square}^{(L)} = g(\square_{\square}^{(L)}) \quad (2)$$

Onde \square_{\square} é o número de entradas da rede no caso da primeira camada escondida e o número de neurônios da camada anterior no caso das demais camadas. E $g(\cdot)$ é uma função de ativação contínua e diferenciável em todo o seu domínio e \square_0 o limiar, ou bias, de forma que $\square_{\square 0}^{(L)}$ é a sinapse que liga o neurônio j da camada L ao seu bias.

Antes de iniciar a fase de *backpropagation*, devem ser calculados os erros das saídas da rede, em relação aos quais as sinapses serão atualizadas. O erro de cada saída para uma dada amostra $\square(\square)$ é calculado como a diferença entre a saída da rede $\square_{\square}^{(L)}$ e o valor ideal $\square_{\square}(\square)$ esperado para a amostra $\square(\square)$. A partir desses erros também é possível medir o desempenho da rede em relação a uma amostra como o erro quadrático:

$$\square(\square) = \frac{1}{2} \sum_{\square=1}^{\square} (\square_{\square}(\square) - \square_{\square}^{(L)})^2 \quad (3)$$

Na equação (3), acima, m é o número de neurônios da camada de saída. Sendo uma época igual a apresentação para a rede de todas as \square amostras de treinamento por uma vez, o erro médio quadrático da rede ao final de uma determinada época é:

$$\square_{\square} = \frac{1}{\square} \sum_{\square=1}^{\square} \square(\square) \quad (4)$$

Por fim, para calcular o quanto as sinapses da rede devem variar devido aos erros referentes a uma época de treinamento, o erro é retropropagado. De acordo com Da Silva et al. [18], as sinapses devem ser atualizadas na direção oposta ao gradiente do erro médio quadrático, pois se objetiva encontrar o valor mínimo para este erro. Além disso, o erro é retropropagado camada por camada, atualizando-se primeiro as sinapses que ligam a camada de saída à última camada intermediária e por último as que ligam a primeira camada intermediária às entradas da rede.

Para atualizar as sinapses que ligam a camada de saída à última camada intermediária, devesse-se derivar o erro das saídas da rede em relação à estas sinapses. Para tanto, se faz necessário utilizar a regra da cadeia. Definindo $L=s$ para a camada de saída [18]:

$$\nabla_{\omega_{jj}^{(L)}} = \frac{\partial E}{\partial \omega_{jj}^{(L)}} = \frac{\partial E}{\partial \sigma_{jj}^{(L)}} * \frac{\partial \sigma_{jj}^{(L)}}{\partial \omega_{jj}^{(L)}} * \frac{\partial \sigma_{jj}^{(L)}}{\partial \sigma_{jj}^{(L-1)}} \quad (5)$$

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

$$\frac{\partial E}{\partial \omega_{jj}^{(L)}} = -(\sigma_{jj} - \sigma_{jj}^{(L)}) * \sigma'_{jj}(\sigma_{jj}^{(L)}) * \sigma_{jj}^{(L-1)} \quad (6)$$

Sendo $\sigma_{jj}^{(L)} = (\sigma_{jj} - \sigma_{jj}^{(L)}) * \sigma'_{jj}(\sigma_{jj}^{(L)})$ o gradiente local relativo ao neurônio j da camada de saída e η o passo de treinamento, e como o incremento em $\omega_{jj}^{(L)}$ deve ser realizado em direção oposta ao gradiente:

$$\Delta \omega_{jj}^{(L)} = \eta * \sigma_{jj}^{(L)} * \sigma_{jj}^{(L-1)} \quad (7)$$

Assim:

$$\omega_{jj}^{(L)}(t+1) = \omega_{jj}^{(L)}(t) + \Delta \omega_{jj}^{(L)} \quad (8)$$

Onde t é a t -ésima época de treinamento.

Em seguida, devem ser atualizadas as sinapses ligadas às entradas dos neurônios das camadas intermediárias. A lógica é semelhante à realizada para as sinapses anteriormente atualizadas. Para as sinapses ligadas à entrada de cada neurônio das camadas intermediárias, o gradiente do erro é calculado como se segue [18]:

$$\nabla_{\omega_{jj}^{(L)}} = \frac{\partial E}{\partial \omega_{jj}^{(L)}} = \frac{\partial E}{\partial \sigma_{jj}^{(L)}} * \frac{\partial \sigma_{jj}^{(L)}}{\partial \omega_{jj}^{(L)}} * \frac{\partial \sigma_{jj}^{(L)}}{\partial \sigma_{jj}^{(L-1)}} \quad (9)$$

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

$$\frac{\partial E}{\partial \omega_{jj}^{(L)}} = \frac{\partial E}{\partial \sigma_{jj}^{(L)}} * \sigma'_{jj}(\sigma_{jj}^{(L)}) * \sigma_{jj}^{(L-1)} \quad (10)$$

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

$$\frac{\partial \text{erro}}{\partial w_{jk}^{(L)}} = \sum_{i=1}^n \frac{\partial \text{erro}}{\partial w_{ik}^{(L+1)}} * \frac{\partial w_{ik}^{(L+1)}}{\partial w_{jk}^{(L)}} = \sum_{i=1}^n \frac{\partial \text{erro}}{\partial w_{ik}^{(L+1)}} * \frac{\partial (\sum_{i=1}^n w_{ik}^{(L+1)} * \text{neurônio}_i^{(L)})}{\partial w_{jk}^{(L)}} = \sum_{i=1}^n \frac{\partial \text{erro}}{\partial w_{ik}^{(L+1)}} * \text{neurônio}_i^{(L+1)} \quad (11)$$

Sendo n o número de neurônios da camada seguinte à camada L , ou seja, da camada $L+1$. Como $\frac{\partial \text{erro}}{\partial w_{jk}^{(L)}} = \frac{\partial \text{erro}}{\partial w_{jk}^{(L+1)}} * \frac{\partial w_{jk}^{(L+1)}}{\partial w_{jk}^{(L)}} = -\sum_{i=1}^n w_{ik}^{(L+1)} * \text{neurônio}_i^{(L+1)}$, tem-se que a Equação (10) se torna:

$$\frac{\partial \text{erro}}{\partial w_{jk}^{(L)}} = -\left(\sum_{i=1}^n w_{ik}^{(L+1)} * \text{neurônio}_i^{(L+1)}\right) * \text{derivada}'\left(w_{jk}^{(L)}\right) * \text{neurônio}_j^{(L-1)} \quad (12)$$

É importante ressaltar que $\text{neurônio}_i^{(L+1)}$ é o valor do gradiente local relativo ao neurônio k da camada seguinte a camada L , já calculado na etapa anterior da retropropagação do erro, e $w_{jk}^{(L+1)}$ é o valor já atualizado da sinapse que liga a entrada do neurônio k da camada $L+1$ à saída do neurônio j da camada L . Como o incremento em $w_{jk}^{(L)}$ deve ser realizado em direção oposta ao gradiente:

$$\Delta w_{jk}^{(L)} = -\eta * \frac{\partial \text{erro}}{\partial w_{jk}^{(L)}} * w_{jk}^{(L-1)} \quad (13)$$

Onde $\frac{\partial \text{erro}}{\partial w_{jk}^{(L)}} = \left(\sum_{i=1}^n w_{ik}^{(L+1)} * \text{neurônio}_i^{(L+1)}\right) * \text{derivada}'\left(w_{jk}^{(L)}\right)$ é o gradiente local relativo ao neurônio j da camada L e η o passo de treinamento. Assim:

$$w_{jk}^{(L)}(L+1) = w_{jk}^{(L)}(L) + \Delta w_{jk}^{(L)} \quad (14)$$

3.2 Configuração e Validação da Rede Neural

Após testar redes com diferentes parâmetros e configurações, decidiu-se por utilizar redes com apenas uma camada escondida, sendo a camada intermediária composta por 6 neurônios e a camada de saída por 3, todos com função de ativação do tipo tangente hiperbólica. Foi realizado o treinamento *backpropagation* com gradiente descendente com passo de treinamento inicial igual a 0,05, variando com fator de incremento de 1,05 e fator de decremento de 0,9. Os critérios de parada de treinamento das redes foram atingir mil épocas de treinamento ou o erro de validação aumentar por 6 épocas consecutivas.

Para validar os resultados, foi utilizado o método de validação cruzada com 5 partições. No qual os dados são divididos em 5 partes, cada uma com 20% dos dados, e todas as combinações possíveis de forma que se obtenha, 60% dos dados para treinamento, 20% para validação e 20% para teste, são realizadas com essas partições. Assim, é treinada uma rede para cada combinação de partições, resultando em 20 redes treinadas.

As entradas da rede foram os 19 parâmetros normalizados para média zero e desvio padrão 1. E as saídas possuíam range de -1 a 1, devido a função de ativação

escolhida. Cada amostra foi classificada como pertencente a classe representada pelo neurônio que apresentou o maior valor de saída.

4 RESULTADOS E DISCUSSÃO

As classes dos dados utilizados para treinar as redes foram definidas de acordo com a definição teórica das características da propagação da trinca em cada fase descritas por Pinto [13]. Segundo o qual a classe sem propagação (SP) ocorre durante o período em que a trinca não se altera, mesmo com o aumento da pressão; a classe de propagação estável (PE) se refere a fase em que a trinca cresce lentamente a medida que a pressão se eleva; e a classe de propagação instável (PI) ocorre quando a trinca cresce rapidamente, em um curto intervalo de tempo, até a ruptura do duto. Durante a fase de propagação instável, ocorre o crescimento da trinca mesmo que a pressão pare de se elevar, desde que não ocorra redução da mesma para um valor anterior à fase de PI começar. Assim, definiu-se que a transição entre as classes SP e PE ocorreu no tempo de 3100 segundos e entre as classes PE e PI no tempo de 9500 segundos, como pode ser observado na Figura 3.

Os sinais captados e a divisão definida para as classes formaram um conjunto com 50 amostras de SP, 95 de PE e 140 de PI. Para balancear as classes decidiu-se por utilizar a mesma quantidade de amostras de cada uma para realizar o treinamento e a validação cruzada das redes. Assim, foram selecionadas todas as amostras de SP, e 50 amostras de PE e de PI de forma uniforme ao longo de todo o espaço amostral dessas classes. Os conjuntos de treino e de validação se formaram por 60% e 20%, respectivamente, das amostras selecionadas de cada classe. Os conjuntos de teste foram formado pelos outros 20% das amostras selecionadas de cada classe e pelo restante dos dados não selecionados para o subconjunto de dados participantes do treinamento com validação cruzada das redes.

As Tabelas 2 e 3, abaixo, mostram os resultados obtidos com os dados dos conjuntos de treinamento e dos conjuntos de teste, respectivamente, para as redes treinadas.

Tabela 2. Desempenho das Redes Treinadas para os Conjuntos de Treino

	MÉDIA DE ACERTOS (%)			DESVIO PADRÃO (%)		
	SP	PE	PI	SP	PE	PI
SP	94,00	6,00	0,00	3,68	3,68	0,00
PE	2,83	97,17	0,00	2,48	2,48	0,00
PI	0,83	0,00	99,17	1,48	0,00	1,48
Total		96,78			1,57	

Tabela 3. Desempenho das Redes Treinadas para os Conjuntos de Teste

	MÉDIA DE ACERTOS (%)			DESVIO PADRÃO (%)		
	SP	PE	PI	SP	PE	PI
SP	85,50	12,00	2,50	9,99	10,05	4,44
PE	7,55	92,45	0,00	3,79	3,79	0,00
PI	3,05	1,50	95,45	1,85	0,83	1,99
Total		93,85			1,58	

4 CONCLUSÃO

Através dos resultados de média e desvio padrão obtidos na validação cruzada para as redes treinadas, foi possível observar que as redes foram capazes de identificar as três fases de propagação de trincas no duto rígido pressurizado de 40 m.

No geral, as redes treinadas obtiveram alta média de acerto e baixo desvio padrão. A classe com menor desempenho de classificação foi SP, para a qual a rede apresentou bastante confusão com a classe PE. No entanto, se deseja que a análise dos resultados permita parar o treinamento antes do duto romper, o que ocorre na classe PI. E considerando que após entrar em PI, o duto rompe em apenas alguns segundos, a classe PE é provavelmente a que precisa ser melhor identificada. O resultado obtido na classificação da mesma foi bastante satisfatório.

Como se trata de uma tomada de decisão cujos erros podem levar a graves acidentes, uma possível solução para encontrar o correto momento de interromper a produção para reparo e evitar erros de interpretação de dados seria, ao invés de realizar a análise individual dos sinais, analisar cada sinal em conjunto com alguns sinais adjacentes no tempo e avaliar a probabilidade de cada fase estar ocorrendo. Essa ideia talvez também apresente uma boa forma de se enxergar quando uma fase está terminando e outra está prestes a começar, o que se deseja identificar especialmente em relação as classes PE e PI, para assim, se conseguir interromper a produção do duto no momento ideal.

Agradecimentos

Os autores gostariam de expressar sua gratidão à CAPES pelo apoio financeiro, ao Laboratório de Processamento de Sinais da COPPE (LPS) por permitir o uso de seus computadores e software, à Petrobras por sua cooperação e também à UFRGS.

REFERÊNCIAS

- 1 Lasi H, Fettke P, Kemper H-G, Feld T, Hoffmann M. Industry 4.0. Business & Information Systems Engineering. 2014;6(4):239-242.
- 2 Stancioiu A. The fourth industrial revolution „industry 4.0”. Fiabilitate si Durabilitate - Fiability & Durability. 2017;(1):74-78.
- 3 Hellier CJ. Handbook of nondestructive evaluation. McGraw-Hill Companies, Inc; 2003.
- 4 Mix PE. Introduction to nondestructive testing: a training guide. 2ª ed. Hoboken: John & Sons, Inc; 2005.
- 5 Yuki H, Homma K. Estimation of acoustic emission source waveform of fracture using a neural network. NDT & E International. 1996;29(1):21–25.
- 6 Kral Z, Horn W, Steck J. Crack propagation analysis using acoustic emission sensors for structural health monitoring Systems. The Scientific World Journal. 2013;2013(823603): 13 páginas.
- 7 Dai Y, Huang D, Xu J. Optimization of characteristic parameters of pipeline crack identification based on BP neural network. Advanced Materials Research. 2014;926-930:3442-3446.
- 8 Yang L, Kang HS, Zhou YC, He LM, Lu C. Intelligent discrimination of failure modes in thermal barrier coatings: wavelet transform and neural network analysis of acoustic emission signals. Experimental Mechanics. 2015;55(2):321-330.

- 9 Gaja H, Liou F. Defect classification of laser metal deposition using logistic regression and artificial neural networks for pattern recognition. *Int J Adv Manuf Technol.* 2018;94(1-4):315-326.
- 10 Zhang X, Wang K, Wang Y, Shen Y, Hu H. An improved method of rail health monitoring based on CNN and multiple acoustic emission events. Paper presented at the IEEE Instrumentation and Measurement Technology Conference, Politecnico di Torino, Torino, Italy; 2017.
- 11 Da Silva RR, Soares SD, Calôba LP, Siqueira MHS, Rebello JMA. Detection of the propagation of defects in pressurised pipes by means of the acoustic emission technique using artificial neural networks. *Insight.* 2006;48(1):45-51.
- 12 Pinto CFC, Silva RR, Calôba LP, Soares SD. Uso de redes neurais artificiais na detecção de propagação de defeitos em dutos rígidos. *Matéria (UFRJ).* 2012;17(3):1084-1097.
- 13 Pinto CFC. Monitoração de defeitos em dutos rígidos por análise dos parâmetros de emissão acústica utilizando redes neurais, Tese de D.Sc. Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ, Brasil; 2011.
- 14 Pinto CFC, Silva RR, Calôba LP, Soares SD. Probability of defect propagation in pipelines (POP curves). *Insight.* 2014;56(4):204-210.
- 15 Physical Acoustics Corporation. DiSP with AEwin user's manual. Rev. 4. Princeton Junction; 2011.
- 16 Jacques RC. Avaliação de parâmetros de emissão acústica para monitoramento de risers flexíveis, Tese de Dr.Ing. Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, Brasil; 2009.
- 17 Haykin S. *Redes neurais: princípios e prática.* 2ª ed. Porto Alegre: Bookman; 2001.
- 18 Da Silva IN, Spatti DH, Flauzino RA. *Redes neurais artificiais para engenharia e ciências aplicadas: curso prático.* São Paulo: Artliber Editora Ltda; 2010.