

# ANÁLISE NÃO DESTRUTIVA DE ESTRUTURAS DE AÇO UTILIZANDO A TÉCNICA DO CAMPO MAGNÉTICO DE FUGA E REDES NEURAIS

J. Amaral<sup>1</sup>, C. Hall Barbosa<sup>2</sup>, M. Vellasco<sup>2</sup>, M. Pacheco<sup>2</sup>, R. Feitosa<sup>2</sup>, R. Schifini<sup>3</sup>

<sup>1</sup>DETEL-FEN-ERJ, Rua São Francisco Xavier 524, Maracanã, 20550-013 – Rio de Janeiro, RJ

<sup>2</sup>DEE-PUC-Rio, PUC-Rio, Rua Marquês de São Vicente, 225, Gávea, 22453-900 – Rio de Janeiro RJ

<sup>3</sup>Centro de Investigación Industrial-Siderca, Campana, Buenos Aires, Argentina

**Resumo** Uma série de experimentos em chapas de aço contendo diversos tipos de defeito, realizados em um simulador de PIG (*pipeline inspection gizmo*) magnético construído na PUC-Rio, proporcionou uma excelente base de dados de sinais magnéticos, a qual foi utilizada para treinamento de um sistema integrado de redes neurais artificiais para a análise não destrutiva de estruturas de aço. Inicialmente, uma rede PNN (*probabilistic neural network*) determina em qual lado da chapa de aço se localiza o defeito. Em seguida, uma rede neural de classificação divide os defeitos de acordo com sua profundidade, e finalmente redes neurais MLP de caracterização fornecem uma estimativa numérica da profundidade dos defeitos. Os resultados obtidos são satisfatórios, com erros de classificação no caso da determinação do lado do defeito em torno de 15% e no caso da classificação de profundidade abaixo de 5%. Já a rede de caracterização forneceu estimativas da profundidade dos defeitos com erros médios menores que 1%.

**Palavras Chaves:** Redes Neurais, MLP, PNN, Ensaios Não-Destrutivos, PIG Magnético.

**Abstract** A set of measurements, using a pig (*pipeline inspection gizmo*) simulator has been accomplished in steel plates containing several types of flaws, yielding a database of magnetic signals. This database was used to train a set of neural networks to perform non destructive evaluation of steel structures. Initially, a PNN (*probabilistic neural network*) indicates the side of the flaw. Then another classification neural network classifies the flaws in relation to their depths. Finally, a MLP neural network gives an estimation of the flaw depth. The results herein presented are satisfactory, with classification errors in the case of flaw side of about 15% and in the case of flaw depth below 5%. Finally, the MLP characterization neural network has provided estimates of flaw depths with mean errors smaller than 1%.

**Keywords:** Neural Networks, MLP, PNN, Nondestructive Testing, Magnetic PIG.

## 1 INTRODUÇÃO

A análise não destrutiva é um conjunto de técnicas de medida e análise utilizada para caracterizar materiais ou estruturas, sem que suas propriedades físicas e o desempenho sejam alterados durante o teste (Blitz, 1991). Na indústria petroquímica, vários métodos de análise não destrutiva são utilizados para inspeção de tanques e dutos, procurando encontrar pequenos defeitos tipicamente causados por corrosão, os quais podem comprometer a integridade destas estruturas e causar vazamentos de substâncias que teriam efeitos catastróficos no meio ambiente.

Atualmente existem diversas técnicas de análise não destrutiva baseadas nos mais diversos princípios físicos. Alguns exemplos destas técnicas são: radiográficas, nucleares, acústicas, magnéticas ou químicas. Este trabalho utiliza uma técnica de análise magnética chamada técnica do campo de fuga (Beissner, 1980), que consiste em submeter um material magneticamente permeável a um campo magnético externo. Caso este material apresente algum defeito na superfície ou no seu interior, o campo magnético externo sofrerá uma perturbação chamada de campo magnético de fuga. Essas variações são geralmente proporcionais às dimensões do defeito, e podem ser captadas por sensores de efeito Hall. Os sinais fornecidos pelos sensores podem, então, ser processados e armazenados para uma análise posterior. A Fig. 1 mostra um campo magnético de fuga típico em torno de um defeito superficial em uma chapa de aço.


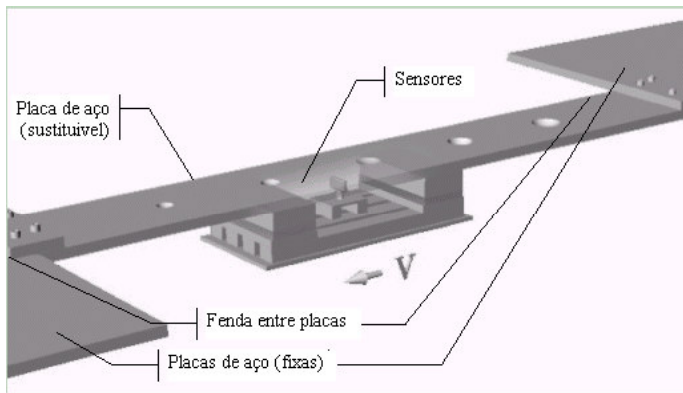


Figura 1 Campo magnético de fuga em um defeito.



**Figura 2. Sistema experimental utilizado neste trabalho, consistindo de um simulador de pig plano baseado em 15 sensores de efeito Hall, e um conjunto de placas de aço contendo defeitos superficiais.**

Uma vez que a análise manual da grande quantidade de dados produzida é demorada e cara, existe um grande interesse na automação do processo de análise. Este artigo descreve um sistema automático de análise destes dados utilizando uma hierarquia de redes neurais.

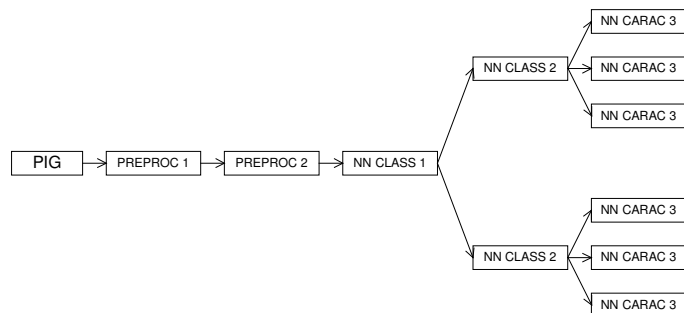
O restante deste trabalho está organizado da seguinte forma: a seção 2 descreve o sistema experimental; a seção 3 apresenta o pré-processamento realizado; a seção 4 descreve as redes neurais utilizadas para classificar e caracterizar os defeitos; a seção 5 apresenta os resultados obtidos; e a seção 6 conclui este trabalho.

## 2 SISTEMA EXPERIMENTAL

A Fig. 2 mostra o sistema experimental, consistindo de um simulador de pig (*pipeline inspection gizmo*). Este mesmo sistema já foi apresentado em (Schifini e Bruno, 2000) e em (Schifini, 2002), e por isso será feita aqui somente uma descrição resumida do mesmo.

O sistema consiste de um pig plano, contendo um conjunto de 15 sensores separados por 8 mm movimentando-se sobre uma placa de aço contendo defeitos superficiais. Foi criado um conjunto de 41 defeitos em 9 placas de aço de 6,35 mm de espessura, 260 mm de largura e 2 m de comprimento. As dimensões destes defeitos variam de 7,8 mm a 27,3 mm para o comprimento, 7,8 mm a 27,2 mm para a largura e 1,3 mm a 5,2 mm para a profundidade. Neste trabalho, considera-se o comprimento como a dimensão na direção do movimento do pig, enquanto que a largura é a dimensão perpendicular a este movimento. A distribuição das profundidades não é uniforme, tendo altas concentrações (modas) em torno de 35%, 55% e 80% da espessura da placa. Estes defeitos também podem ser divididos em três categorias: circulares, longitudinais e transversais. Os defeitos longitudinais apresentam um comprimento maior que a largura, enquanto que nos transversais a largura é maior que o comprimento. Um detalhe interessante deste sistema é a possibilidade de fazer com que o pig passe tanto do lado oposto ao defeito como também passe pelo mesmo lado do defeito. Foram realizadas 20 medidas de cada placa, para cada lado dos defeitos em relação aos sensores.

A Fig. 3 mostra o sistema de análise e processamento dos sinais provenientes do pig. Inicialmente, ocorre um primeiro pré-processamento (**PREPROC 1**) conforme descrito em (Schifini e Bruno, 2000), que identifica e isola o campo magnético de fuga referente a cada defeito processado em um arquivo de dados.



**Figura 3. Diagrama de Blocos do Sistema de Processamento.**

Atualmente, este primeiro módulo de pré-processamento é baseado em um procedimento manual, cuja eficiência depende da experiência do operador; entretanto, um algoritmo automático baseado em redes neurais, como o apresentado em (Hall et al, 2001), pode ser facilmente adaptado para esta aplicação. Por ora, tem-se para cada defeito uma janela de 81 pontos (extensa o suficiente para englobar o sinal de interesse para todos os defeitos estudados), gerando uma matriz de dimensões 81 x 15 para o conjunto de sensores (Fig. 1). Três medidas referentes ao mesmo lado, tiveram que ser excluídas por problemas na medição e processamento, havendo assim um total de  $(41 + 38) \times 20 = 1.580$  medidas.

A seguir, tem-se a segunda etapa do pré-processamento (**PREPROC 2**), que foi introduzida neste trabalho visando retirar o campo magnético de fundo, o qual não traz nenhuma informação adicional, uma vez que seu valor é idêntico para todos os defeitos. Esta etapa é descrita na seção 3.

Após a etapa **PREPROC 2**, tem-se o primeiro nível da hierarquia de redes neurais (**NN CLASS 1**). Este é constituído por uma rede de classificação que determina de qual lado está o defeito. O segundo nível (**NN CLASS 2**) consiste também em uma rede de classificação e determina em que classe de profundidade se encontra o defeito. O terceiro nível de hierarquia (**NN CARAC 3**) caracteriza as dimensões dos defeitos, havendo uma rede para cada dimensão.

A seção a seguir apresenta em detalhes o módulo **PREPROC 2** de pré-processamento, e a seção 4 as diversas redes neurais que compõem o sistema de análise automática.

## 3 ETAPA DE PRÉ-PROCESSAMENTO (PREPROC 2)

Conforme pode ser visto na Fig. 1, existe um campo magnético de fundo cujo valor está em torno de 100 G, sendo que os valores de pico variam entre 107.1 G e 246.6 G. Este campo magnético de fundo tende a mascarar informação relevante, especialmente no caso de defeitos de pequenas dimensões, e portanto deve ser removido.

Para estabelecer um procedimento genérico, o campo de fundo foi calculado para todas as medidas, e foi encontrado o valor  $DC = 105.1$  G. Este valor foi então subtraído de todos os sinais medidos. Cada sinal é então dividido pelo mesmo valor DC, obtendo-se sinais adimensionais, que estão normalizados em relação ao campo magnético de fundo e, indiretamente, à intensidade do campo magnético aplicado.

Na verdade, os sinais são divididos por 1.6 vezes o valor do campo de fundo, de modo a obter sinais que estejam no intervalo  $[-1,+1]$ .





Figura 4. Padrão de entrada da rede.



A função núcleo mais usada é a Gaussiana (Eq. 3).

$$\phi(u) = \frac{1}{(2\pi)^{d/2} \sigma^d} e^{-\frac{u^2}{2\sigma^2}} \quad (3)$$

## 4 SISTEMA DE REDES NEURAIS

### 4.1 NN CLASS 1

Esta é uma rede de classificação utilizada para determinar o lado no qual o defeito está localizado em relação aos sensores magnéticos. O vetor de entrada para esta rede é obtido calculando-se a energia do sinal para cada um dos sensores e expressando este valor como uma fração da energia total medida por todos os sensores. De modo que os padrões sejam invariantes à translação, este vetor de entrada é ordenado antes de ser apresentado à rede, conforme mostra a Fig. 4. Este vetor de entrada é então classificado como pertencendo a uma de duas classes possíveis: à classe MESMO, que indica que o defeito está no mesmo lado dos sensores; ou à classe OPOSTO, que indica que o defeito está no lado oposto aos sensores.

A rede neural utilizada foi a PNN (*probabilistic neural network*) que é uma rede inspirada nos classificadores baseados em Janela de Parzen (Duda et al., 2000). A técnica das Janelas de Parzen é um procedimento não paramétrico que produz uma estimativa da função de densidade de probabilidade (*pdf*) através da superposição de um certo número de funções núcleo. O classificador baseado em Janelas de Parzen primeiro calcula a estimativa da *pdf* de cada classe utilizando os exemplos de treinamento e depois determina a classe *k* com base na equação abaixo:

$$P_k p_k > P_j p_j, \text{ para todo } j \neq k \quad (1)$$

onde:

- $P_k$  é a probabilidade *a priori* da ocorrência de exemplares da classe *k*.
- $p_k$  é a *pdf* estimada da classe *k*.

Dado um conjunto de **n** padrões de treinamento, cada um dos quais com dimensão igual a **d**, amostrado aleatoriamente de **c** classes, a estimativa da *pdf* pode, então, ser obtida através equação:

$$\hat{p}_k(x) = \frac{1}{N} \sum_{i=1}^N \phi(x - x_{ki}) \quad (2)$$

onde:

- $x_{ki}$  é o *i*-ésimo exemplo da classe *k*
- $\phi(\cdot)$  é a função núcleo.

Figura 5: Estrutura da Rede PNN

A PNN possui um aprendizado rápido e converge para um classificador Bayesiano, que é definido como classificador ótimo na presença de dados suficientes. A rede PNN, cuja estrutura é mostrada na Fig. 5, é composta de quatro camadas, descritas a seguir:

- **Camada de Entrada**, semelhante àquela existente nas perceptron multicamadas (MLP), serve para distribuir as entradas na rede.
- Primeira camada escondida, também chamada de **camada de padrões**, contém um nó para cada exemplo de treinamento.
- Segunda camada escondida, também conhecida como **camada de categorias**, contém um nó para cada categoria ou classe.
- **Camada de saída**, um único nó que serve como um discriminador, identificando o maior valor dos nós da camada de categorias.

### 4.2 NN CLASS 2

Uma vez que o lado onde se encontra o defeito está determinado, o segundo nível de hierarquia, NN CLASS 2, é usado para classificar o defeito em função da sua profundidade. A rede classifica o defeito em uma de três classes possíveis: RASO, MÉDIO e PROFUNDO. A definição destas três classes foi feita em função da distribuição das profundidades: a classe RASO representa defeitos com profundidade em torno de 35% da espessura da chapa, a classe MÉDIO representa defeitos em com profundidades em torno de 55% e a classe PROFUNDO representa defeitos com profundidade em torno de 80%. Esta etapa é necessária para produzir melhores resultados na etapa posterior de caracterização do defeito.

O padrão de entrada para esta rede é composto:

- Pelo valor pico a pico do sinal; e
- Pela largura de uma área de limiar magnético.

Estas entradas foram escolhidas porque foram determinadas empiricamente como as que apresentam a maior relação com as dimensões do defeito (Mandayam et al., 1997). No caso específico da classificação em função da profundidade foram usadas como entrada o valor pico a pico do sinal e a largura de uma área de limiar magnético.

A área de limiar magnético é obtida determinando-se a região em que o sinal bidimensional assume valores superiores a um determinado limiar.




Figura 6. Áreas de diversos limiares magnéticos.

A largura desta área pode ser facilmente medida utilizando algoritmos bem conhecidos de processamento de imagens (Gonzalez, 2002). A Fig. 6 mostra as áreas obtidas para diversos limiares magnéticos.

### 4.3 NN CARAC 3

As redes deste terceiro nível são redes do tipo Multi-Layer Perceptron (MLP), com uma camada escondida, treinadas com o algoritmo de Levenberg-Marquardt (Moré, 1977). Estas redes têm uma estrutura semelhante entre si, mas cada uma delas é especializada em uma classe de profundidade. Os padrões de entrada para esta rede são obtidos do mesmo modo que para as redes NN CLASS 2, isto é, utilizando medidas das áreas de limiar magnético e o valor do sinal pico a pico. A saída da rede representa uma dimensão do defeito, isto é, profundidade, largura ou comprimento.

## 5 RESULTADOS

A seguir são apresentados alguns resultados obtidos com este sistema de redes neurais.

### 5.1 NN CLASS1

A rede PNN foi treinada dividindo os 1.580 padrões em conjuntos de treinamento, validação e teste, nas porcentagens de 60%, 25% e 15%, respectivamente. A tabela 1 apresenta os resultados obtidos considerando um número de sensores que variava entre 7 e 15. Estes limites foram obtidos analisando a massa de dados disponível e observando que este número de sensores representa entre 70% e 100% da energia total do sinal. O erro de classificação foi calculado através da fórmula:

$$E = \frac{Ne}{N} \quad (4)$$

onde  $Ne$  é o número de classificações erradas e  $N$  é o número total de padrões.

Esta taxa de acerto, em torno de 87%, representa um resultado bastante promissor, sobretudo se levarmos em conta que a determinação do lado em que se encontra o defeito ainda é pouco explorado na literatura. Em geral, assume-se que o lado onde o defeito se encontra é conhecido a priori (Alcântara et al., 2002), (Enokizono et al., 1998).

Tabela 1. Resultados da determinação do lado.

Número de Sensores	Porcentagem de Energia Total (%)	Erro na Validação (%)	Erro no Teste (%)
7	70	11,96	15,20
9	80	13,32	12,75
11	90	13,59	13,73
13	95	12,28	14,71
15	100	11,69	15,69

Uma das soluções mais promissoras em problemas inversos magnéticos envolve a otimização iterativa de uma malha de elementos finitos com o objetivo de minimizar o erro residual entre o campo magnético de fuga simulado e o experimental. Uma solução unidimensional foi obtida anteriormente em (Hall, 2000) e posteriormente estendida a duas dimensões usando o software comercial 3-d/TOSCA em conjunto com o toolbox de otimização do Matlab (Schifini, 2002), obtendo-se excelentes resultados. Entretanto, ambos os algoritmos necessitam saber *a priori* em que lado o defeito está localizado em relação aos sensores, para que seja possível fornecer um modelo inicial. Se a informação a respeito de que lado o defeito se encontra for incorreta, o algoritmo consegue encontrar a melhor solução, que pode estar completamente errada devido à não unicidade do problema inverso. Portanto, um sistema capaz de determinar em que lado se encontra o defeito, com base somente nos sinais magnéticos do campo de fuga, é de vital importância na solução automática completa do problema inverso.

### 5.2 NN CLASS 2

A rede PNN foi treinada dividindo os  $41 \times 20 = 820$  padrões em conjuntos de treinamento, validação e teste, nas porcentagens de 60%, 25% e 15%, respectivamente. Serão apresentados os resultados supondo que os defeitos se encontram do lado oposto aos sensores, por ser esta a situação mais comum no caso de dutos de petróleo ou de gás porque o lado oposto é que está exposto ao meio ambiente e portanto mais sujeito a sofrer corrosão.

As duas entradas utilizadas na rede PNN foram: o valor pico a pico e a largura de uma área com limiar igual a 50% do sinal pico a pico. O erro de validação foi igual a 4.18% e o erro no teste foi de 1.61%.

### 5.3 NN CARAC 3

A rede MLP usada neste nível do sistema possui 13 entradas, que são as medidas de comprimento e largura de seis limiares magnéticos e o valor do sinal pico a pico.

Serão apresentados neste trabalho apenas os resultados referentes à rede que determina a estimativa da profundidade para classe de profundidade intermediária (concentração em torno de 55% da espessura).

A classe intermediária foi a escolhida porque é neste caso que se deseja uma estimativa mais precisa das dimensões do defeito.

Além disso, escolheu-se inicialmente a profundidade por ser esta a grandeza mais importante para se determinar a gravidade do defeito, porque indica o risco que teria uma tubulação de furar.

A Tabela 2 mostra os erros de treinamento, validação e teste para redes com número de neurônios da camada escondida variando entre 5 e 15. A métrica utilizada para o erro foi o *Mean Absolute Percentage Error* (MAPE), dado pela expressão a seguir (5).


$$MAPE = \frac{\sum_{k=1}^N \left| \frac{a_k - y_k}{a_k} \right|}{N} \times 100\% \quad (5)$$

onde :  $N$  é o número de padrões,  $a_k$  é o valor desejado e  $y_k$  é o valor obtido.

**Tabela 2: Erro de Treinamento, validação e teste.**

Número de Neurônios da Camada escondida	Erro de Treinamento (%)	Erro na Validação (%)	Erro no Teste (%)
5	0,07234	0,47078	0,61716
7	0,01459	0,41568	0,36712
9	0,35310	0,48505	0,42569
11	0,00016	0,28174	1,23808
13	0,24572	0,50021	0,50077
15	0,39714	0,5355	0,45086

Na Figura 7 apresenta-se valores de profundidade obtidos no teste (o) e os valores desejados(+). Pode-se observar que estes valores são realmente bastante próximos sendo que a maior diferença observada foi de 0.1 mm, o que está dentro da tolerância com a qual o furo foi feito.



**Figura 7: Profundidades obtidas pela rede comparadas com as profundidades desejadas.**

## 6 COMENTÁRIOS E CONCLUSÕES

Os resultados apresentados demonstram que o sistema proposto é útil na classificação e caracterização de defeitos.

Este sistema de redes foi construído a partir de dados obtidos numa série de experimentos em chapas de aço e não a partir de simulações numéricas.

A rede de classificação que determina o lado em que o defeito se encontra apresenta uma contribuição para um problema que é ainda pouco explorado.

A estrutura composta de uma rede classificadora seguida de uma rede que aproxima funções melhora o desempenho global do sistema. O mapeamento realizado pela rede que aproxima funções é menos complexo, por estar confinado a uma região e não a todo o domínio.

A organização em níveis do sistema permite que este possa ser utilizado de acordo com a necessidade do usuário, cabendo a este escolher o tipo de informação que lhe é mais adequada.

No sistema apresentado existe espaço para trabalhos futuros a saber:

- A ampliação do conjunto de defeitos superficiais que atualmente é de 41 para 60, para permitir um aumento no número de padrões que é utilizado no sistema, tanto para treinamento e validação quanto para teste.
- Verificar se o pré-processamento proposto permite que sinais adquiridos por *pigs* com diferentes intensidades de campo magnético possam ser utilizados para formar um conjunto único de padrões a ser analisado pelo sistema.
- Estudo de outras técnicas de classificação com o objetivo de aumentar a taxa de acerto da determinação do lado onde o defeito se encontra.

## 7 REFERÊNCIAS BIBLIOGRÁFICAS

- Alcântara, N.P, Carvalho, A.M., Ulson, J.A.C, (2002). Investigações sobre o uso do método de elementos finitos e redes neurais artificiais na análise não destrutiva de tubos metálicos, XIV Congresso Brasileiro de Automática, pp. 38-42.
- Beissner et al., (1980). *NDE Applications of Magnetic Leakage Field Methods: A State of Art Survey*, Nondestructive Information Analysis Center, San Antonio, Texas, Janeiro , pg. 49.
- Blitz (1991). *Electrical and Magnetic Methods of Nondestructive Testing* (Hilger, New York)
- Duda, R. O., Hart, P. E, Stork, D. G. (2000) *Pattern Classification*, second edition, Willey-Interscience.
- Enokizono, M., Tsuchida, Y., Chady, T. (1998). Crack Size and Shape Determination by Moving Magnetic Field Type Sensor, *IEEE Transactions on Magnetics*, vol. 34, no. 4, pp.1252-1254.

Gonzalez, R. G., Woods, R. E. (2002). *Digital Image Processing* (Prentice Hall, New York)

Hall, C. et al. (2000). Nondestructive evaluation of steel structures using a superconducting quantum interference device magnetometer and a neural network system. *Review of Scientific Instrumentation*, vol. 71, no. 10, pp.3806-3815.

Mandayam, S., Udpa, L., Udpa, S., Lord, W. (1997). Wavelet-based permeability compensation technique for characterizing magnetic flux leakage images, *NDT&E International*, vol 30, no 5, pp 297-303.

Moré, J.J. (1977). "The Levenberg-Marquardt Algorithm: Implementation and Theory," *Numerical Analysis*, ed. G. A. Watson, *Lecture Notes in Mathematics* 630, Springer Verlag, pp. 105-116.

Schifini, R., Bruno, A.C. (2000). Three Dimensional Reconstruction of Surface-breaking Flaws Using Finite Element Methods, *Review of Progress in Quantitative Nondestructive Evaluation*, vol. 19, 897.

Schifini, R., (2002), Solução do problema inverso magnetostático utilizando elementos finitos e técnicas de otimização, Tese de Doutorado, PUC-RJ.