

UNIVERSIDADE ESTADUAL PAULISTA  
FACULDADE DE ENGENHARIA  
CAMPUS DE BAURU

**IDENTIFICAÇÃO DE DEFEITOS EM  
TUBULAÇÕES METÁLICAS UTILIZANDO  
REDES NEURAIS ARTIFICIAIS E O  
MÉTODO DOS ELEMENTOS FINITOS**

ALEXANDRE MIGUEL DE CARVALHO

Dissertação apresentada à Faculdade  
de Engenharia da UNESP - Campus  
de Bauru, para obtenção do título de  
Mestre em Engenharia Industrial.

Bauru - SP  
Desembro - 2002

UNIVERSIDADE ESTADUAL PAULISTA  
FACULDADE DE ENGENHARIA  
CAMPUS DE BAURU

**IDENTIFICAÇÃO DE DEFEITOS EM  
TUBULAÇÕES METÁLICAS UTILIZANDO  
REDES NEURAIS ARTIFICIAIS E O  
MÉTODO DOS ELEMENTOS FINITOS**

ALEXANDRE MIGUEL DE CARVALHO  
carvalhoamc@ieee.org

Orientador: Prof. Dr. Naasson Pereira de Alcantara Junior

**Dissertação apresentada à Faculdade  
de Engenharia da UNESP - Campus  
de Bauru, para obtenção do título de  
Mestre em Engenharia Industrial.**

Bauru - SP  
Dezembro - 2002

## AGRADECIMENTOS

Agradeço à minha irmã Maria Zélia de Carvalho pela dedicação, ajuda e paciência nos momentos difíceis, e também, por sempre acreditar em mim.

Muito obrigado, também, a minha irmã Ana Maria de Carvalho pela atenção e ajuda nos momentos decisivos.

Ao grande amigo e professor, Naasson Pereira de Alcântara Jr., agradeço pela confiança e fé na minha pessoa, pois sem estas, certamente este trabalho nunca seria realizado.

Agradeço, também, a todo o corpo docente do departamento de Engenharia Elétrica da Faculdade de Engenharia da Universidade Estadual Paulista campus de Bauru, UNESP-BAURU, pela ajuda e formação. Foi nesta universidade que me tornei um profissional responsável e competente.

Agradeço a Deus por sempre me indicar o caminho do bem e a minha mãe, Conceição Gouveia de Carvalho, que reza por mim todos os dias mesmo desencarnada.

Faço aqui um agradecimento especial à Cecília Pereira de Souza que me ajudou a ficar calmo nos momentos finais deste trabalho.

Por fim, agradeço ao meu pai por me ensinar a ter paciência.

# Sumário

<b>Lista de Siglas e Abreviações</b>	<b>ix</b>
<b>Lista dos Símbolos Principais</b>	<b>x</b>
<b>Resumo</b>	<b>xi</b>
<b>Abstract</b>	<b>xii</b>
<b>1 Introdução</b>	<b>1</b>
1.1 Descrição do Trabalho . . . . .	2
1.2 Motivação . . . . .	3
1.3 Contribuições . . . . .	4
1.4 Possíveis Vantagens e Desvantagens . . . . .	4
1.5 Organização do Texto . . . . .	5

<i>SUMÁRIO</i>	ii
<b>2 Técnicas de Inspeção</b>	<b>7</b>
2.1 Introdução . . . . .	8
2.2 Descrição de Algumas Técnicas de Inspeção em Tubulação Metálicas . .	13
2.2.1 Dispersão do Fluxo Magnético ou MFL . . . . .	13
2.2.2 Correntes Parasitas . . . . .	17
<b>3 Campos Magnéticos Estáticos</b>	<b>21</b>
3.1 Campos Magnéticos Estáticos . . . . .	22
3.2 Resolução de Problemas de Campos Através do Método dos Elementos Finitos . . . . .	26
3.2.1 Introdução . . . . .	26
3.2.2 Modelagem do problema através do Método dos Elementos Finitos	26
<b>4 Redes Neurais</b>	<b>35</b>
4.1 Introdução . . . . .	36
4.2 Pequeno Histórico . . . . .	38
4.3 O Modelo Matemático do Neurônio . . . . .	40
4.3.1 Principais Funções de Ativação . . . . .	42
4.4 Arquiteturas . . . . .	43

4.4.1	Redes Alimentadas Adiante . . . . .	44
4.4.2	Redes Recorrentes . . . . .	44
4.4.3	O Processo da Aprendizagem . . . . .	45
4.5	A Rede Perceptron de Múltiplas Camadas . . . . .	46
4.5.1	O Processo de Aprendizagem da Rede Perceptron de Múltiplas Camadas . . . . .	47
4.6	Classificação de Padrões Utilizando-se Redes Perceptron Multicamadas	55
4.6.1	Introdução . . . . .	55
4.6.2	Reconhecimento de Padrões Utilizando Redes Neurais Artificiais	55
4.7	Interpolação de Funções Utilizando-se Redes Neurais Artificiais . . . . .	58
4.7.1	Introdução . . . . .	58
4.7.2	Aproximador de Funções . . . . .	58
<b>5</b>	<b>Detecção e Classificação de Defeitos</b>	<b>60</b>
5.1	Modelagem do Problema . . . . .	61
5.2	Primeira Análise - Classificação de Padrões de Defeitos de Acordo com Classes Pré-Definidas . . . . .	65
5.3	Segunda Análise - Estimacão das Dimensões dos Defeitos . . . . .	79

<i>SUMÁRIO</i>	iv
<b>6 Conclusões e Sugestões</b>	<b>91</b>
<b>7 Referências Bibliográficas</b>	<b>94</b>
<b>A Descrição do Sistema Computacional FEMM</b>	<b>100</b>
A.1 O Pré-Processador . . . . .	101
A.2 O Processador . . . . .	105
A.3 O Pós-Processador . . . . .	106

# Lista de Figuras

2.1	Instalação de um duto subterrâneo . . . . .	10
2.2	<i>MagneScan<sup>TM</sup></i> - Equipamento que utiliza a tecnologia da dispersão do fluxo magnético . . . . .	10
2.3	<i>TranScan<sup>TM</sup></i> - Equipamento que utiliza a tecnologia da dispersão do fluxo magnético . . . . .	11
2.4	Preparação do <i>MagneScan<sup>TM</sup></i> - Equipamento que utiliza a tecnologia da dispersão do fluxo magnético . . . . .	11
2.5	<i>TranScan<sup>TM</sup></i> sendo lançado em tubulação metálica . . . . .	12
2.6	<i>MagneScan<sup>TM</sup></i> em tamanhos diferentes . . . . .	12
2.7	Ilustração da dispersão do fluxo magnético na presença de um defeito. .	15
2.8	Arquitetura interna de uma sonda que utiliza técnica MFL . . . . .	15
2.9	Equipamento com um circuito magnético e sensor <i>Hall</i> . . . . .	16
2.10	Ilustração da dispersão do fluxo magnético na presença de um defeito. Amostragem do fluxo na posição 3. . . . .	17

2.11	Indução de Correntes Parasitas em uma placa condutora . . . . .	20
2.12	As correntes parasitas também induzem campos magnético . . . . .	20
3.1	Representação de um campo magnético bidimensional. . . . .	25
3.2	Alguns tipos de elementos: triangular linear, quadrilátero linear, tetraedro, triangular quadrático, quadrilátero quadrático e isoparamétrico, respectivamente. . . . .	27
3.3	Representação livre de um domínio subdividido em elementos triangulares	30
4.1	Modelo Matemático do Neurônio . . . . .	40
4.2	Rede Perceptron multicamadas . . . . .	44
4.3	Rede Recorrente . . . . .	45
4.4	Fluxograma para a construção de um sistema de reconhecimento de padrões . . . . .	57
5.1	Modelo esquemático do sistema com bobina de corrente . . . . .	61
5.2	Modelo esquemático do sistema com dispositivo em U . . . . .	62
5.3	Bobina de Corrente com gráfico de cores que mostra a intensidade do campo magnético $\vec{B}$ . Sistema com fluxo magnético disperso no ar . . .	62
5.4	Geometria em U com gráfico de cores que mostra a intensidade do campo magnético $\vec{B}$ . Sistema com fluxo magnético confinado . . . . .	63
5.5	Dimensões do dispositivo em forma de U . . . . .	63

5.6	Sistema com Bobina de Corrente e Tubulação Metálica Modelados pelo MEF . . . . .	67
5.7	Procedimentos para a realização das simulações. . . . .	68
5.8	Ilustração de dois defeitos gerados através do método dos Elementos Finitos. Neste caso o sistema utilizado é a Bobina de Corrente com o Sensor <i>Hall</i> posicionado no centro da mesma. . . . .	69
5.9	Translação do sistema de detecção de defeitos com fluxo disperso no ar	70
5.10	Curvas dos valores absolutos da indução magnética em uma mesma posição do sensor, sem defeito (curva menor) e com um defeito (curva maior) de 98,24 mm de comprimento e 4 mm de altura. . . . .	73
5.11	Gráficos dos desvios da indução magnética na região da bobina para uma posição do sensor, referentes a dez defeitos com uma mesma altura.	74
5.12	Gráfico dos desvios da indução magnética nas 25 posições do sensor, para os defeitos de altura igual a 1 mm . . . . .	75
5.13	Gráfico dos desvios da indução magnética nas 25 posições do sensor, para os defeitos de altura igual a 4 mm . . . . .	76
5.14	Fragmento da parede da tubulação com um defeito de 3,87 mm de comprimento por 0,5 mm de altura . . . . .	80
5.15	Indução magnética para 4 defeitos com altura fixa igual a 2,50 mm e larguras de 0,39 mm; 1,36 mm; 2,90 mm e 4,27 mm. . . . .	82
5.16	Indução magnética para 4 defeitos com altura fixa igual a 5,00 mm e larguras de 0,39 mm; 1,36 mm; 2,90 mm e 4,27 mm. . . . .	83

5.17	Indução magnética para 4 defeitos com largura fixa igual a 1,94 mm e 4 alturas diferentes . . . . .	84
5.18	Indução magnética para 4 defeitos com largura fixa igual a 3,88 mm e 4 alturas diferentes . . . . .	85
5.19	Convergência do erro quadrático médio em uma seção de treinamento da rede neural artificial. . . . .	86
A.1	Pré-processador - Desenho da Geometria . . . . .	102
A.2	Pré-processador - Discretização da Geometria em Elementos Triangulares de Primeira Ordem . . . . .	102
A.3	Pré-processador - Materiais Disponíveis . . . . .	103
A.4	Pré-processador - Biblioteca de Materiais . . . . .	103
A.5	Pré-processador - Edição das Características de um Dado Material . . . . .	104
A.6	Pré-processador - Edição da Curva B-H de um Determinado Material . . . . .	104
A.7	Processador - Utilização do Método de Newton . . . . .	105
A.8	Processador - Utilização do Método do Conjugado-Gradiente . . . . .	106
A.9	Pós-Processador - Gráfico de Cores . . . . .	107
A.10	Pós-Processador - Gráfico de Linhas . . . . .	107
A.11	Pós-Processador - Gráfico do valor do campo magnético normal à superfície da parede metálica sem defeito. Valor medido no centro da bobina de corrente. . . . .	108

# Lista de Siglas e Abreviações

RNA - Rede Neural Artificial

MEF - Método dos Elementos Finitos

DFM - Dispersão do Fluxo Magnético

MCF - Método das Correntes de Fuga

PMC - Perceptron de Múltiplas Camadas

fem - força eletromotriz induzida

FEMM - *Finite Element Method Magnetics* [www.femm.berlios.de/](http://www.femm.berlios.de/)

*MagneScan<sup>TM</sup>* é marca registrada da empresa **General Electric Power Systems**

*TranScan<sup>TM</sup>* é marca registrada da empresa **General Electric Power Systems**

# Lista dos Símbolos Principais

$\mu$  - permeabilidade magnética ( $H/m$ )

$\vec{A}$  - potencial magnético ( $Wb/m$ )

$\mathcal{V}$  - força eletromotriz ( $V$ )

$\Psi_m$  - fluxo magnético ( $Wb$ )

$t$  - tempo ( $s$ )

$L$  - comprimento ( $m$ )

$v$  - velocidade ( $m/s$ )

$\vec{B}$  - densidade de fluxo magnético ( $T$ )

$d\vec{S}$  - elemento de área ( $m^2$ )

$\vec{H}$  - intensidade de campo magnético ( $A/m$ )

$d\vec{L}$  - elemento infinitesimal de comprimento ( $m$ )

$\vec{J}$  - densidade de corrente ( $A/m^2$ )

$I$  - corrente elétrica ( $A$ )

$S$  - área ( $m^2$ )

$\nu$  - relutividade ( $m/H$ )

$\nabla$  - operador nabla

# Resumo

Este trabalho apresenta uma contribuição ao estudo de técnicas para a detecção de defeitos em tubulações metálicas, causados pela ação agressiva dos fluidos conduzidos pelos mesmos, ou ações atmosféricas. O trabalho consiste no mapeamento e classificação da assinatura magnética que cada defeito, em uma tubulação metálica. A assinatura magnética do defeito pode ser entendida como sendo o padrão apresentado pela indução magnética na superfície do tubo, na presença de defeitos, objetos de investigação deste trabalho.

Os defeitos simulados tiveram uma variação na altura e largura. Após as simulações, foram gerados vetores com valores da indução magnética na superfície logo acima de cada defeito simulado ( assinatura magnética ). Os vetores obtidos foram utilizados para o treinamento de duas redes neurais artificiais perceptron multicamada. A primeira arquitetura foi utilizada para fazer a classificação de novos defeitos gerados através do método dos elementos finitos. Na segunda arquitetura, a rede neural foi utilizada para estimar o tamanho do defeito, ou seja, foi utilizada como uma rede identificadora. Os resultados obtidos foram bastante satisfatórios, encorajando a continuação dos estudos bem como a construção de um dispositivo que venha a utilizar os métodos aqui propostos.

# Abstract

This work presents an investigation into the use of the finite element method and artificial neural networks in the identification of defects in industrial plants metallic tubes, due to the aggressive actions of the fluids contained by them, and/or atmospheric agents. The methodology used in this study consists of simulating a very large number of defects in a metallic tube, using the finite element method. Both variations in width and height of the defects are considered. Then, the obtained results are used to generate a set of vectors for the training of two perceptron multilayer artificial neural network. The first one was used to classify a group of new defects, simulated by the finite element method and the second one was used to estimate the dimensions ( high and width ) of defects which also do not belong to the datasets. Finally, the obtained neural network is used to classify a group of new defects, simulated by the finite element method, but that do not belong to the original dataset. The reached results demonstrate the efficiency of the proposed approach, and encourage future works on this subject.

# Capítulo 1

## Introdução

Tubulações metálicas são importantes componentes de diversos tipos de instalações, como gasodutos, oleodutos, refinarias, indústrias petroquímicas, usinas de açúcar e álcool, sistemas de abastecimentos de água, etc. Essas tubulações devem ser mantidas em perfeito estado de conservação e operação, pois acidentes que, porventura, venham a acontecer poderão acarretar prejuízos muitas vezes incalculáveis, tanto ao meio ambiente, como às empresas que as operam.

Para verificar periodicamente a integridade física de tubulações metálicas, várias técnicas de detecção de defeitos foram desenvolvidas. Uma breve descrição das principais técnicas será mostrado no capítulo 2, com uma atenção especial às técnicas que se utilizam de fenômenos eletromagnéticos como a técnica baseada na dispersão do fluxo magnético (MFL) e a técnica baseada em indução de correntes parasitas (ECT).

## 1.1 Descrição do Trabalho

Este trabalho apresenta uma contribuição ao estudo de técnicas de detecção de defeitos em tubulações metálicas que utiliza dispersão do fluxo magnético, que é uma das tecnologias mais utilizadas para esta finalidade como mostra Katragadda em [1] e [2]. A técnica MFL (*Magnetic Flux Leakage*) consiste, basicamente, em se configurar um circuito magnético em que a parede da tubulação metálica seja parte integrante do mesmo. Considera-se como uma distribuição de fluxo padrão, aquela onde a parede metálica não apresenta defeitos. A diminuição da espessura da parede metálica levará a uma alteração no comportamento da indução magnética na superfície próxima a essa região, indicando a presença de defeitos. Esta alteração é detectada em casos reais por sensores adequados.

Este trabalho propõe a associação de duas poderosas ferramentas computacionais: o Método dos Elementos Finitos (MEF) e as Redes Neurais Artificiais

(RNA), com a técnica de Dispersão do Fluxo Magnético, objetivando de otimizar a análise dos resultados.

No sistema proposto deve-se fazer, primeiro, a simulação dos defeitos na tubulação metálica através de um programa computacional para cálculo de campos magnéticos estáticos pelo Método dos Elementos Finitos. Com os resultados das simulações, obtém-se curvas para a indução magnética nas superfícies próximas aos defeitos, obtendo-se, portanto, um banco de dados que será utilizado para preparar os vetores de treinamento correspondentes à cada defeito como pode ser visto em Alcântara [3], [4] e [5]. Este banco de dados será a base de conhecimento para o treinamento da rede neural artificial. Neste trabalho foram utilizadas duas redes neurais. A primeira funcionando como um classificador de padrões e a segunda funcionando como um aproximador de funções, ou interpolador. Após o treinamento das redes, elas poderão classificar novos padrões de entrada de acordo com padrões pré-definidos, ou seja, classes de defeitos, assim como estimar o tamanho de cada novo defeito apresentado à rede interpoladora.

## 1.2 Motivação

Zaoui [6], em seu trabalho, faz a classificação e localização de defeitos, representados por figuras geométricas, em superfícies metálicas através da utilização de uma bobina de corrente. Em se tratando do método utilizado para a geração dos dados para o treinamento da rede neural, Zaoui se utiliza de corrente alternada na bobina de excitação juntamente com o método das correntes parasitas. Fiori [7], em seu trabalho, utiliza-se da variação da impedância calculada através do método das diferenças finitas para gerar dados de treinamento para a rede neural artificial. Este trabalho tem como motivação principal apresentar um estudo sobre a utilização de campos magnéticos estáticos na detecção de defeitos em tubulações metálicas. Sabe-se, da teoria eletromagnética, que campos magnéticos gerados próximos à superfícies

metálicas, por enrolamentos percorridos por correntes alternadas tem a sua penetração limitada pela frequência da corrente elétrica. Por outro lado, campos magnetostáticos se distribuem em todo o material magnético, permitindo, desta forma, a detecção de defeitos mais profundos nas paredes da tubulação. Esta é a razão para se utilizar correntes contínuas nas simulações deste trabalho.

### 1.3 Contribuições

As contribuições esperadas neste trabalho são:

1. mostrar que a utilização de campos magnetostáticos neste tipo de análise permite a obtenção de padrões de comportamento da indução magnética mais fiéis à verdadeira geometria do defeito;
2. mostrar que a utilização das Redes Neurais Artificiais permite uma classificação rápida e precisa desses defeitos, uma vez gerado o banco de dados necessário;
3. mostrar a utilidade do Método dos Elementos Finitos na simulação de defeitos, dispensando a coleta de dados reais para a geração dos padrões a serem utilizados nas RNAs, o que redundaria em um trabalho extremamente oneroso e demorado.

### 1.4 Possíveis Vantagens e Desvantagens

Em Barcherini [8] é mostrado que as redes neurais são sistemas robustos e suficientemente imunes a ruídos. O sistema de detecção de defeito apresentado por Barcherini utiliza sinais amostrados diretamente de um sistema de detecção de defeitos através do método das correntes parasitas. Estes sinais com ruídos são apresentados a uma rede neural que consegue generalizar e classificar os defeitos apresentados. A

metodologia aqui apresentada tem a vantagem de utilizar o método dos elementos finitos para gerar os dados de treinamento da rede neural, o que diminui o tempo e o custo para o treinamento da rede. Outra vantagem detectada é a robustez a ruídos, como mostrado em Barcherini. A principal desvantagem deste método é a necessidade de se realizar simulações em larga escala, o que requer um grande esforço computacional. Outra limitação é que uma vez treinada, a rede neural artificial só pode ser empregada em tubulações idênticas à modelada pelo método dos elementos finitos, ou seja, uma tubulação com as mesmas dimensões e construído com o mesmo tipo de material utilizado nas simulações.

## 1.5 Organização do Texto

No **Capítulo 1** é apresentada a relevância, motivação e contribuições deste trabalho.

O **Capítulo 2** apresenta as principais técnicas de inspeção em tubulações metálicas que se utilizam de fenômenos eletromagnéticos.

O **Capítulo 3** apresenta os princípios do Eletromagnetismo necessários para se compreender o sistema proposto, assim como apresenta os fundamentos do Método dos Elementos Finitos para a resolução de problemas eletromagnéticos estáticos.

O **Capítulo 4** apresenta um estudo sobre as Redes Neurais Artificiais, seus princípios de funcionamento, suas principais arquiteturas, suas características de funcionamento, suas aplicações e, um pouco mais em detalhe, apresenta a arquitetura da rede neural utilizada neste trabalho para a classificação e estimação de tamanhos de defeitos.

O **Capítulo 5** apresenta os passos da metodologia aqui proposta.

O **Capítulo 6** apresenta as conclusões finais, sugestões e trabalhos futuros.

O **Capítulo 7** apresenta as referências bibliográficas utilizadas neste trabalho.

E o **Apêndice A** apresenta as principais características do programa de elementos finitos utilizado na modelagem do problema.

## Capítulo 2

# Algumas Técnicas De Inspeção em Tubulações Metálicas

## 2.1 Introdução

Nesta seção serão apresentadas algumas técnicas de inspeção de defeitos em tubulações metálicas.

A figura 2.1 ilustra o momento da instalação de uma tubulação subterrânea. Esta fase da operação é muito delicada pois a tubulação pode sofrer impactos mecânicos, o que pode causar fraturas ou até mesmo o rompimento da parede da tubulação. Devido a isto, antes de se colocar uma instalação em funcionamento, deve-se, primeiro, realizar inspeções, com o fim de se verificar a sua integridade física. Basicamente, as tubulações podem ser separadas em dois grandes grupos, ou seja, tubulações aéreas e tubulações enterradas. A grande diferença entre elas está na forma de acesso: em tubulações aéreas chega-se pelos dois lados da parede da tubulação. Em tubulações enterradas só é possível o acesso ao lado interno. As tubulações aéreas podem ser encontradas em instalações como refinarias, indústrias petroquímicas e plataformas marítimas de extração de petróleo. As tubulações enterradas são utilizadas em sistemas de abastecimento de água, oleodutos e gasodutos que interligam regiões distantes entre si.

Existem várias técnicas de inspeção de tubulações metálicas. O tipo de tubulação ou defeito procurado determinará a técnica mais adequada. Algumas técnicas são apresentadas a seguir:

1. **Ultrassom** é uma técnica utilizada para a detecção da diminuição da espessura da parede da tubulação e também para a detecção de defeitos em soldas. Esta técnica consiste em se aplicar uma onda mecânica de alta frequência na direção da parede metálica e medir a intensidade das ondas refletidas que, na presença de defeitos, possuem desvios em relação a um valor padrão.
2. **Líquidos Penetrantes** para detecção de trincas superficiais. Este método consiste em se aplicar um líquido na superfície de uma parede metálica. As trincas

são preenchidas por este líquido. Depois, um outro líquido, o removedor, é aplicado para retirar o líquido da superfície da parede metálica. Após isto, uma luz ultravioleta é aplicada na parede metálica para se verificar possíveis trincas pois o líquido penetrante pode ser visível sob raios ultravioletas. Caso o líquido penetrante não seja visível desta forma, um talco revelador deverá ser usado.

3. **Correntes Parasitas ou *eddy current*** para a detecção de defeitos superficiais, trincas e redução de espessura da parede da tubulação. Este método está descrito na seção 2.2.2.
4. **Dispersão do Fluxo Magnético ou MFL** para a detecção de defeitos na parede da tubulação assim como corrosão interna ou externa. Este método está descrito na seção 2.2.1.
5. **Inspeção Visual**, onde um especialista verifica pessoalmente as tubulações, se estas forem aéreas.

Nas inspeções de tubulações enterradas são utilizadas sondas que deslizam internamente por toda a extensão da tubulação. Na figura 2.2 é mostrado o equipamento *MagneScan<sup>TM</sup>* que é uma sonda que utiliza a técnica da Dispersão do Fluxo Magnético, assim como o equipamento *TranScan<sup>TM</sup>* que é mostrado na figura 2.3. Na figura 2.4 é mostrado um equipamento *TranScan<sup>TM</sup>* sendo preparado para utilização. Na figura 2.5 é mostrado um equipamento *TranScan<sup>TM</sup>* sendo lançado em uma tubulação metálica e na figura 2.6 pode-se ver a preparação de dois equipamentos *MagneScan<sup>TM</sup>* de tamanhos diferentes.



Figura 2.1: Instalação de duto subterrâneo. Figura retirada do site de empresa General Electric Power Systems

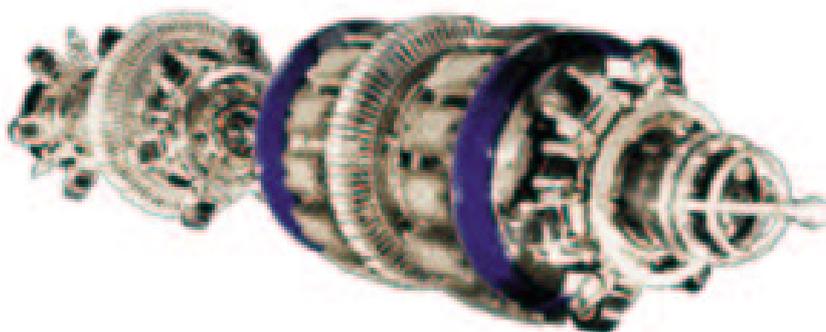


Figura 2.2: *MagneScan™* - Equipamento que utiliza a tecnologia da dispersão do fluxo magnético. Figura retirada do site de empresa General Electric Power Systems.



Figura 2.3: *TranScan™* - Equipamento que utiliza a tecnologia da dispersão do fluxo magnético. Figura retirada do site de empresa General Electric Power Systems.

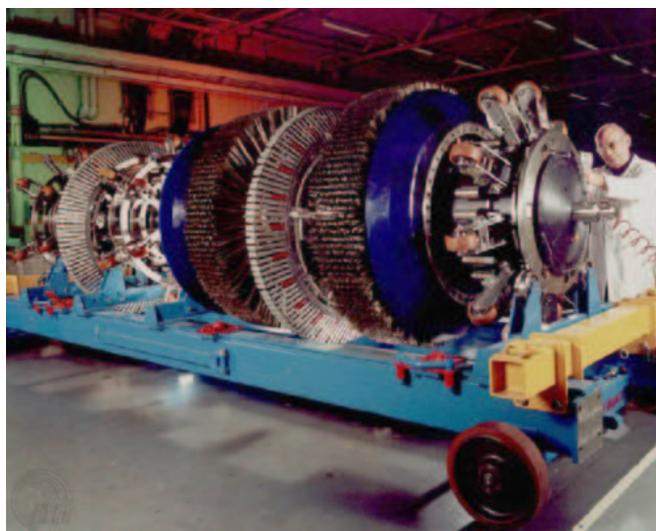


Figura 2.4: Preparação do *MagneScan™* - Equipamento que utiliza a tecnologia da dispersão do fluxo magnético. Figura retirada do site de empresa General Electric Power Systems.



Figura 2.5: *TranScan™* sendo lançado em tubulação metálica. Figura retirada do site de empresa General Electric Power Systems.

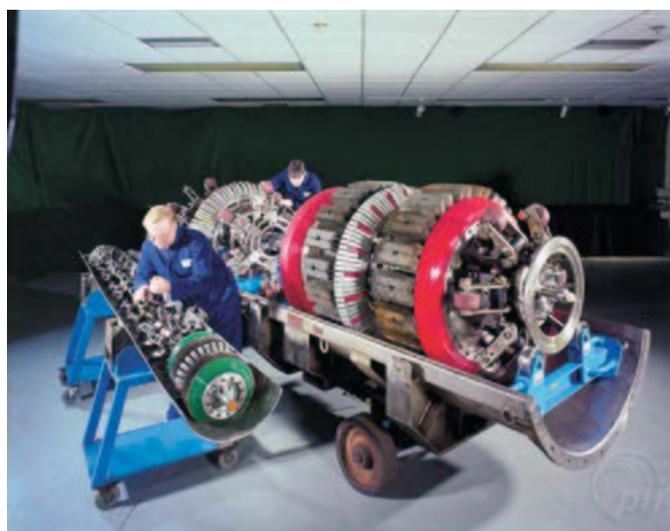


Figura 2.6: *MagneScan™* em tamanhos diferentes. Figura retirada do site de empresa General Electric Power Systems.

## 2.2 Descrição de Algumas Técnicas de Inspeção em Tubulação Metálicas

Nesta seção, serão abordadas algumas técnicas de detecção de defeitos em tubulações metálicas que se baseiam em fenômenos eletromagnéticos como a Dispersão do Fluxo Magnético descrita em Katragadda, [1] e [2], e a técnica de Correntes Parasitas, descrita em Lee [9] e Bowler [10].

### 2.2.1 Dispersão do Fluxo Magnético ou MFL

Esta técnica consiste em se percorrer a superfície sob inspeção com um dispositivo que é um núcleo de ferro em forma de "U" dotado de uma bobina de corrente. Esta corrente, que pode ser contínua ou alternada induz a um fluxo magnético através do circuito magnético formado pelo dispositivo e a parede da tubulação. O dispositivo pode se mover com velocidades em torno de  $10m/s$  [1]. O defeito é detectado através da variação do fluxo magnético que passa pelo sensor *Hall* no centro do circuito magnético como mostra a figura 2.7.

Como pode ser visto na figura 2.7, o fluxo magnético na parede de uma tubulação que não contem defeitos é uniforme. Entretanto, na existência de defeitos, haverá uma variação no comportamento do fluxo magnético, com a existência de um pequeno fluxo disperso, que será detectado por um sensor *Hall* colocado no centro do núcleo de ferro.

A figura 2.8 ilustra esta arquitetura adaptada para uma sonda como o *MagneScan<sup>TM</sup>* da figura 2.2. Na figura 2.9 tem-se uma visão mais detalhada da parte do sistema que possui o sensor e o circuito magnético. Uma descrição do modelo para uma análise numérica pode ser encontrada em Katragadda[2].

**Dispersão do Fluxo Magnético com Variação da Relutância**

Uma forma alternativa para a técnica da Dispersão do Fluxo Magnético é fazer a amostragem do fluxo magnético no centro de uma das paredes do circuito magnético. Neste caso, o sensor *Hall* está na posição 3 da figura 2.8 e na posição 3 da figura 2.10.

Pode-se observar a variação da relutância através da equação abaixo:

$$\mathcal{R}_T = \frac{1}{\mu} \cdot \frac{L}{S} \quad (2.1)$$

Onde:

$\mathcal{R}_T$  é a relutância total do circuito magnético ( $H^{-1}$ );

$\mu$  é a permeabilidade magnética do meio ( $H^{-1}$ );

$S$  é a área da seção do circuito magnético ( $m^2$ );

$L$  é o comprimento médio do circuito magnético ( $m$ )

Este método é descrito em Katragadda [1]. Como se pode ver na equação 2.1, com o surgimento de um defeito, há uma variação na área  $S$  e, por sua vez, uma variação na relutância  $\mathcal{R}_T$ .

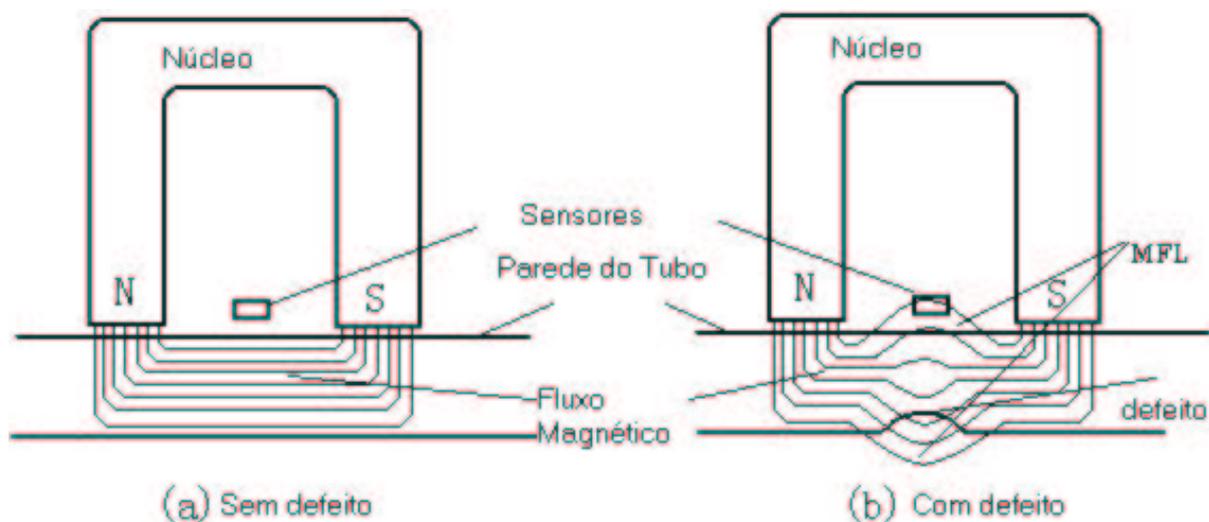


Figura 2.7: Ilustração da dispersão do fluxo magnético na presença de um defeito.

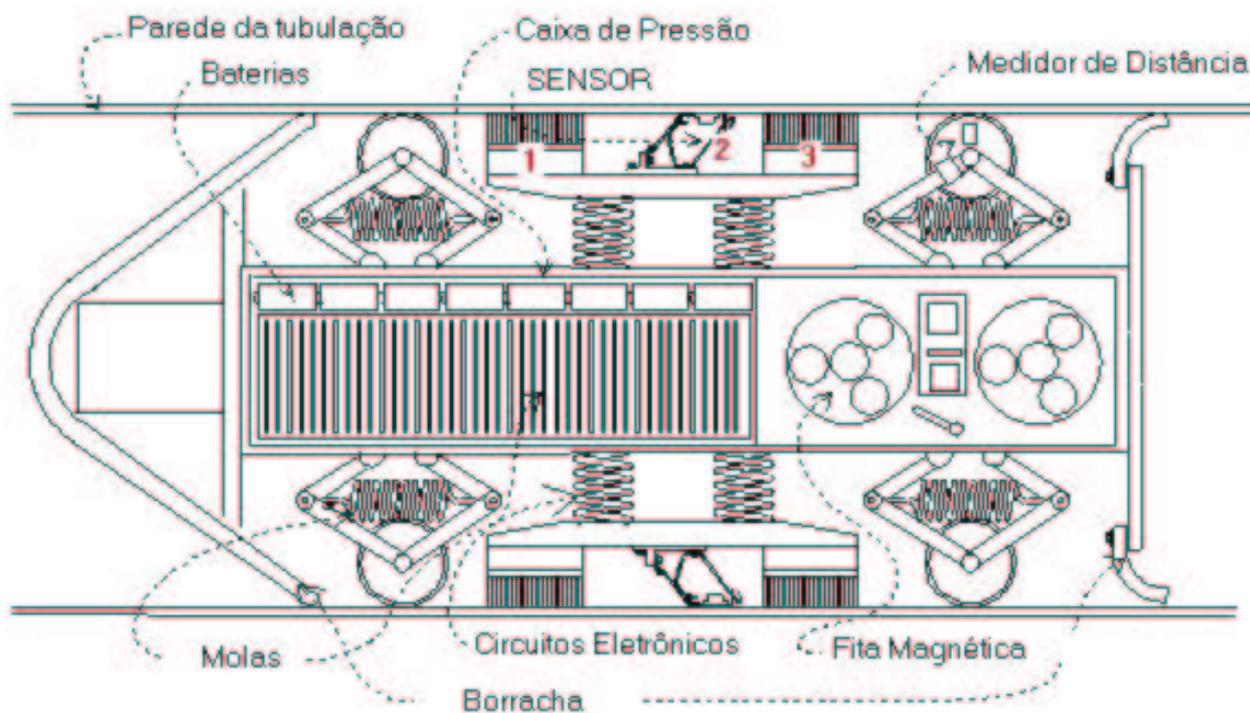


Figura 2.8: Arquitetura interna de uma sonda que utiliza técnica MFL. Figura retirada do site de empresa General Electric Power Systems.

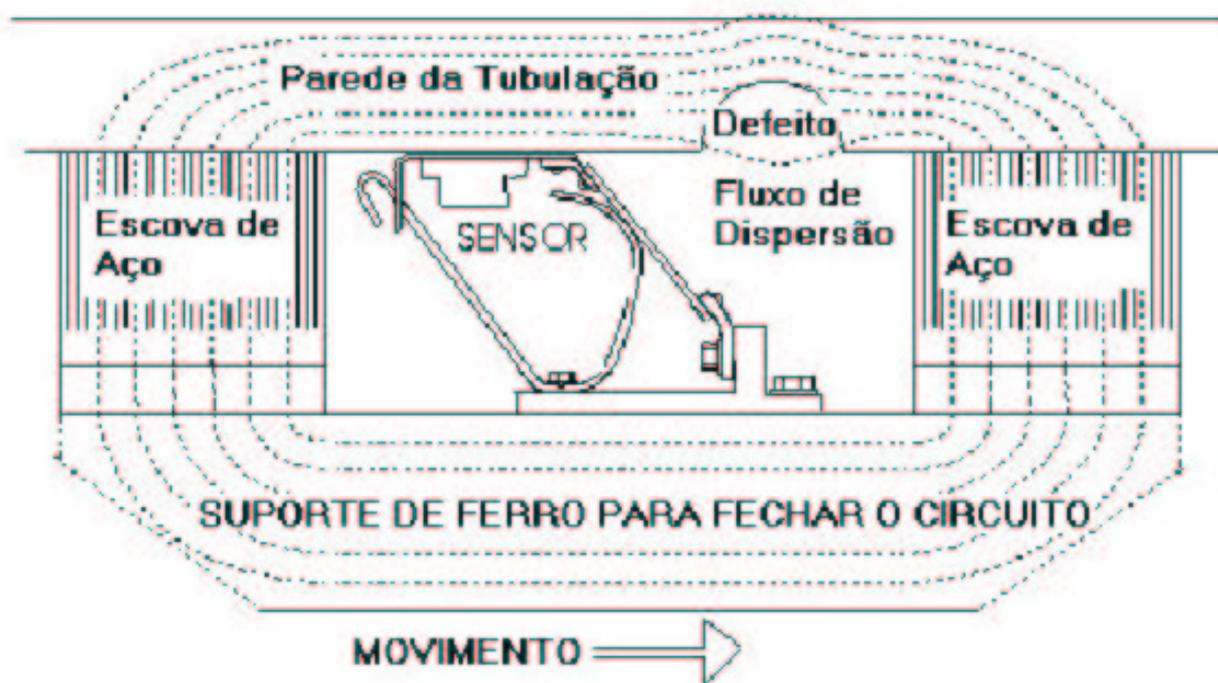


Figura 2.9: Equipamento com um circuito magnético e sensor *Hall*. Figura retirada do site de empresa General Electric Power Systems.

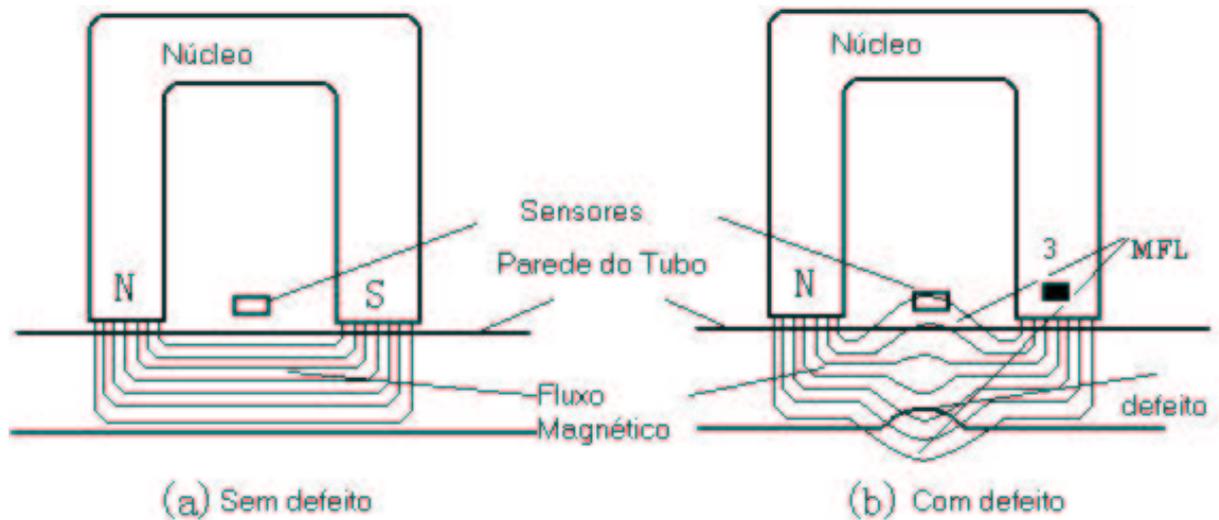


Figura 2.10: Ilustração da dispersão do fluxo magnético na presença de um defeito. Amostragem do fluxo na posição 3.

### 2.2.2 Correntes Parasitas

Na figura 2.11 tem-se uma bobina alimentada por corrente alternada induzindo correntes parasitas em uma superfície metálica. Estas correntes parasitas, por sua vez, também induzem campos magnéticos como mostra a figura 2.12. A Lei de Faraday mostra que a força eletromotriz induzida em um circuito atravessado por um fluxo magnético é igual à taxa de variação deste fluxo em relação ao tempo, ou seja:

$$\mathcal{V} = -\frac{d\Psi_m}{dt} \quad (2.2)$$

Onde:

$\mathcal{V}$  é a força eletromotriz (fem) (V);

$\Psi_m$  é o fluxo magnético (Wb);

$t$  é o tempo.

A indução de força eletromotriz ocorre de duas maneiras: força eletro-

motriz induzida por efeito variacional e força eletromotriz induzida por efeito mocional. A força eletromotriz induzida por efeito mocional ocorre devido ao movimento relativo entre o condutor e o campo magnético, enquanto que a força eletromotriz induzida por efeito variacional ocorre devido à variação da amplitude da densidade de fluxo magnético em relação ao tempo. Matematicamente a Lei de Faraday também pode ser expressa por:

$$\mathcal{V} = \oint_L (\vec{v} \times \vec{B}) \cdot d\vec{L} - \int_S \frac{\partial \vec{B}}{\partial t} \cdot d\vec{S} \quad (2.3)$$

Onde:

$\mathcal{V}$  é a tensão induzida total (V);

$L$  é o caminho a ser percorrido (m);

$\vec{v}$  é a velocidade do condutor (m/s);

$\vec{B}$  é a densidade de fluxo magnético (T);

$t$  é o tempo (s);

$d\vec{S}$  é o elemento de área (m<sup>2</sup>).

Na equação 2.3 o primeiro termo do segundo membro da equação refere-se à força eletromotriz induzida por efeito mocional e o segundo termo refere-se à força eletromotriz induzida por efeito variacional.

### Método do Dispositivo Indutor de Correntes Parasitas

A figura 2.11 também serve para ilustrar o princípio de funcionamento do Dispositivo Indutor de Correntes parasitas. Neste método, uma bobina alimentada por corrente alternada induz correntes parasitas na superfície da tubulação. Estas correntes parasitas, por sua vez, geram campos magnéticos que vão induzir correntes na bobina que está envolta na parte externa da tubulação. Quando há um defeito ocorre uma variação do fluxo e por sua vez uma variação das correntes induzidas pelas correntes parasitas, o que causa uma variação na tensão induzida nos terminais de

coleta de dados. Este sinal coletado é comparado com um sinal padrão, ou seja, um sinal gerado com uma tubulação sem defeitos. Baseado nesta diferença é possível dizer se há ou não defeito na tubulação.

No próximo capítulo, serão apresentados alguns princípios da teoria eletromagnética, necessários para a compreensão deste trabalho bem como uma descrição sucinta do Método dos Elementos Finitos aplicado à solução de problemas eletromagnéticos.

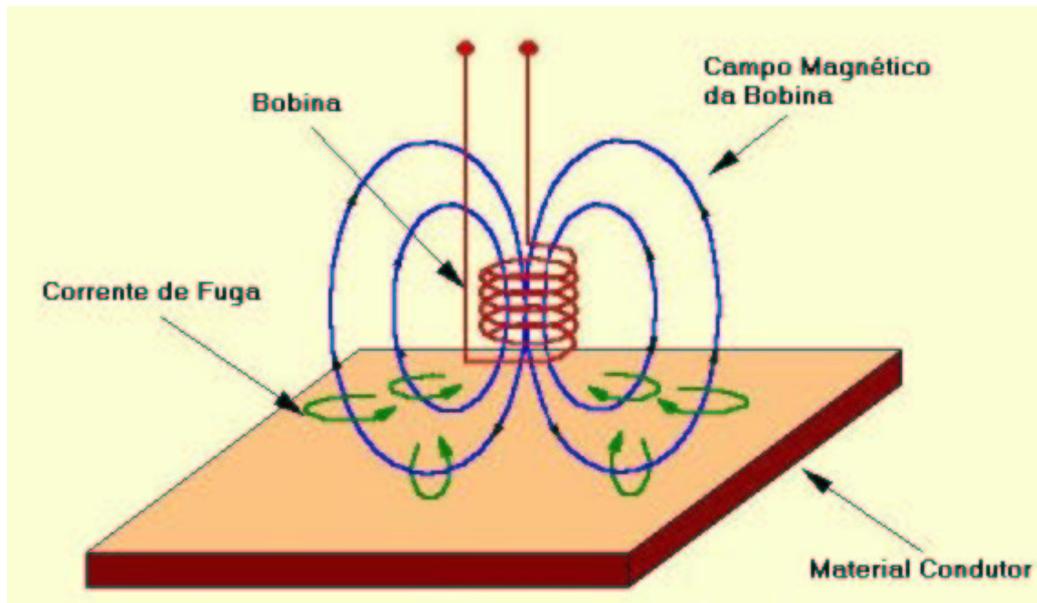


Figura 2.11: Indução de Correntes Parasitas em uma placa condutora

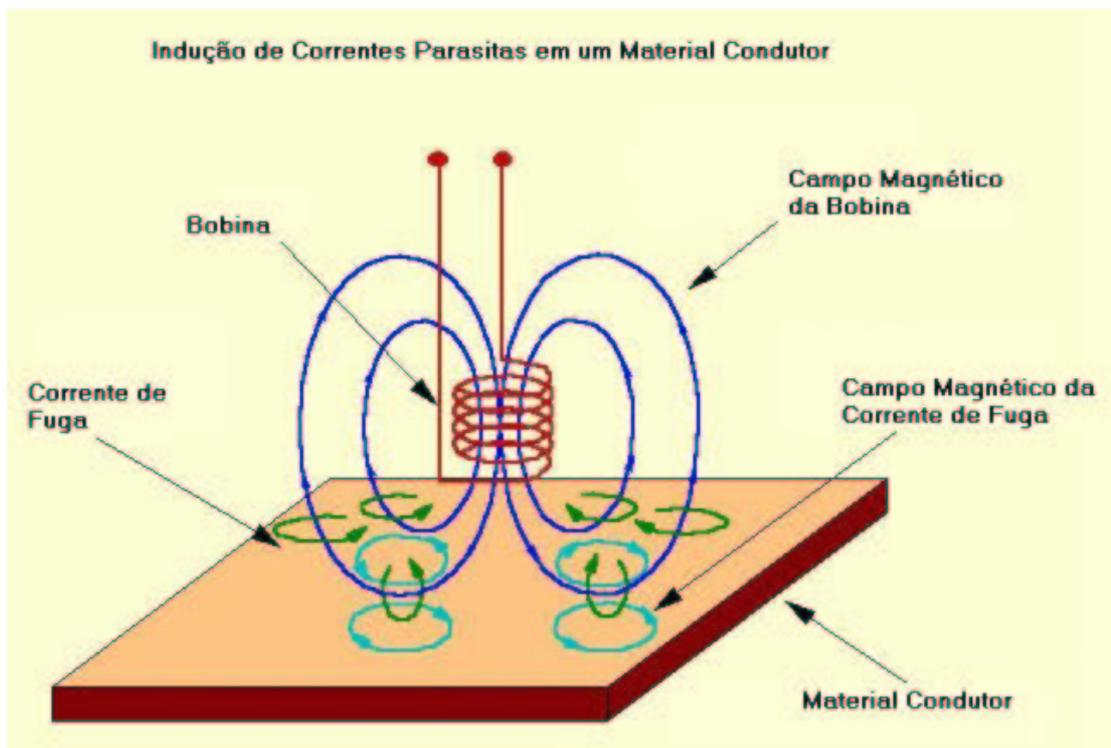


Figura 2.12: As correntes parasitas também induzem campos magnéticos

## **Capítulo 3**

# **Campos Magnéticos Estáticos e o Método dos Elementos Finitos**

### 3.1 Campos Magnéticos Estáticos

A relação entre corrente elétrica e campo magnético foi descoberta por Hans Christian Oersted em 1819. A equação que associa a corrente elétrica com a intensidade de campo magnético é a lei circuital de Ampère:

$$\oint_L (\vec{H} \cdot d\vec{L}) = \int_S \vec{J} \cdot d\vec{S} = I \quad (3.1)$$

Onde:

$\vec{H}$  é a intensidade de campo magnético (  $A/m$  );

$d\vec{L}$  é um elemento infinitesimal do caminho percorrido (  $m$  );

$\vec{J}$  é a densidade de corrente (  $A/m^2$  );

$d\vec{S}$  é um elemento infinitesimal de área (  $m^2$  );

$I$  é a corrente elétrica (  $A$  );

$L$  é o caminho total percorrido (  $m$  );

$S$  é a área delimitada pelo caminho fechado  $L$  (  $m^2$  ).

A equação 3.1 diz que a integral de linha da intensidade de campo magnético  $\vec{H}$ , ao longo do contorno fechado  $L$ , é igual à corrente total envolvida por esse caminho.

Aplicando-se o Teorema de Stokes ao primeiro membro da equação 3.1 tem-se:

$$\oint_L (\vec{H} \cdot d\vec{l}) = \int_S (\vec{\nabla} \times \vec{H}) \cdot d\vec{s} \quad (3.2)$$

Substituindo o primeiro termo da equação 3.1 pelo segundo termo da

equação 3.2 tem-se:

$$\int_S (\vec{\nabla} \times \vec{H}) \cdot d\vec{s} = \int_S \vec{J} \cdot d\vec{s} \quad (3.3)$$

Pode-se então escrever a Lei de Ampère na forma vetorial:

$$\vec{\nabla} \times \vec{H} = \vec{J} \quad (3.4)$$

Definindo a relutividade ( $\nu$ ) como sendo o inverso da permeabilidade magnética ( $\mu$ ) pode-se escrever:

$$\vec{\nabla} \times (\nu \cdot \vec{B}) = \vec{J} \quad (3.5)$$

Onde:

$\vec{B}$  é o vetor indução magnética ( $T$ ).

Ao contrário do campo eletrostático, onde as linhas de campo começam e terminam em cargas elétricas, as linhas de fluxo magnético são contínuas. Isto significa que não existem cargas magnéticas isoladas. Isto pode ser matematicamente representado igualando-se à zero o fluxo magnético através de uma superfície fechada:

$$\phi = \oint_S \vec{B} \cdot d\vec{S} = 0 \quad (3.6)$$

A equação 3.6 é conhecida como a Lei de Gauss para o magnetismo. Aplicando-se à ela o teorema da divergência tem-se:

$$\vec{\nabla} \cdot \vec{B} = 0 \quad (3.7)$$

Por outro lado, sabe-se do cálculo vetorial que, para qualquer função vetorial  $\vec{\Phi}$ , pode-se escrever:

$$\vec{\nabla} \cdot (\vec{\nabla} \times \vec{\Phi}) = 0 \quad (3.8)$$

Portanto, uma vez que o divergente de  $\vec{B}$  é nulo, deve existir uma função vetorial  $\vec{A}$  tal que:

$$\vec{B} = \vec{\nabla} \times \vec{A} \quad (3.9)$$

Pois tem-se:

$$\vec{\nabla} \cdot (\vec{\nabla} \times \vec{A}) = 0 \quad (3.10)$$

qualquer que seja  $\vec{A}$ .

A função  $\vec{A}$  é denominada função potencial magnético ou vetor potencial magnético e não possui significado físico, ou seja, o potencial magnético possui apenas um significado matemático. Substituindo-se a equação 3.9 na equação 3.5 tem-se:

$$\vec{\nabla} \times (\nu \cdot (\vec{\nabla} \times \vec{A})) = \vec{J} \quad (3.11)$$

Para a maioria dos problemas práticos, pode-se considerar que as componentes em x e y do vetor potencial magnético  $\vec{A}$  e do vetor densidade de corrente  $\vec{J}$  são nulas na maior parte do domínio, existindo, apenas, a componente em z. Também admitir-se-á que  $\vec{A}$  não varia na direção z, mas apenas nas direções x e y. Este é um campo magnético de comportamento bidimensional e pode ser exemplificado pela figura 3.1. Desenvolvendo os rotacionais da equação 3.11 tem-se:

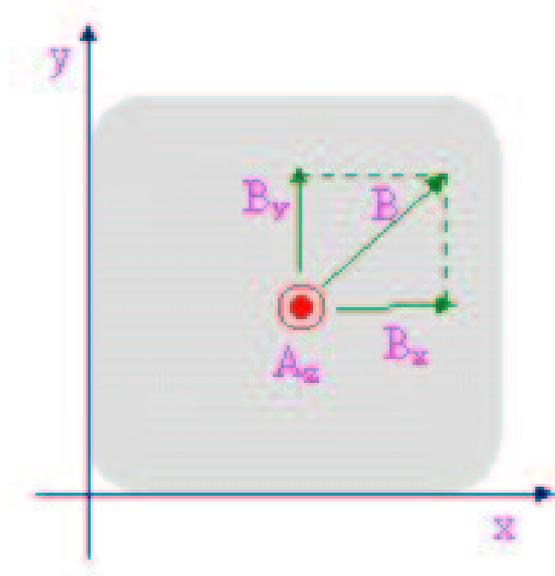


Figura 3.1: Representação de um campo magnético bidimensional.

$$\frac{\partial}{\partial x} \left( \nu \frac{\partial A}{\partial x} \right) + \frac{\partial}{\partial y} \left( \nu \frac{\partial A}{\partial y} \right) = -J \quad (3.12)$$

Com estas simplificações, o potencial magnético inicialmente apresentado como um vetor passa, simplificadamente, a ser tratado como uma função escalar, conforme a equação 3.12. A equação 3.12 é uma equação diferencial a derivadas parciais de segunda ordem, não linear, mais conhecida como função Quase-Poisson, ou equação de Poisson não linear.

A solução da equação 3.12 possibilita o conhecimento do campo magnético em qualquer ponto de um circuito magnético. Entretanto, esta equação não possui uma solução analítica conhecida, e é por esta razão que utilizam-se métodos numéricos para se encontrar soluções aproximadas para ela. Dentre os mais utilizados está o **Método dos Elementos Finitos** [12] que será descrito na próxima seção e que foi utilizado neste trabalho.

## 3.2 Resolução de Problemas de Campos Através do Método dos Elementos Finitos

### 3.2.1 Introdução

O Método dos Elementos Finitos é um dos métodos numéricos utilizados para encontrar soluções aproximadas para equações diferenciais a derivadas parciais, dadas as condições de contorno [12], como é o caso da equação 3.12. Para se resolver este tipo de equação, os métodos numéricos são largamente utilizados pois elas não possuem solução analítica conhecida.

### 3.2.2 Modelagem do problema através do Método dos Elementos Finitos

Para se resolver um problema através do Método dos Elementos Finitos, tem-se os seguintes passos:

1. Discretização do domínio da função;
2. Seleção da função de interpolação;
3. Formulação do sistema de equações;
4. Solução do sistema de equações.

#### Discretização do Domínio da Função

A discretização do domínio da função consiste em subdividi-lo em inúmeros subdomínios. Estes subdomínios que são denominados elementos. Os ele-

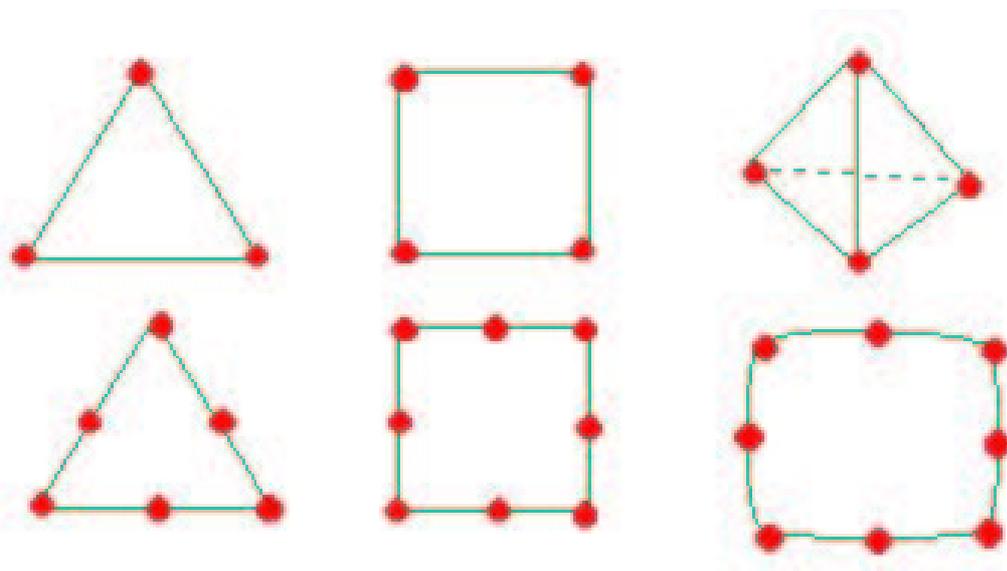


Figura 3.2: Alguns tipos de elementos: triangular linear, quadrilátero linear, tetraedro, triangular quadrático, quadrilátero quadrático e isoparamétrico.

mentos mais utilizados para a modelagem eletromagnética são o segmento de reta, o triângulo e o tetraedro, respectivamente para uma, duas e três dimensões [12]. Na figura 3.2 tem-se alguns tipos de elementos finitos que são utilizados na discretização de domínios.

Os problemas são formulados em termos de uma função desconhecida  $\phi$  associada aos nós de cada elemento, ou seja, para um elemento triangular linear há três nós, sendo um em cada vértice. A discretização do domínio é chamada de pré-processamento pois pode ser executada separadamente e independentemente dos outros passos.

### Seleção da Função de Interpolação

O segundo passo para a análise através do método dos elementos finitos é a seleção da função de interpolação que vai aproximar o valor da função desconhecida dentro do elemento. Geralmente, uma função polinomial é escolhida para ser a função de interpolação. As mais utilizadas são as equações polinomiais de primeira, segunda e terceira ordem. Quanto maior o grau do polinômio, maior a complexidade da formulação. A formulação mais utilizada é a formulação linear, ou seja, um polinômio de primeira ordem [12].

Uma vez que o polinômio foi selecionado pode-se ter a expressão que mostra o valor de  $\phi$  no elemento. Tem-se então:

$$\phi^e = \sum_{j=1}^n N_j^e \cdot \phi_j^e \quad (3.13)$$

Onde:

$e$  é um elemento da discretização do domínio;

$\phi^e$  é o valor da função desconhecida no elemento  $e$ ;

$n$  é o número de nós do elemento;

$\phi_j^e$  é o valor da função desconhecida no nó  $j$ ;

$N_j^e$  é a função de interpolação, também conhecida como função de expansão ou função base.

A equação 3.14 calcula o valor da função desconhecida em um elemento. Se a função  $N_j^e$  é um polinômio do primeiro grau, ou seja, linear, diz-se que o elemento é linear. Se a função  $N_j^e$  é quadrática, diz-se que o elemento é quadrático e assim sucessivamente.

### Formulação do Sistema de Equações

Neste passo, o sistema de equações é formulado. Pode-se utilizar os métodos de Ritz ( Variacional ) e de Galerkin para estes propósitos. Em [12] tem-se a descrição dos dois métodos. Aqui, entretando, o método utilizado foi o Variacional como descrito no manual do programa para modelagem eletromagnética **FEMM** [13].

### Formulação Variacional

Utilizando-se o Cálculo Variacional, um problema de campo magnetostático pode ser descrito por um funcional de energia:

$$F = \int \int \left( \int (\nu \cdot B) dB - J \cdot A \right) dx dy \quad (3.14)$$

Onde:

$F$  é o funcional de energia.

Um funcional geralmente é uma integral definida, cujo resultado dependerá da função que define o integrando. Na equação 3.15 a função é a expressão do potencial magnético  $A$  em função de  $x$  e de  $y$ . O resultado depende da expressão da função. A solução consiste em encontrar a função  $A$  que dá o menor valor para o funcional  $F$ , ou seja, a minimização do funcional. A função aproximadora utilizada é de primeira ordem, ou seja, linear e do tipo:

$$A(x, y) = \sum_{i=1}^n \Phi_i \cdot A_i \quad (3.15)$$

Onde:

$A_i$  é o valor do potencial magnético em cada nó da malha de elementos finitos;

$\Phi_i$  são chamadas **funções de forma**.

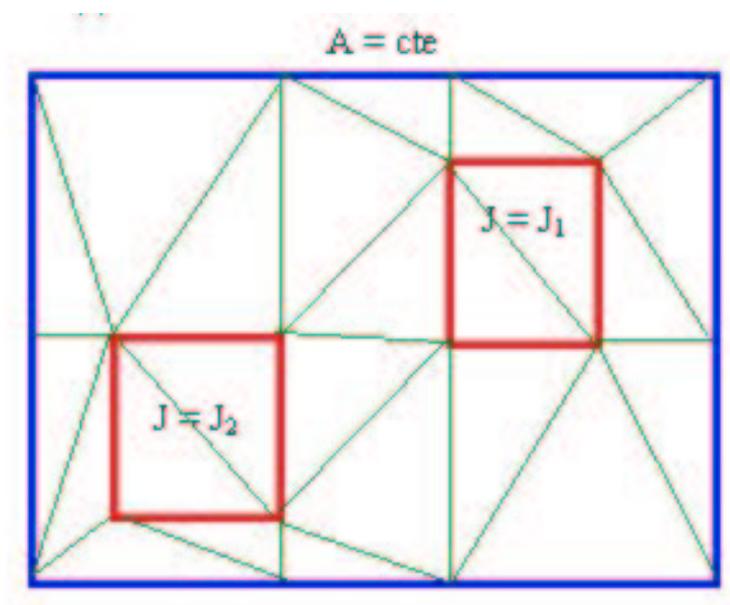


Figura 3.3: Representação livre de um domínio subdividido em elementos triangulares

Para um elemento triangular linear, ou seja, três nós por elemento tem-se:

$$\Phi_i = \frac{a_i x + b_i y + c}{2\Delta} \quad (3.16)$$

Onde:

$a_i, b_i, c_i$  dependem da posição dos nós do elemento;

$\Delta$  é a área do elemento.

Na figura 3.3 tem-se uma representação livre de um domínio separado em vários subdomínios triangulares de primeira ordem. Esta figura mostra, ainda, que no contorno o valor do potencial magnético é constante e que há duas correntes  $J_1$  e  $J_2$  neste domínio.

A aplicação do Método dos Elementos Finitos a um determinado domínio resulta em um sistema global de equações do tipo  $[S] \cdot [A] = [R]$  onde  $[S]$

é uma matriz global com informações geométricas e magnéticas,  $[A]$  é um vetor com o potencial magnético nos nós da malha e  $[R]$  é um vetor com os valores de correntes nos nós. Este sistema possui as seguintes características: a matriz  $[S]$  é altamente esparsa, ou seja, possui poucos elementos não nulos em cada linha, simétrica, em banda, positiva definida e diagonalmente dominante. A ordem desta matriz é igual ao número de nós na malha de elementos finitos. Para problemas complexos, esta matriz poderá chegar à ordem dos milhares.

Esta matriz é originalmente singular, ou seja, determinante igual a zero, e o sistema possui infinitas soluções. Para tornar este sistema não singular, impõe-se ao sistema de equações as condições de contorno como é mostrado em [12].

Teoricamente, os elementos podem ter qualquer aspecto. Entretanto, para se obter uma solução mais precisa, os elementos devem ser os mais regulares possíveis.

Os elementos devem ser mais concentrados em regiões onde as variáveis de interesse apresentam grandes variações e menos concentrados nas regiões onde há pouca mudança das variáveis de interesse.

Como a indução magnética  $\vec{B}$  é o rotacional da vetor potencial magnético ( equação 3.9 ) tem-se:

$$B = \frac{1}{2\Delta} \sum_{i=1}^3 \left( b_i i_x + c_i i_y \right) A_i \quad (3.17)$$

cujos módulo é igual a:

$$|B| = \frac{1}{2\Delta} \sqrt{(b_1 A_1 + b_2 A_2 + b_3 A_3)^2 + (c_1 A_1 + c_2 A_2 + c_3 A_3)^2} \quad (3.18)$$

que resulta constante em cada elemento.

Com as funções A e B definidas em termos do potencial magnético nos

vértices dos elementos, a minimização do funcional  $F$  é feita igualando-se a primeira derivada do funcional em relação ao potencial magnético em cada vértice igual a zero.

$$\frac{\partial F}{\partial A_k} = 0 \quad (3.19)$$

Onde:

$k$  é igual a 1, 2, 3, ...,  $M$  onde  $M$  é o número de vértices da malha.

Realizando-se todas as operações algébricas que se fizerem necessárias, chega-se, para cada elemento, às expressões:

$$\left(\frac{\nu}{4\Delta}\right) \cdot \left( (b_1b_1 + c_1c_1)A_1 + (b_1b_2 + c_1c_2)A_2 + (b_1b_3 + c_1c_3)A_3 \right) = \frac{\Delta J}{3} \quad (3.20)$$

Para o nó 1;

$$\left(\frac{\nu}{4\Delta}\right) \cdot \left( (b_2b_1 + c_2c_1)A_1 + (b_2b_2 + c_2c_2)A_2 + (b_2b_3 + c_2c_3)A_3 \right) = \frac{\Delta J}{3} \quad (3.21)$$

Para o nó 2;

$$\left(\frac{\nu}{4\Delta}\right) \cdot \left( (b_3b_1 + c_3c_1)A_1 + (b_3b_2 + c_3c_2)A_2 + (b_3b_3 + c_3c_3)A_3 \right) = \frac{\Delta J}{3} \quad (3.22)$$

Para o nó 3.

Escrevendo na forma matricial tem-se:

$$\left(\frac{\nu}{4\Delta}\right) \cdot \begin{pmatrix} b_1b_1 + c_1c_1 & b_1b_2 + c_1c_2 & b_1b_3 + c_1c_3 \\ b_2b_1 + c_2c_1 & b_2b_2 + c_2c_2 & b_2b_3 + c_2c_3 \\ b_3b_1 + c_3c_1 & b_3b_2 + c_3c_2 & b_3b_3 + c_3c_3 \end{pmatrix} \cdot \begin{pmatrix} A1 \\ A2 \\ A3 \end{pmatrix} = \left(\frac{\Delta}{3}\right) \cdot \begin{pmatrix} J \\ J \\ J \end{pmatrix} \quad (3.23)$$

A equação 3.23, se refere a apenas um elemento. Agrupando-se todas as equações dos subdomínios, ou seja, todas as equações dos elementos chega-se à equação:

$$[S] \cdot [A] = [R] \quad (3.24)$$

onde:

$[S]$  é uma matriz global com informações geométricas e magnéticas;

$[A]$  é a matriz dos potenciais magnéticos dos nós da malha de elementos finitos;

$[R]$  é a matriz dos valores de correntes nos nós.

A equação 3.24 é a equação a ser resolvida pois com os valores de  $A$  pode-se calcular  $B$  e outras grandezas relacionadas.

### Solução do Sistema de Equações

Como foi visto na seção anterior, a equação 3.25 é a equação a ser resolvida. A matriz  $S$  é originalmente singular, ou seja, seu determinante é igual a zero, portanto, o sistema possui infinitas soluções. Para torná-lo não singular, impõe-se ao sistema as condições de contorno que são, na maioria dos casos, condições do tipo Dirichlet[12], onde o potencial magnético  $A$  é conhecido nos pontos do contorno do domínio. Neste trabalho, considerou-se como condições de contorno o potencial magnético igual a zero em todas as bordas do domínio. Com as condições de contorno impostas ao sistema ele pode ser resolvido por métodos numéricos que explorem a

esparcidade da matriz  $[S]$ . O programa **FEMM** que foi utilizado neste trabalho utiliza o método do conjugado gradiente como pode ser visto em Golub [14].

## Capítulo 4

# Introdução ao Estudo das Redes Neurais Artificiais

## 4.1 Introdução

As Redes Neurais Artificiais são modelos matemáticos inspirados no funcionamento do cérebro humano [15]. Diferentemente dos modelos computacionais tradicionais, que são sequenciais, o cérebro humano apresenta funcionamento paralelo, distribuído e adaptativo, ou seja, ele pode manipular sua estrutura para executar uma determinada tarefa. Os modelos matemáticos dos neurônios são baseados nas estruturas do neurônio biológico. Entretanto, tendo em vista que o conhecimento a respeito do cérebro humano ainda é muito limitado e que a capacidade computacional disponível hoje também é limitada, os modelos matemáticos podem ser considerados aproximações grosseiras se comparados ao neurônio biológico. Contudo, mesmo com estas limitações, estes modelos têm sido aplicados com sucesso na resolução de muitos problemas.

As principais características das redes neurais artificiais são:

1. aprender através de exemplos;
2. capacidade de generalização;
3. capacidade de se adaptar à novas situações, ou adaptabilidade;
4. tolerância à falhas;
5. auto-organização;
6. capacidade de armazenar e agrupar dados.

Abaixo pode-se ver algumas das áreas em que as Redes Neurais Artificiais podem ser aplicadas:

- A) **Reconhecimento de padrões;**
- B) **Aproximação de funções;**

- C) **Previsão e Estimação;**
- D) **Memórias Associativas;**
- E) **Controle.**

#### A) Reconhecimento de Padrões

O reconhecimento de padrões é a classificação de um conjunto de dados baseado em alguns conjuntos pré-determinados. Exemplos deste tipo de aplicação é o reconhecimento de numerais manuscritos por um sistema computacional, como pode ser encontrado em [21].

#### B) Aproximação de Funções

O processo de se aproximar uma função consiste em encontrar uma estimativa de uma função desconhecida/conhecida como pode ser visto em Chen [22]. Por exemplo, pode-se construir uma rede neural para implementar-se a função seno ou cosseno.

#### C) Previsão e estimação

Este problema - previsão e estimação - consiste em se prever o valor de uma variável no tempo  $t_{n+1}$  baseado em uma coleção de eventos que aconteceram em  $t_0, t_1, t_2, \dots, t_{n-1}, t_n$ . Pode-se encontrar exemplos deste tipo de aplicação em Saad [23] e Melo [24]. Um exemplo de aplicação é a previsão de chuvas em uma época do ano baseado em medições pluviométrica de anos anteriores. Outro exemplo é a previsão da demanda de energia elétrica de uma determinada cidade ou região baseado nos dados de consumo anteriores.

#### D) Memórias Associativas

Memória Associativa é a capacidade de recuperar um item correto

mesmo que a entrada seja parcial ou incorreta. Um exemplo disto é o reconhecimento de caracteres das placas de automóveis em situações onde não estejam totalmente legíveis nas imagens fotográficas.

#### E) Controle

Aqui a rede neural artificial gera as entradas do sistema a ser controlado para que o mesmo se comporte adequadamente. Um exemplo da aplicação de redes neurais artificiais em sistemas de controle pode ser encontrado em [26].

Nas próximas seções será apresentado um pequeno histórico sobre redes neurais artificiais, o principal modelo matemático dos neurônios, as principais arquiteturas de redes e os tipos de treinamento, assim como a utilização de redes neurais no processo de classificação de padrões e aproximador de funções.

## 4.2 Pequeno Histórico

Os estudos modernos das redes neurais artificiais tiveram início com os trabalhos de McCulloch e Pitts [15]. McCulloch era um psiquiatra e também um neuroanatomista, enquanto que Pitts era matemático. Publicaram juntos um artigo em 1943 onde era apresentado o primeiro modelo matemático do neurônio. O primeiro computador de propósito geral, o ENIAC, utilizou a teoria apresentada por McCulloch e Pitts. Em 1948 o livro *Cibernética (Cybernetics)* de Wiener [16] é publicado. Este livro trás conceitos importantes sobre controle, comunicações e processamento de sinais. Em sua segunda edição de 1961 este livro levanta, subjetivamente, a importância da mecânica-estatística nos processos de treinamento das redes neurais, entretando somente 30 anos mais tarde é que Hopfield consegue fazer a ligação formal entre a mecânica-estatística e o processo de treinamento das redes neurais artificiais.

Em 1949 é publicado o livro *The Organization of Behavior* de Hebb

[17]. Neste livro é apresentado o modelo de aprendizagem fisiológica para a alteração das conexões sinápticas dos neurônios artificiais. O livro de Hebb foi a fonte de inspiração para o desenvolvimento dos modelos computacionais de aprendizagem e sistemas adaptativos [15].

Em 1952 é publicado o livro *Design for Brain: The Origin of Adaptive Behavior*, de Ashby [18]. Este livro apresenta o conceito de que os comportamentos adaptativos de um sistema são obtidos através do treinamento deste sistema.

Em 1954 é defendida uma tese de doutorado sobre redes neurais na Universidade de Princeton por Minsky. O título da tese é *Theory of Neural-Analog Reinforcement Systems and Its Application to the Brain-Model Problem* [19].

Em 1958 é apresentado à comunidade científica um novo modelo matemática para o neurônio. Trata-se do modelo perceptron, proposto por Rosenblatt [27]. Este modelo era o melhor modelo já desenvolvido e novos horizontes de pesquisa foram abertos. Este modelo possibilitava à rede neural a capacidade de adaptação e de processamento distribuído.

Em 1969, Minsky e Papert provam matematicamente que as redes neurais artificiais desenvolvidas com perceptrons eram capazes de resolver apenas problemas de separação linear. A função XOR, ou "ou-exclusivo", por exemplo, não poderia ser resolvida por este modelo de rede. Tem início, então, a "Época das Trevas" no estudo das redes neurais artificiais pois, com a publicação do livro *Perceptrons* [20] onde era provada a ineficiência das redes neurais para problemas mais complexos, a maioria dos pesquisadores abandonaram seus estudos neste campo.

Hopfield, na década de 80, propõe um modelo matemático baseado em neurônios para ser utilizado em aplicações de memórias associativas. Nesta década, o modelo neural é também utilizado para tarefas de controle complexas. Kohonen, em 1984, estuda a capacidade de auto-organização destes sistemas [27].

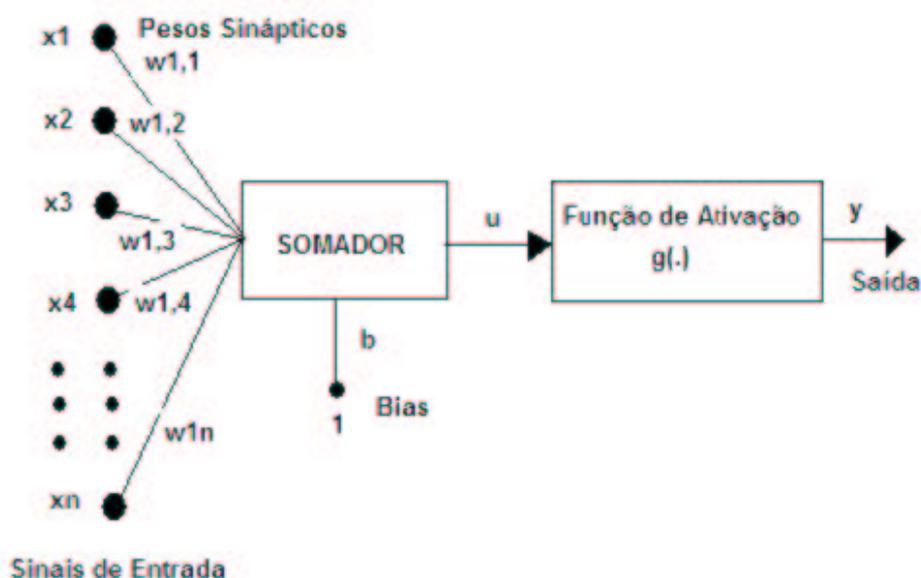


Figura 4.1: Modelo Matemático do Neurônio

Em 1986 é apresentado o algoritmo de aprendizado *Backpropagation* por Rumelhart, Hinton e Willians. Este algoritmo era utilizado para a treinamento de redes neurais multicamadas do tipo perceptron. Este algoritmo desmistificou a idéia de que as redes neurais eram incapazes de resolver problemas complexos e não lineares. A partir do algoritmo de retropropagação, novas arquiteturas de redes neurais e novas formas de treinamento foram apresentadas desde então. Atualmente tem-se diversas arquiteturas e diversos algoritmos de treinamento para as redes neurais artificiais, assim como uma vasta área de aplicações como mostrado nas seções anteriores.

### 4.3 O Modelo Matemático do Neurônio

A figura 4.1 , mostra o modelo genérico do neurônio, onde observa-se:

1.  $x_1, x_2, \dots, x_n$  é um vetor com sinais de entrada com  $n$  elementos;

2.  $\mathbf{W}$  ( $W_{1,1}, \dots, W_{1,n}$ ) são as conexões sinápticas do neurônio;
3.  $\mathbf{b}$  é um escalar que é o limiar de ativação do neurônio;
4. **o combinador linear** ou Somador, que faz a combinação linear dos valores de entrada com os pesos sinápticos.
5.  $\mathbf{u}$  é uma grandeza escalar que é a saída do combinador linear ( Somador );
6.  $f(\cdot)$  é a função de ativação que pode ser do tipo rampa, degrau unipolar, degrau bipolar, logística, tangente hiperbólica entre outras;
7.  $\mathbf{y}$  é uma grandeza escalar que é o sinal de saída do neurônio;

Matematicamente, tem-se:

$$u = \sum_{i=1}^n (W_{1i} \cdot x_i) + b \quad (4.1)$$

Como o sinal de saída do neurônio corresponde a um valor da função de ativação onde a variável independente é o valor do sinal oriundo do combinador linear, tem-se então que:

$$y = f(u) \quad (4.2)$$

A função de ativação  $f(\cdot)$  produz o sinal de saída do neurônio baseado no sinal de saída do combinador linear. As funções de ativação são, na maioria das vezes não lineares e geralmente possuem um ponto de limiar ou limite, tanto superior quanto inferior. Estas características visam fazer com que o funcionamento do neurônio artificial seja o mais próximo possível do neurônio biológico. Uma das características do neurônio biológico é que ele só se torna ativo quando o estímulo imposto a ele for maior que o limiar de ativação, característica esta reproduzida pelo neurônio artificial através do uso de funções de ativação convenientes. As conexões de entrada do neurônio artificial são análogas aos dendritos do neurônio biológico como mostrado em [27] e [28], assim como as conexões de saída são análogas ao axônio biológico. Vejamos agora as principais funções de ativação.

### 4.3.1 Principais Funções de Ativação

Abaixo, são apresentadas algumas das funções de ativação mais utilizadas:

1. Função Rampa

$$f(u) = \begin{cases} a & : u > a \\ u & : -a \leq u \leq a \\ -a & : u < -a \end{cases} \quad (4.3)$$

onde  $a, u \in \mathcal{R}$ ;

2. Função Degrau Unipolar

$$f(u) = \begin{cases} 1 & : u \geq a \\ 0 & : u < a \end{cases} \quad (4.4)$$

onde  $u, a \in \mathcal{R}$ ;

3. Função Degrau Bipolar

$$f(u) = \begin{cases} 1 & : u \geq a \\ -1 & : u < a \end{cases} \quad (4.5)$$

onde  $u, a \in \mathcal{R}$ ;

4. Função Logística

$$f(u) = \frac{1}{1 + e^{-\beta u}} \quad (4.6)$$

onde  $u \in \mathcal{R}$  e  $\beta \in \mathcal{R}^+$ ;

#### 5. Função Tangente Hiperbólica

$$f(u) = \frac{1 - e^{-\beta u}}{1 + e^{-\beta u}} \quad (4.7)$$

onde  $u \in \mathcal{R}$  e  $\beta \in \mathcal{R}^+$ ;

As funções de ativação são escolhidas de acordo com a arquitetura da rede neural e do tipo de treinamento escolhido, por exemplo, a função de ativação tangente hiperbólica é comumente utilizada na rede perceptron multicamadas. Os parâmetros das funções de ativação também são escolhidos convenientemente visando melhorar o desempenho dos algoritmos de treinamento. No próximo tópico veremos as principais arquiteturas de redes neurais artificiais.

## 4.4 Arquiteturas

A unidade básica de uma rede neural artificial é o neurônio, que é uma unidade de processamento matemático muito simples. A combinação destes neurônios em uma estrutura espacial e interconectada, a função de ativação utilizada e ainda, o tipo de treinamento a qual é submetida a estrutura, é que diferencia uma rede neural de outra. Esta estrutura formada por neurônios é denominada de arquitetura da rede, ou seja, a forma com que os neurônios estão arranjados no espaço, como eles estão interconectados, juntamente com o tipo de aprendizado ao qual estão submetidos. Pode-se fazer a classificação das arquiteturas das redes em dois grandes grupos: topologia da rede e processo de aprendizagem.

Em relação à topologia espacial dos neurônios, as redes podem ser classificadas em Redes Alimentadas Adiante e Redes Recorrentes. O processo de

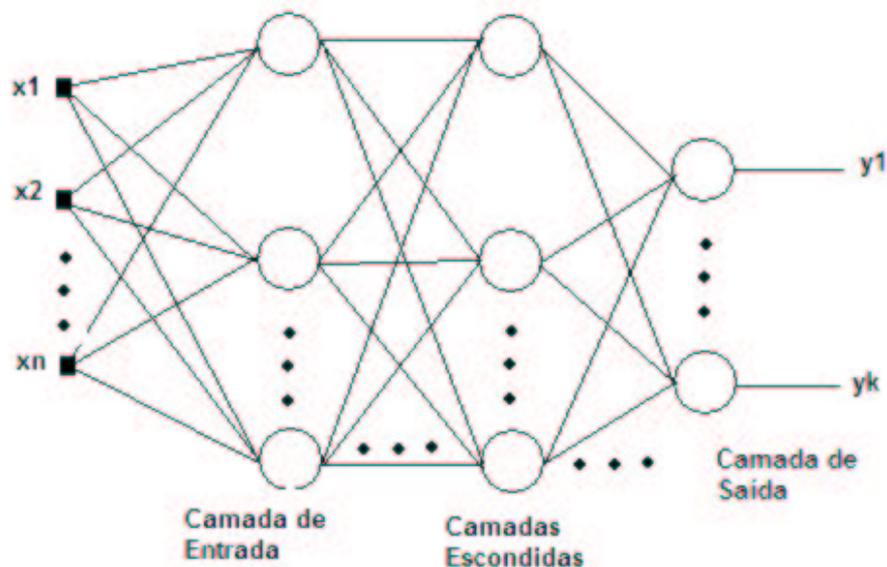


Figura 4.2: Rede Perceptron multicamadas

aprendizagem da rede pode ser supervisionado ou associativo e não supervisionado ou auto-organizado.

#### 4.4.1 Redes Alimentadas Adiante

Neste tipo de rede, os sinais se propagam a partir da camada de entrada em direção à camada de saída. Não há retroalimentação dos sinais, como pode ser mostrado na figura 4.2.

#### 4.4.2 Redes Recorrentes

A principal característica deste tipo de rede é que seus neurônios possuem retroalimentação, isto quer dizer que o sinal de saída de um neurônio é utilizado como padrão de entrada pela rede, como mostra a figura 4.3.

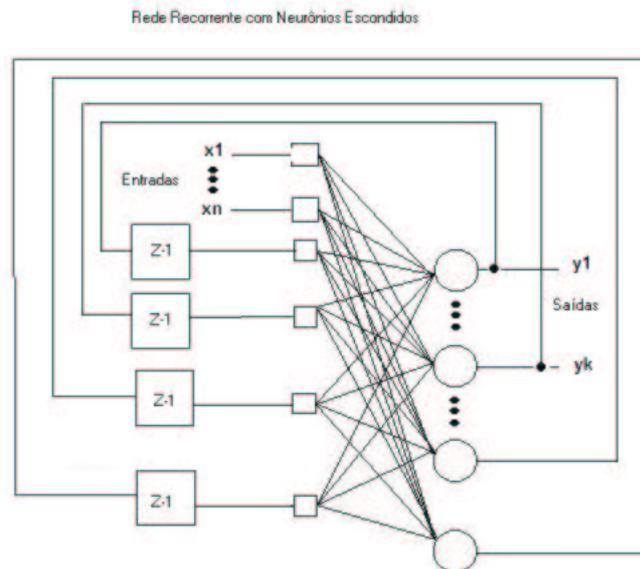


Figura 4.3: Rede Recorrente

### 4.4.3 O Processo da Aprendizagem

A rede neural possui a capacidade de aprender sobre o sistema ao qual ela está submetida. Sob o ponto de vista matemático, aprender significa ajustar os parâmetros livres da rede de uma forma organizada e contínua. Como está descrito em Haykin [15] e em Gonçalves [27], o processo de aprendizagem consiste dos seguintes passos:

1. a rede é exposta a um novo sistema;
2. a rede neural sofre alterações internas dos parâmetros livres;
3. a rede neural, agora, pode fornecer respostas coerentes sobre o sistema ao qual ela foi exposta.

O estudo do processo de aprendizagem das redes neurais artificiais é uma área de estudo e pesquisa muito complexa pois seus parâmetros internos podem

ser alterados através de uma variedade muito grande de métodos. Alguns processos de aprendizagem alteram a arquitetura da rede, outros, as funções de ativação, e ainda, os pesos das conexões sinápticas. Estes últimos são os métodos mais utilizados. Pode-se, ainda, classificar os métodos de aprendizagem das redes neurais artificiais em dois grandes grupos: **o aprendizado supervisionado ou associativo** e **o aprendizado não supervisionado ou auto-organizado**. Esta classificação diz respeito ao conjunto de dados disponíveis para o treinamento da rede. Se há dados de saída da rede conhecidos, ou seja, se há vetores de entrada com os respectivos valores de saída desejados, o processo de aprendizado é supervisionado. Se não há dados de saída disponíveis, a própria rede terá de extrair as características do sistema. A este tipo de aprendizado se dá o nome de aprendizado não-supervisionado ou auto-organizado.

Nas próximas seções serão mostradas as arquiteturas utilizadas neste trabalho que é a Rede Multicamadas Alimentadas Adiante do tipo Perceptron.

## 4.5 A Rede Perceptron de Múltiplas Camadas

A rede perceptron de múltiplas camadas, ou PMC, consiste de uma camada de entrada, uma camada de saída e uma ou várias camadas intermediárias ou escondidas. A figura 4.3 mostra a topologia de uma rede PMC. Esta rede é usada, principalmente, em aplicações de reconhecimento de padrões como mostrado em Pandya e Macy [29] e como aproximador universal de funções como mostrado em Haykin [15] e em Chen [22], porém ela pode ser aplicada também em previsão de séries temporais, dentre outras aplicações. Esta rede possui aprendizado supervisionado e é do tipo *Feedforward*.

### 4.5.1 O Processo de Aprendizagem da Rede Perceptron de Múltiplas Camadas

O principal algoritmo de treinamento das redes perceptron multicamadas é o *Backpropagation*, ou o algoritmo de retropropagação. Ele foi proposto pela primeira vez por Paul Werbos [27] e popularizado em 1986 por D.E. Rumelhart, G.E. Hinton e R.J. Williams com a publicação *Learning Representations by Back-Propagating Errors* na revista "Nature", vol. 323 de 1986. Este algoritmo se baseia na minimização do erro entre os valores desejados e os valores efetivamente encontrados pela rede, ou seja, o erro quadrático médio como mostra Haykin [15] e Chen [22].

#### O Algoritmo de Retropropagação

O algoritmo de retropropagação altera os pesos sinápticos da rede neural através da minimização da função do erro quadrático médio. Esta minimização pode ser feita através de técnicas de otimização matemática, como mostrado em Bazaraa [30]. O algoritmo de retropropagação utiliza o método do gradiente como descrito em Abid [31]. Este algoritmo consiste de dois passos bem definidos a saber: **Passo para Frente** e o **Passo Para Trás**.

##### 1. Passo para Frente

No Passo para Frente um padrão de treinamento é aplicado nas entradas da rede neural e as informações são propagadas camada a camada até a saída. Os pesos sinápticos mantêm-se inalterados.

##### 2. Passo para Trás

No Passo para Trás, a partir das saídas encontradas através do primeiro passo, o erro é calculado e propagado na direção das entradas. Neste passo os valores dos pesos sinápticos são alterados de acordo com alguma regra específica. No

caso do algoritmo de retropropagação esta regra é a regra delta generalizada, ou a minimização do erro através do método do gradiente de descida.

Abaixo tem-se o algoritmo de retropropagação que está descrito em Hagan [32], Haykin [15] e também em Abid [31].

### Regra Delta Generalizada

Considerando que  $\underline{p}$  é o vetor de um padrão de entrada e  $\underline{t}$  é o respectivo vetor da saída desejada tem-se que:

$$n^{k+1}(i) = \sum_{j=1}^{S_k} w^{k+1}(i, j)a^k(j) + b^{k+1}(i) \quad (4.8)$$

onde:  $n$  é a saída do combinador linear;

$k + 1$  é o número de camadas da rede neural;

$i$  é o número de neurônios na camada  $k + 1$ ;

$S_k$  é o número de neurônios na camada  $k$ ;

$j$  é o número de neurônios na camada  $k$ ;

$w$  é o peso sináptico do neurônio;

$a$  é a saída do neurônio após a função de ativação;

$b$  é o limiar de ativação do neurônio.

A saída do neurônio  $i$  da camada  $k + 1$  é dada por:

$$a^{k+1}(i) = f^{k+1}(n^{k+1}(i)) \quad (4.9)$$

onde:  $f$  é a função de ativação do neurônio.

Para uma rede neural com  $M$  camadas, o sistema de equações na forma matricial fica:

$$\underline{a}^{k+1} = \underline{f}^{k+1}(W^{k+1}\underline{a}^k + \underline{b}^{k+1}), k = 0, 1, \dots, M - 1 \quad (4.10)$$

Onde tem-se que os padrões de entrada  $\underline{p}$  equivalem a  $\underline{a}^0$ , como mostra a equação 4.11.

$$\underline{a}^0 = \underline{p} \quad (4.11)$$

A equação abaixo mostra o conjunto dos vetores de padrões de treinamento  $\underline{t}$  que serão apresentados à rede com os respectivos vetores de valores desejados  $\underline{p}$ .

$$\{(\underline{p}_1, \underline{t}_1), (\underline{p}_2, \underline{t}_2), (\underline{p}_3, \underline{t}_3), (\underline{p}_4, \underline{t}_4), \dots, (\underline{p}_Q, \underline{t}_Q)\} \quad (4.12)$$

onde  $\underline{p}_q$  e  $\underline{t}_q$  são, respectivamente, as entradas desejadas e as saídas desejadas.

O índice de desempenho para a rede neural é:

$$V = \frac{1}{2} \sum_{q=1}^Q (\underline{t}_q - \underline{a}_q^M)^T (\underline{t}_q - \underline{a}_q^M) = \frac{1}{2} \sum_{q=1}^Q \underline{e}_q^T \underline{e}_q \quad (4.13)$$

onde:  $V$  é a função energia do erro relativo;

$\underline{a}_q^M$  é a saída da rede quando o q-ésimo padrão de entrada  $\underline{p}_q$  é apresentado à rede;

$\underline{e}_q = \underline{t}_q - \underline{a}_q^M$  é o erro para o q-ésimo padrão de entrada.

Aproximando a equação 4.13 [30] tem-se:

$$\hat{V} = \frac{1}{2} \underline{e}_q^T \underline{e}_q \quad (4.14)$$

Aplicando-se o método do gradiente de descida tem-se:

$$\Delta w^k(i, j) = -\alpha \frac{\partial \hat{V}}{\partial w^k(i, j)} \quad (4.15)$$

$$\Delta b^k(i) = -\alpha \frac{\partial \hat{V}}{\partial b^k(i)} \quad (4.16)$$

onde  $\alpha$  é a taxa de aprendizagem da rede.

Definindo  $\delta$  como sendo a sensibilidade do índice de desempenho para a alteração dos valores de entrada da unidade  $i$  da camada  $k$  tem-se:

$$\delta^k(i) \equiv \frac{\partial \widehat{V}}{\partial n^k(i)} \quad (4.17)$$

onde  $\delta^k(i)$  é o gradiente logal da função energia do erro relativo  $V$ .

Utilizando, agora as equações 4.8, 4.14 e 4.17 tem-se a equação 4.20 como segue:

$$\frac{\partial \widehat{V}}{\partial w^k(i, j)} = \frac{\partial \widehat{V}}{\partial n^k(i)} \cdot \frac{\partial n^k(i)}{\partial w^k(i, j)} = \delta^k(i) a^{k-1}(j) \quad (4.18)$$

$$\frac{\partial \widehat{V}}{\partial b^k(i)} = \frac{\partial \widehat{V}}{\partial n^k(i)} \cdot \frac{\partial n^k(i)}{\partial b^k(i)} = \delta^k(i) \quad (4.19)$$

$$\underline{\delta}^k = \dot{F}^k(\underline{n}^k) W^{k+1T} \underline{\delta}^{k+1} \quad (4.20)$$

onde

$$\dot{F}^k(\underline{n}^k) = \begin{pmatrix} f^k(n^k(1)) & 0 & \cdots & 0 \\ 0 & f^k(n^k(2)) & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & f^k(n^k(Sk)) \end{pmatrix} \quad (4.21)$$

e

$$f^k(n) = \frac{df^k(n)}{dn} \quad (4.22)$$

Esta relação de recorrência é inicializada na última camada.

$$\underline{\delta}^M = -\dot{F}^M(\underline{n}^M)(\underline{t}_q - \underline{a}_q) \quad (4.23)$$

Resumindo, o algoritmo de retropropagação segue os seguintes passos:

1. propaga os sinais de entrada através da rede utilizando as equações 4.10 e 1.11;
2. propaga os sinais de erro no sentido contrário ao da propagação, retropropagação, utilizando 4.23 e 4.20;
3. por fim, atualiza os pesos sinápticos utilizando 4.15, 4.16, 4.18 e 4.19, como descrito em Hagan [32].

### O Algoritmo Levenberg-Marquardt

Um dos maiores problemas do algoritmo de retropropagação é a taxa de convergência do algoritmo, como descrito em Abid [31]. Muitas iterações são necessárias para se realizar o treinamento de uma rede pequena, ou seja, trata-se de um algoritmo pouco eficiente computacionalmente.

Para se resolver este problema, várias técnicas foram propostas para aumentar a velocidade de convergência no processo de treinamento das redes neurais do tipo perceptron de múltiplas camadas como mostrado em Abid [31], Parisi [33], Wilamowski [34] e Hagan [32]. O algoritmo utilizado para o treinamento de redes perceptrons de múltiplas camadas, neste trabalho, foi o de Levenberg-Marquardt. Este algoritmo foi implementado utilizando-se a ferramenta *Matlab's Neural Networks Toolbox*.

O algoritmo de Levenberg-Marquardt foi desenvolvido aplicando-se técnicas de otimização não linear [30] para a minimização da função erro. Trata-se de uma aproximação do Método de Newton. Neste caso, o problema é minimizar a função  $V(\underline{x})$  em relação ao parâmetro  $\underline{x}$ .

Utilizando-se o Método de Newton tem-se:

$$\Delta \underline{x} = -[\nabla^2 V(\underline{x})]^{-1} \nabla V(\underline{x}) \quad (4.24)$$

onde  $\nabla^2 V(\underline{x})$  é a matriz Hessiana e  $\nabla V(\underline{x})$  é o gradiente da função.

Assumindo que  $V(\underline{x})$  é a soma dos quadrados da função erro tem-se:

$$V(\underline{x}) = \sum_{i=1}^N e_i^2(\underline{x}) \quad (4.25)$$

então:

$$\nabla V(\underline{x}) = J^T(\underline{x}) \cdot \underline{e}(\underline{x}) \quad (4.26)$$

e

$$\nabla^2 V(\underline{x}) = J^T(\underline{x}) \cdot J(\underline{x}) + S(\underline{x}) \quad (4.27)$$

onde  $J(\underline{x})$  é a matriz Jacobiana.

$$J(\underline{x}) = \begin{pmatrix} \frac{\partial e_1(\underline{x})}{\partial x_1} & \frac{\partial e_1(\underline{x})}{\partial x_2} & \dots & \frac{\partial e_1(\underline{x})}{\partial x_n} \\ \frac{\partial e_2(\underline{x})}{\partial x_1} & \frac{\partial e_2(\underline{x})}{\partial x_2} & \dots & \frac{\partial e_2(\underline{x})}{\partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_N(\underline{x})}{\partial x_1} & \frac{\partial e_N(\underline{x})}{\partial x_2} & \dots & \frac{\partial e_N(\underline{x})}{\partial x_n} \end{pmatrix} \quad (4.28)$$

e

$$S(\underline{x}) = \sum_{i=1}^N e_i(\underline{x}) \cdot \nabla^2 e_i(\underline{x}) \quad (4.29)$$

Para o método de Newton-Gauss é assumido que  $S(\underline{x}) \approx 0$ , portanto, a equação 4.24 torna-se:

$$\Delta \underline{x} = [J^T(\underline{x}) \cdot J(\underline{x})]^{-1} \cdot J^T(\underline{x}) \cdot \underline{e}(\underline{x}) \quad (4.30)$$

A modificação de Levenberg-Marquardt no algoritmo de Newton-Gauss é:

$$\Delta \underline{x} = [J^T(\underline{x}) \cdot J(\underline{x}) + \mu I]^{-1} \cdot J^T(\underline{x}) \cdot \underline{e}(\underline{x}) \quad (4.31)$$

onde  $\mu$  é a política [15], ou seja, "um mapeamento de estados para ações" e  $I$  é a matriz identidade.

O principal passo do algoritmo de Levenberg-Marquardt é o cálculo da matriz Jacobiana. Os termos da matriz Jacobiana podem ser calculados através da alteração do algoritmo de retropropagação. O índice de desempenho é dado pela equação 4.13 que é equivalente em termos de formato a 4.25, onde:

$$\underline{x} = [w^1(1, 1)w^1(1, 2)\dots w^1(S1, R)b^1(1)\dots b^1(S1)w^2(1, 1)\dots b^M(SM)]^T \quad (4.32)$$

e

$$N = Q \times SM \quad (4.33)$$

O algoritmo de retropropagação calcula termos do tipo:

$$\frac{\partial \hat{V}}{\partial w^k(i, j)} = \frac{\partial \sum_{m=1}^{SM} e_q^2(m)}{\partial w^k(i, j)} \quad (4.34)$$

enquanto que o algoritmo de Levenberg-Marquardt calcula termos como o da equação 4.35.

$$\frac{\partial e_q(m)}{\partial w^k(i, j)} \quad (4.35)$$

Estes termos podem ser calculados utilizando-se o algoritmo de retropropagação com a modificação abaixo:

$$\Delta^M = -\dot{F}^M(\underline{n}^M) \quad (4.36)$$

Resumindo tem-se:

1. apresenta-se os padrões de entrada à rede e calcula-se as saídas correspondentes utilizando-se as equações 4.10 e 4.11;
2. calcula-se o erro utilizando  $\underline{e}_q = \underline{t}_q - \underline{a}_q^M$
3. calcula-se a soma dos quadrados dos erros sobre todas as entradas, ou seja,  $V(\underline{x})$ .
4. calcula-se a matriz Jacobiana utilizando-se as equações 4.36, 4.20, 4.18, 4.19 e 4.28;
5. calcula-se a equação 4.31 para se obter  $\Delta\underline{x}$ ;
6. recalcula-se a soma dos quadrados dos erros utilizando  $\underline{x} + \Delta\underline{x}$ . Se a soma deste novo quadrado for menor que o calculado no passo 3,  $\mu$  deve ser reduzido;
7. faz-se  $\underline{x} = \underline{x} + \Delta\underline{x}$  e volta-se para o primeiro passo;
8. se a soma dos quadrados não diminuir, aumenta-se  $\mu$  e retorna-se para o passo 5.
9. o critério de parada é: a norma do gradiente menor que um determinado valor, ou, quando a soma dos quadrados tenha se reduzido a um valor pré-determinado.

Na próxima seção será mostrado o processo de classificação de padrões utilizando-se redes neurais artificiais, que é um dos tipos de análise realizadas neste trabalho, a saber, a classificação de defeitos em tubulações metálicas baseada na assinatura eletromagnética de cada defeito.

## 4.6 Classificação de Padrões Utilizando-se Redes Perceptron Multicamadas

### 4.6.1 Introdução

Segundo Duda&Hart [35] o homem tem a facilidade de reconhecer palavras, pessoas, caracteres manuscritos, dentre outras coisas. Este processo é denominado reconhecimento de padrões. Embora o ser humano faça isto com uma facilidade extrema, fazer com que as máquinas reconheçam padrões é uma tarefa bem complexa e difícil. O termo **reconhecimento de padrões** pode ser definido como o ato de entender dados em seu estado natural e tomar decisões baseado nas categorias destes padrões. Há, basicamente, três formas de se fazer o reconhecimento de padrões em um sistema, ou seja, o sistema de reconhecimento de padrões estatísticos, o sistema de reconhecimento de padrões sintático e o sistema de reconhecimento de padrões que utiliza redes neurais artificiais, como descrito em Pandya [29].

### 4.6.2 Reconhecimento de Padrões Utilizando Redes Neurais Artificiais

A figura 4.4 ilustra o processo de um sistema de reconhecimento de padrões típico. Este sistema funciona da seguinte forma:

1. Fase 1

Nesta fase os dados devem ser coletados e condicionados conforme as condições e necessidades do sistema;

2. Fase 2

A partir dos dados coletados e tratados, deve-se fazer uma separação entre os dados de treinamento e os dados de validação ou teste.

### 3. Fase 3

A arquitetura da rede neural deve ser escolhida de acordo com o tipo de problema a ser resolvido. Uma rede neural com treinamento supervisionado é recomendada se as classes a serem classificadas são conhecidas e se os valores desejados também são conhecidos. Uma arquitetura com treinamento não supervisionado é utilizada se os valores desejados não estão disponíveis. É nesta fase, também, que o número de entradas, o número de saídas, o número de camadas da rede e o número de neurônios por camada são especificados. Também é aqui que o algoritmo de treinamento é escolhido.

### 4. Fase 4

Nesta fase ocorre o treinamento do sistema, ou seja, a rede neural é submetida aos dados de treinamento.

### 5. Fase 5

Após o treinamento da rede, o sistema é testado submetendo-se os dados de validação ou teste à rede já treinada. Se os resultados forem satisfatórios o sistema está pronto para uso, caso contrário é preciso detectar onde está a falha no sistema. Nesta fase é preciso analisar quais foram as reais causas da falha, verificar se os dados são suficientes para o treinamento da rede, se a arquitetura está adequada ou se necessita de mudanças, e se o algoritmo de treinamento é o adequado. Após a conclusão, o processo se repete novamente com as alterações necessárias.

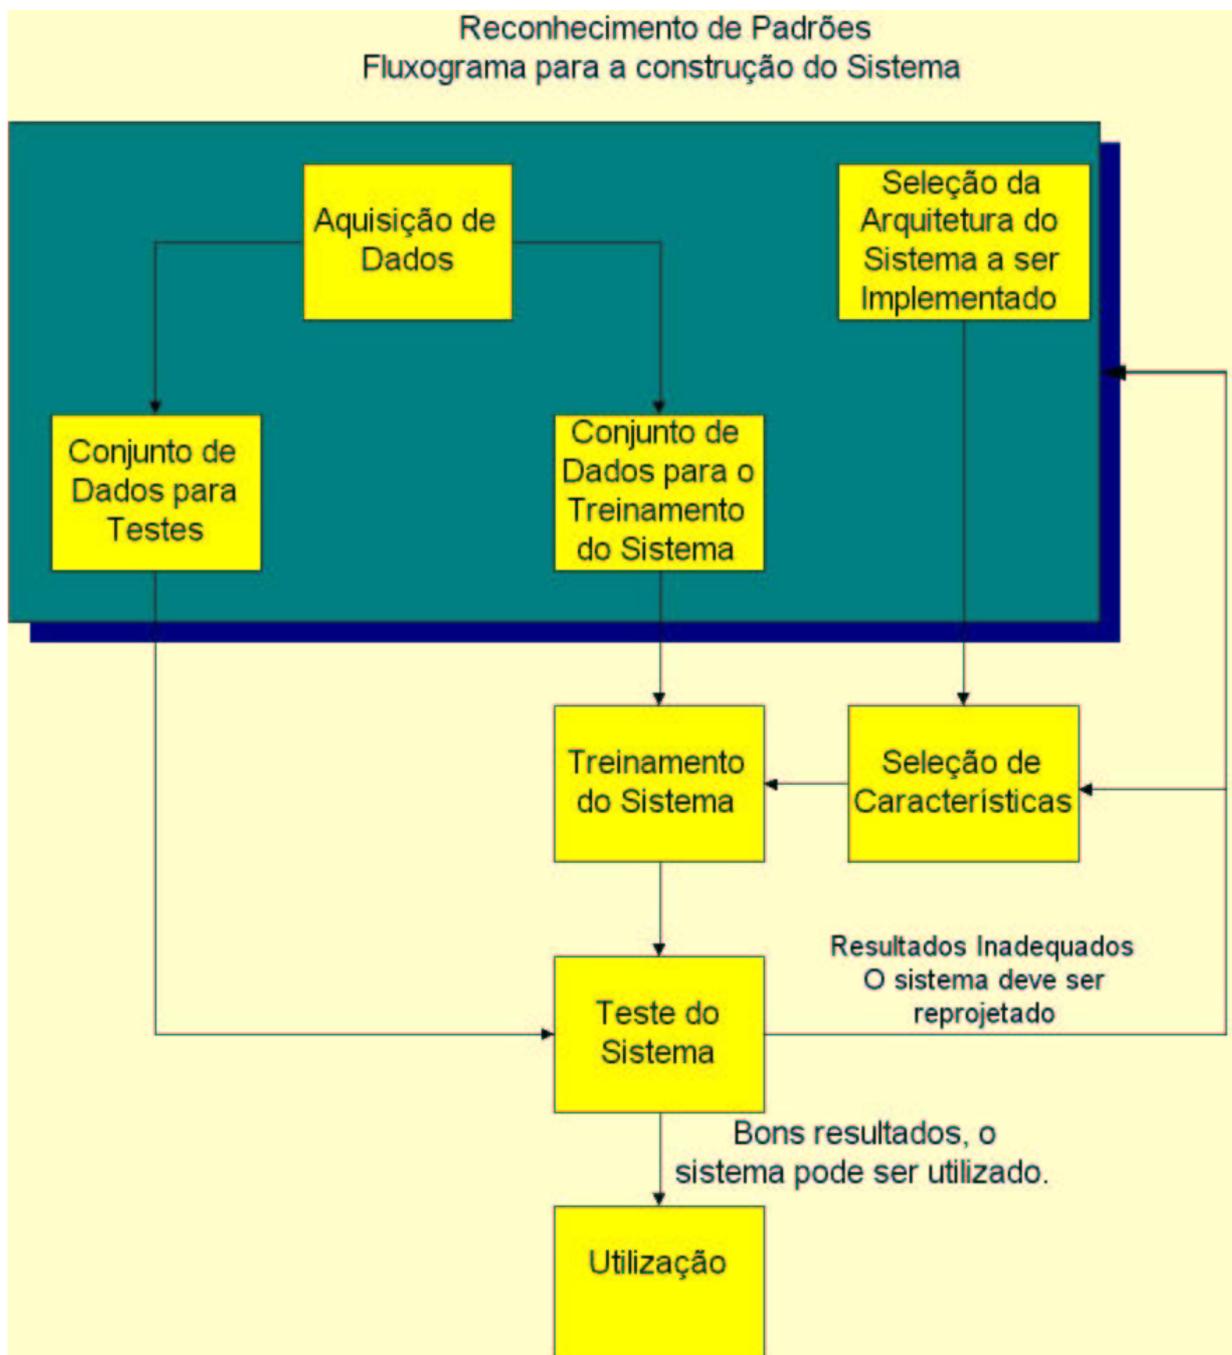


Figura 4.4: Fluxograma para a construção de um sistema de reconhecimento de padrões [29].

## 4.7 Interpolação de Funções Utilizando-se Redes Neurais Artificiais

### 4.7.1 Introdução

Em sistemas altamente complexos e não lineares, o mapeamento das relações entre as variáveis, pode não ser possível, ou ser muito complexo e oneroso. Nestes casos, uma forma de se mapear sistemas altamente não lineares é a utilização de redes neurais artificiais como um aproximador universal de funções como mostra Chen e Ramesh [22]. A aproximação de funções possui um grande número de aplicações nas áreas da engenharia e das ciências exatas em geral. Ela pode mapear funções entre dados de entrada e saída as quais a função matemática que relaciona estes dados não é conhecida ou muito complexa de ser construída. A arquitetura da rede neural utilizada para este tipo de tarefa é a Rede Perceptron Multicamadas.

### 4.7.2 Aproximador de Funções

O aproximador de funções faz o mapeamento da relação entre as entradas e saídas do sistema, ou seja, ele faz o mapeamento da relação entre os valores de entrada e saída do sistema. Os dados de entrada do sistema são os dados de entrada da rede neural. Os dados de saída são os valores desejados quando determinado dado de entrada é apresentado à rede. Trata-se de um treinamento supervisionado de uma rede neural Peceptron Multicamadas. Os dados de entrada e saída do sistema são utilizados no treinamento supervisionado da rede e após a definição da arquitetura e do treinamento da rede, uma vez verificada a convergência e validação da rede neural, ela pode ser utilizada como um aproximador de função, desde que os valores de entrada não estejam fora do domínio da função. Neste caso, a rede funciona como um interpolador de funções.

No próximo capítulo será apresentado aplicações de redes perceptron multicamadas na classificação (reconhecimento de padrões) bem como para a identificação das dimensões de defeitos em tubulações metálicas a partir das assinaturas eletromagnéticas dos mesmos.

## Capítulo 5

# Detecção e Classificação de Defeitos

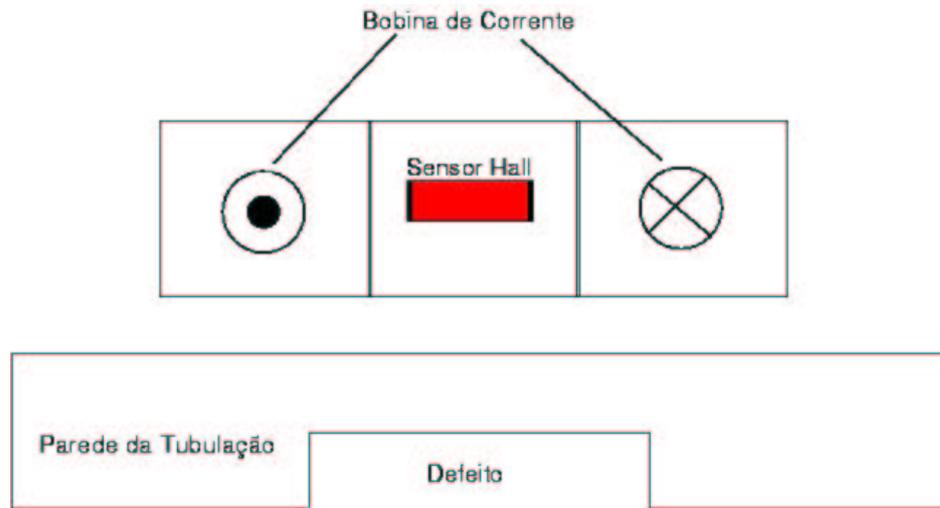


Figura 5.1: Modelo esquemático do sistema com bobina de corrente

## 5.1 Modelagem do Problema

Para a realização das simulações considerou-se uma tubulação metálica hipotética com  $74\text{cm}$  de raio interno e  $75\text{cm}$  de raio externo. Esta tubulação foi modelada em um programa de elementos finitos a fim de se analisar o comportamento da componente normal do vetor indução magnética  $\vec{B}$  na superfície externa da mesma, com os defeitos presentes na parede interna.

Considerou-se dois sistemas hipotéticos de produção de campo e detecção de valores de indução magnética, que são:

1. um sistema formado por uma bobina de corrente e um sensor do tipo *Hall* em seu centro geométrico, como pode ser visto na figura 5.1;
2. um sistema formado por um núcleo de ferro em **U**, com uma bobina de corrente enrolada sobre o mesmo e sensores do tipo *Hall* distribuídos uniformemente na região coberta pelo núcleo de ferro, conforme ilustrado na figura 5.2.

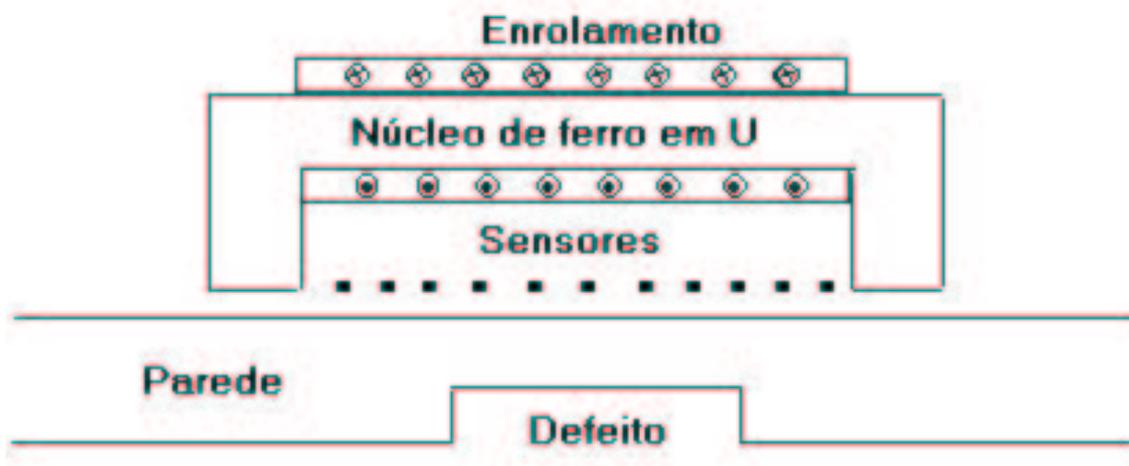
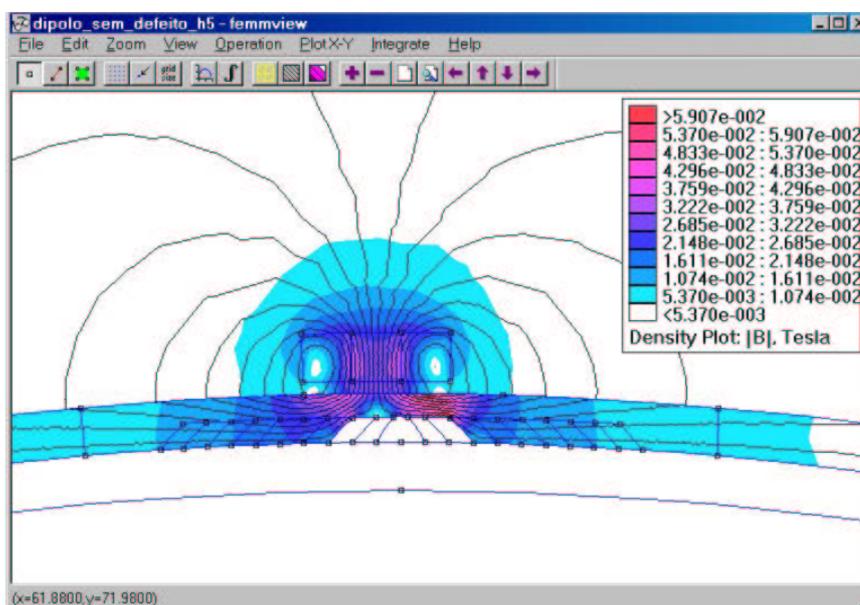


Figura 5.2: Modelo esquemático do sistema com dispositivo em U

Figura 5.3: Bobina de Corrente com gráfico de cores que mostra a intensidade do campo magnético  $\vec{B}$ . Sistema com fluxo magnético disperso no ar

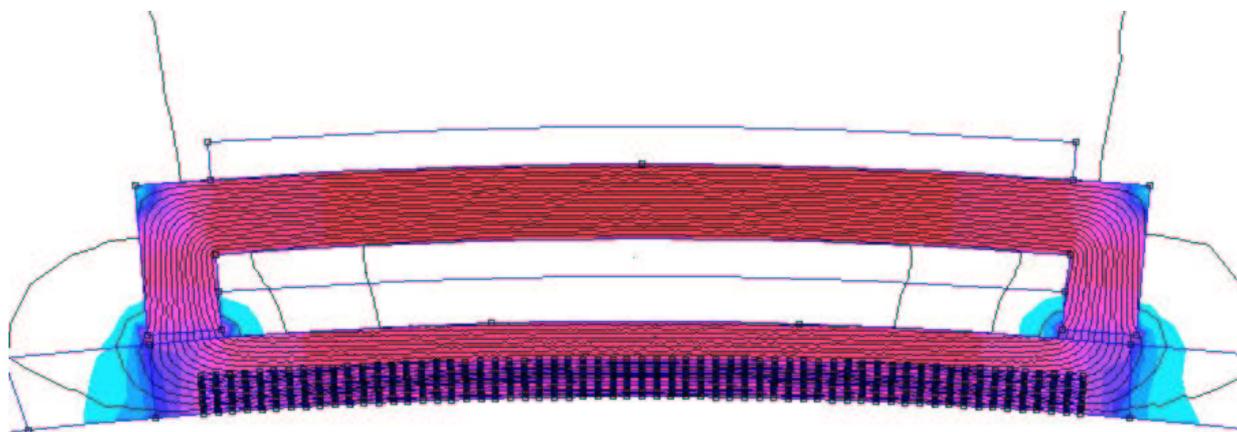


Figura 5.4: Geometria em U com gráfico de cores que mostra a intensidade do campo magnético  $\vec{B}$ . Sistema com fluxo magnético confinado

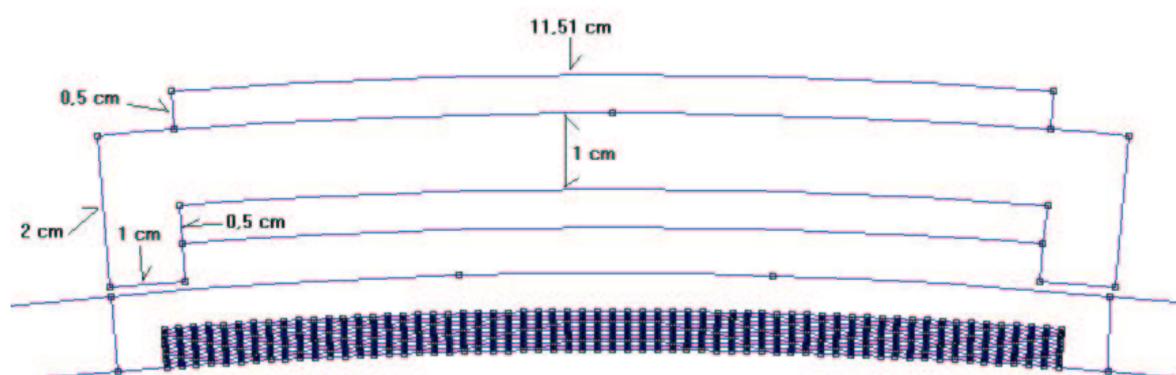


Figura 5.5: Dimensões do dispositivo em forma de U

As figuras 5.3 e 5.4 representam duas distribuições de campos obtidas para cada tipo de análise. Na figura 5.3 pode-se observar que trata-se de um problema de fronteira aberta, ou seja, as linhas de fluxo se espalham pelo ar. No sistema em **U**, como ilustra a figura 5.4, o fluxo está praticamente confinado entre o núcleo de ferro em **U** e a parede da tubulação.

A bobina de corrente da primeira geometria tem as seguintes especificações:

1. a densidade de corrente  $J$  é de  $6,00MA/m^2$ ;
2. está confinada em uma área de  $1,00cm^2$  sendo  $1,00cm$  de altura por  $1,00cm$  de largura;
3. a região onde se encontra o sensor possui permeabilidade magnética  $\mu$  igual a do ar;
4. o raio médio da bobina é  $1,00cm$ ;
5. a distância entre a bobina e a parede externa da tubulação é de  $0,11cm$ .

O dispositivo da geometria com núcleo em **U** tem as seguintes especificações:

1. a densidade de corrente  $J$  é de  $6,00MA/m^2$ ;
2. a região onde se encontra o sensor possui permeabilidade magnética  $\mu$  igual a do ar;
3. as dimensões do núcleo de ferro podem ser observadas na figura 5.5.

Após a modelagem do sistema com o programa de elementos finitos, são feitas as simulações com os defeitos e os resultados são armazenados em arquivos

do tipo texto com os valores da componente normal do vetor indução magnética  $\vec{B}$  que atravessam a região onde se encontra o sensor.

As próximas duas seções irão descrever os dois tipos de análises realizadas. A primeira análise faz a classificação de defeitos baseado em três padrões de classificação previamente conhecidos, ou seja, defeito pequeno, médio e grande utilizando para isto o dispositivo com fluxo disperso no ar e a rede neural funciona como um classificador de padrões. A segunda análise faz a estimação das dimensões dos defeitos, sejam na altura ou na largura. Aqui, a rede neural funciona como um interpolador de funções e o método utilizado é o do fluxo confinado, ou seja, a arquitetura em U.

## 5.2 Primeira Análise - Classificação de Padrões de Defeitos de Acordo com Classes Pré-Definidas

A figura 5.7 apresenta um fluxograma dos procedimentos a serem realizados para a classificação de defeitos em tubulações metálicas. Desta forma tem-se:

1. desenhar a geometria da tubulação juntamente com o dispositivo a ser utilizado, neste caso, o dispositivo da figura 5.6 foi utilizado;
2. as especificações do circuito magnético são acrescentadas tais como a permeabilidade magnética  $\mu$  dos materiais envolvidos, os valores das correntes elétricas, o sentido das correntes, a precisão da malha de elementos finitos e as condições de contorno;
3. definem-se os defeitos, isto é, qual a quantidade de defeitos deverão ser simulados e qual a geometria de cada um;
4. são realizadas as simulações e organização dos dados de saída em arquivos do

tipo texto;

5. verifica-se a coerência dos resultados de indução magnética obtidos;
6. são definidas as classes de defeitos a serem classificados, ou seja, os grupos ao qual cada defeito novo irá pertencer;
7. é feita a definição da arquitetura da rede neural a ser utilizada de acordo com os procedimentos da figura 4.5;
8. este passo um prolongamento do passo anterior, ou seja, uma vez definida a arquitetura da rede, ela deve ser treinada para que possa ser utilizada;
9. neste passo há o teste de validação da rede onde novos padrões são apresentados a mesma, caso os resultados sejam coerentes, pode-se dizer que a rede neural está pronta para realizar a classificação de novos padrões de entrada;
10. neste último passo, considera-se que a rede já tenha aprendido o suficiente sobre o sistema e está apta a classificar novos padrões de defeitos.

Em seguida ter-se-á um detalhamento maior sobre a geração dos defeitos e sobre o procedimento de treinamento da rede neural perceptron multicamadas.

### **Dispositivo com fluxo disperso no ar - Geração dos defeitos**

Utilizando-se o método dos elementos finitos, foram gerados quarenta defeitos diferentes em forma de trapézio como ilustrado na figura 5.8. As dimensões destes defeitos foram variadas de acordo com os dados apresentados nas tabelas 5.1 e 5.2.

Abaixo apresenta-se uma descrição dos procedimentos para a geração dos dados necessários ao treinamento da rede neural artificial.

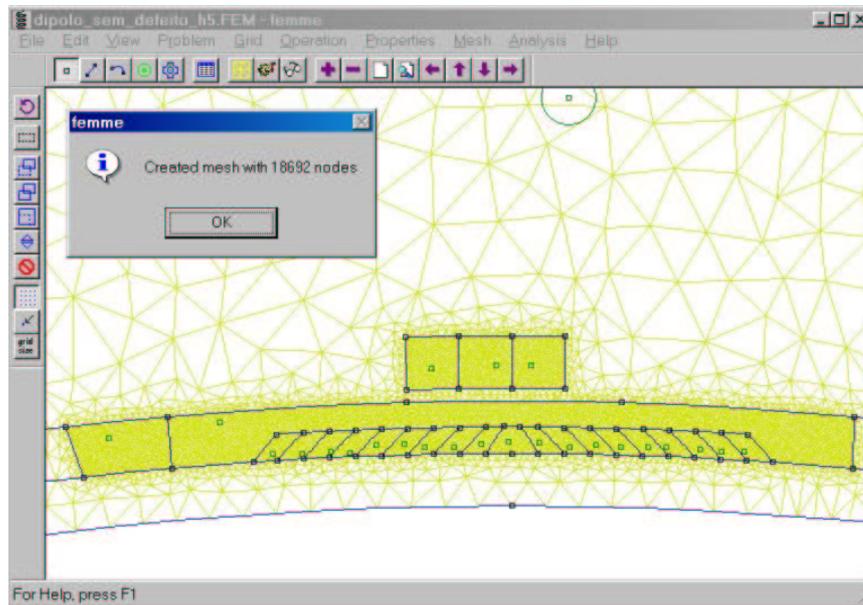


Figura 5.6: Sistema com Bobina de Corrente e Tubulação Metálica Modelados pelo MEF

### Procedimentos

1. Fixar o dispositivo na posição 1 (centro geométrico do defeito) como indicado na figura 5.9;
2. Caracterizar o primeiro defeito com as dimensões  $h_1$ ,  $L_1$  e  $L_{11}$  que são, respectivamente, a altura, a base maior e a base menor do trapézio (tabelas 5.1 e 5.2);
3. Realizar a simulação para esta configuração;
4. Gerar um arquivo de dados que contenha os valores da indução magnética na região do sensor *Hall*;
5. Fazer o deslocamento de  $0,5\text{cm}$  no sentido do centro para a esquerda. Esta posição é a posição 2 do sensor;
6. Voltar ao passo 3 até que o dispositivo chegue à posição 13 como mostra a figura 5.9.

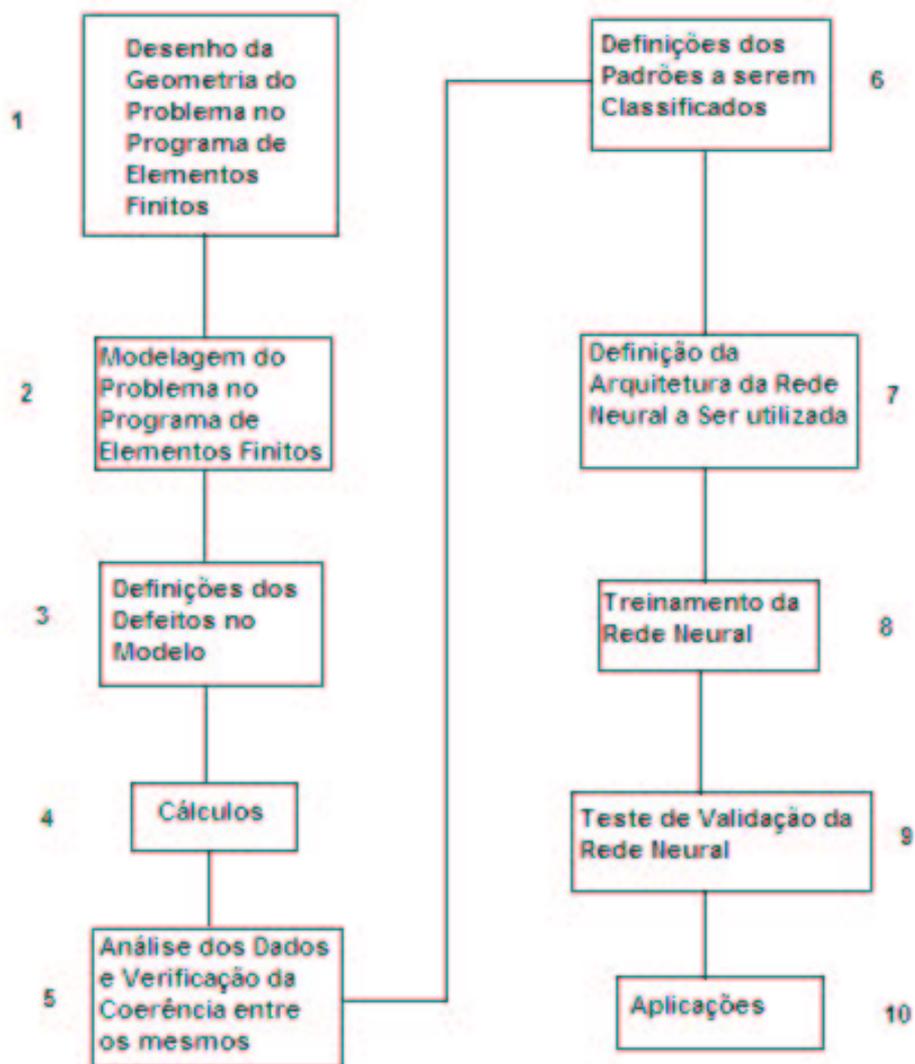


Figura 5.7: Procedimentos para a realização das simulações.

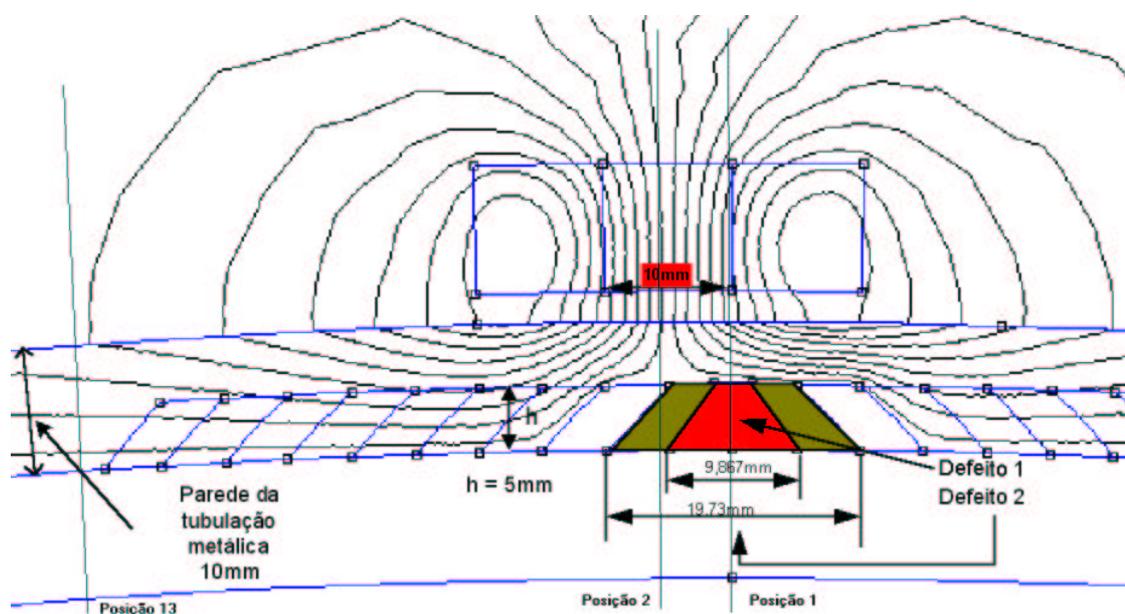


Figura 5.8: Ilustração de dois defeitos gerados através do método dos Elementos Finitos. Neste caso o sistema utilizado é a Bobina de Corrente com o Sensor *Hall* posicionado no centro da mesma.

Após a realização das 13 simulações de elementos finitos para o defeito com dimensões  $(h_1, L_1, L_{11})$ , onde os respectivos valores são mostrados nas tabelas 5.1 e 5.2, novas configurações de defeitos foram caracterizadas. O procedimento anterior foi realizado para 40 defeitos com as dimensões abaixo, onde os valores respectivos de "h" e "L" são mostrados na tabela 5.10:

$[(h_1, L_1, L_{11}), (h_1, L_2, L_{22}), (h_1, L_3, L_{33}), (h_1, L_4, L_{44}), \dots, (h_1, L_{10}, L_{1010})];$   
 $[(h_2, L_1, L_{11}), (h_2, L_2, L_{22}), (h_2, L_3, L_{33}), (h_2, L_4, L_{44}), \dots, (h_2, L_{10}, L_{1010})];$   
 $[(h_3, L_1, L_{11}), (h_3, L_2, L_{22}), (h_3, L_3, L_{33}), (h_3, L_4, L_{44}), \dots, (h_3, L_{10}, L_{1010})];$   
 $[(h_4, L_1, L_{11}), (h_4, L_2, L_{22}), (h_4, L_3, L_{33}), (h_4, L_4, L_{44}), \dots, (h_4, L_{10}, L_{1010})].$

Com a realização das 520 simulações, foram gerados 520 arquivos com os valores da indução magnética. Com estes arquivos, foram gerados 40 vetores com

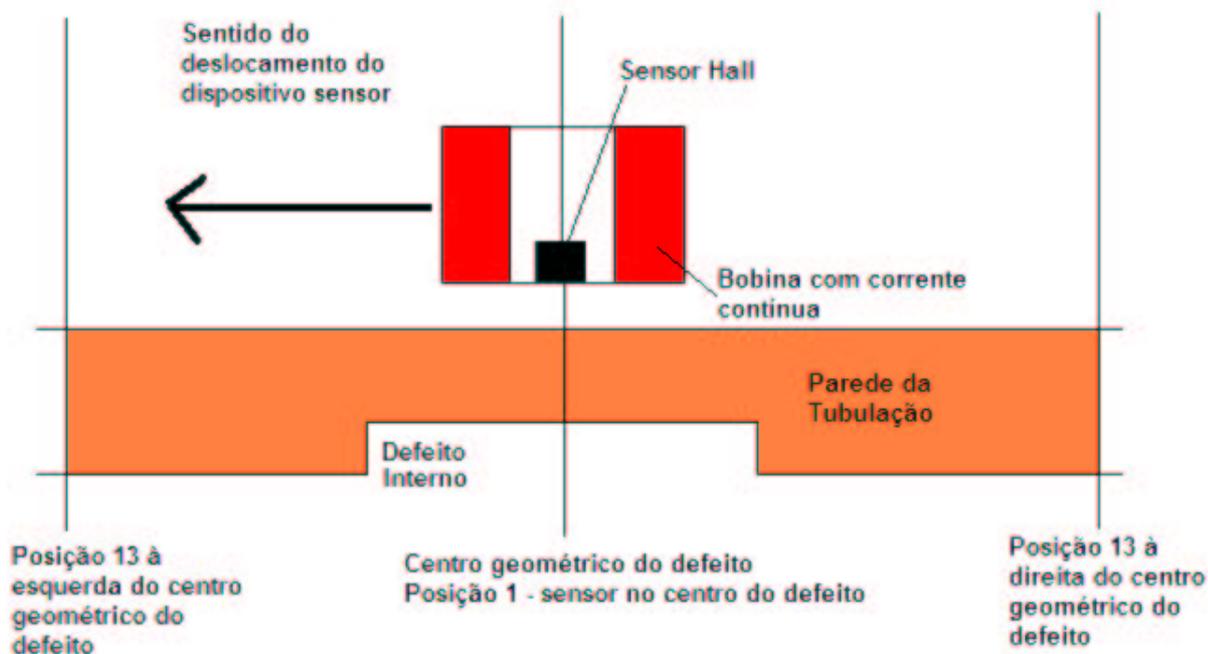


Figura 5.9: Translação dos sistema de detecção de defeitos com fluxo disperso no ar

valores da indução magnética, ou seja, um vetor para cada defeito simulado. Cada vetor possui 25 elementos. Isto se deve ao fato de o problema ser simétrico em relação ao centro geométrico do defeito. A figura 5.9 ilustra esta simetria.

Abaixo tem-se uma ilustração de como foram gerados os vetores de indução magnética para cada defeito. O valor  $p_1$  é o valor da indução magnética no centro do sensor.  $P_1$  indica que o eixo da bobina de corrente está alinhada com o eixo do centro geométrico do defeito. A posição  $p_2$  indica que o eixo da bobina está a  $0,5\text{cm}$  da posição inicial,  $p_1$ , para a direita e para a esquerda e assim sucessivamente até a posição  $p_{13}$ .

$[p_{13}, p_{12}, p_{11}, p_{10}, p_9, p_8, p_7, p_6, p_5, p_4, p_3, p_2, p_1, p_2, p_3, p_4, p_5, p_6, p_7, p_8, p_9, p_{10}, p_{11}, p_{12}, p_{13}]$   
 onde  $p_n$  é a posição do dispositivo sensor.

Alturas	Dimensões (mm)
h1	1,00
h2	2,00
h3	3,00
h4	4,00

Tabela 5.1: Alturas dos defeitos

Base Maior	Dimensões (mm)	Base Menor	Dimensões (mm)
L1	9,87	L11	3,00
L2	19,73	L22	9,92
L3	29,60	L33	19,84
L4	39,47	L44	29,76
L5	49,34	L55	39,68
L6	59,20	L66	49,60
L7	69,18	L77	59,52
L8	78,92	L88	69,44
L9	88,86	L99	79,36
L10	98,24	L1010	89,28

Tabela 5.2: Dimensões das bases maior e menor dos defeitos

### **Análise dos Resultados Obtidos nas Simulações**

Como pode ser visto na figura 5.7, após as simulações, deve ser feita uma verificação da coerência dos resultados de indução magnética obtidos, com o intuito de se verificar a existência de possíveis erros durante as fases de pré-processamento. Uma das formas de se fazer isto consiste em construir gráficos com conjuntos de curvas de indução magnética representando grupos de defeitos com características similares. As figuras 5.10 a 5.13 ilustram os passos realizados para esta verificação.

A figura 5.10 apresenta duas curvas de indução magnética na região do sensor *Hall* no dispositivo, para uma situação sem defeito (valores de referência) e para uma situação com defeito. Pode-se notar facilmente que as curvas são quase coincidentes. Por causa disto, desvios de indução magnética são calculados fazendo-se a diferença entre os valores de indução magnética de situações com e sem defeito. A figura 5.11 apresenta curvas para estes desvios de indução magnética referentes a 10 defeitos que possuem a mesma altura.

O valor do desvio de indução magnética referente a cada posição do sensor é obtido calculando-se a média entre os elementos dos vetores utilizados para gerar as curvas semelhantes às apresentadas na figura 5.11.

A figura 5.12 apresenta os desvios de indução magnética para todas as posições do sensor, referentes aos 10 defeitos com altura de 1,0mm. Semelhantemente, a figura 5.13 apresenta um gráfico com 10 defeitos com altura de 4,0mm.

Uma vez verificada a coerência dos dados calculados pode-se passar para a definição da arquitetura e para o respectivo treinamento da rede neural artificial que será utilizada para o processo de classificação de padrões como se mostrará na próxima seção.

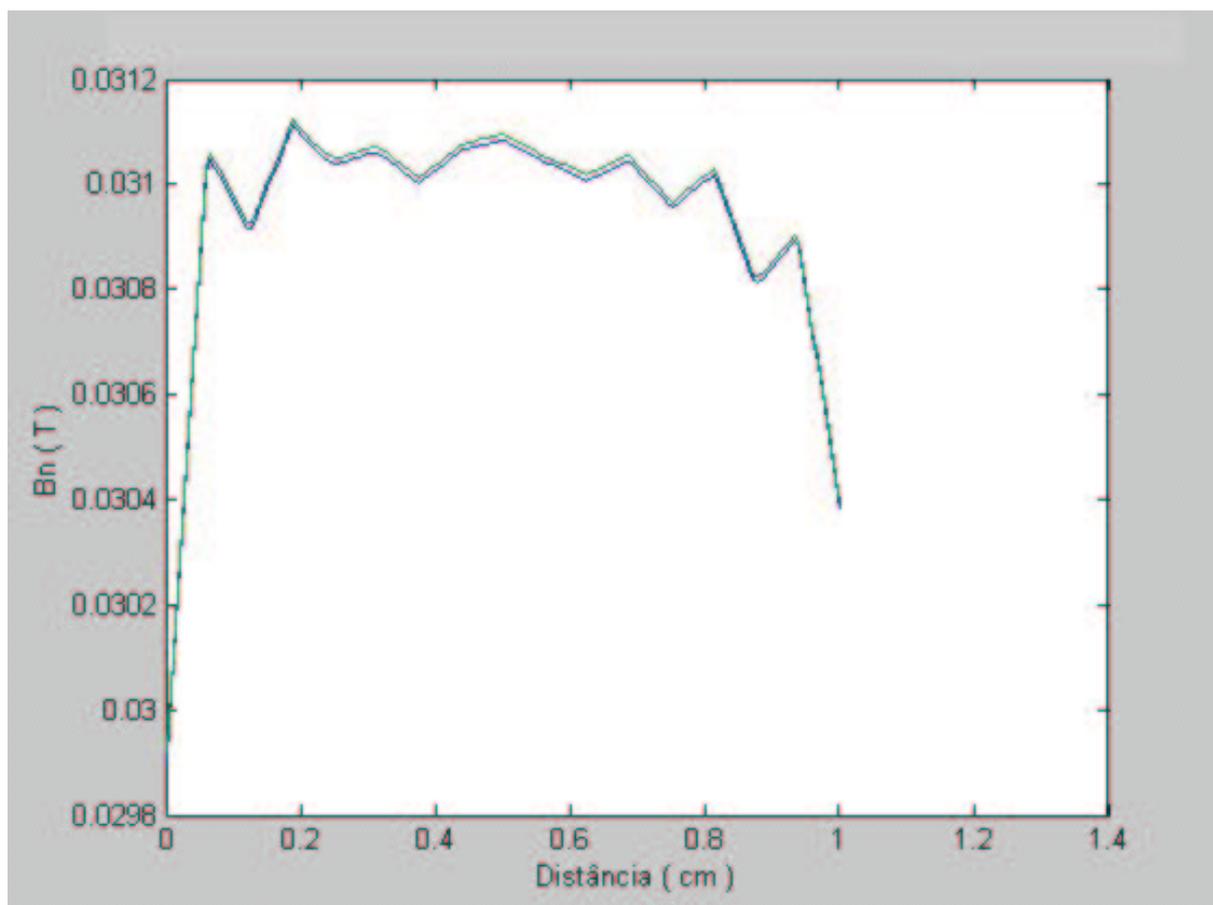


Figura 5.10: Curvas dos valores absolutos da indução magnética em uma mesma posição do sensor, sem defeito (curva menor) e com um defeito (curva maior) de 98,24 mm de comprimento e 4mm de altura.

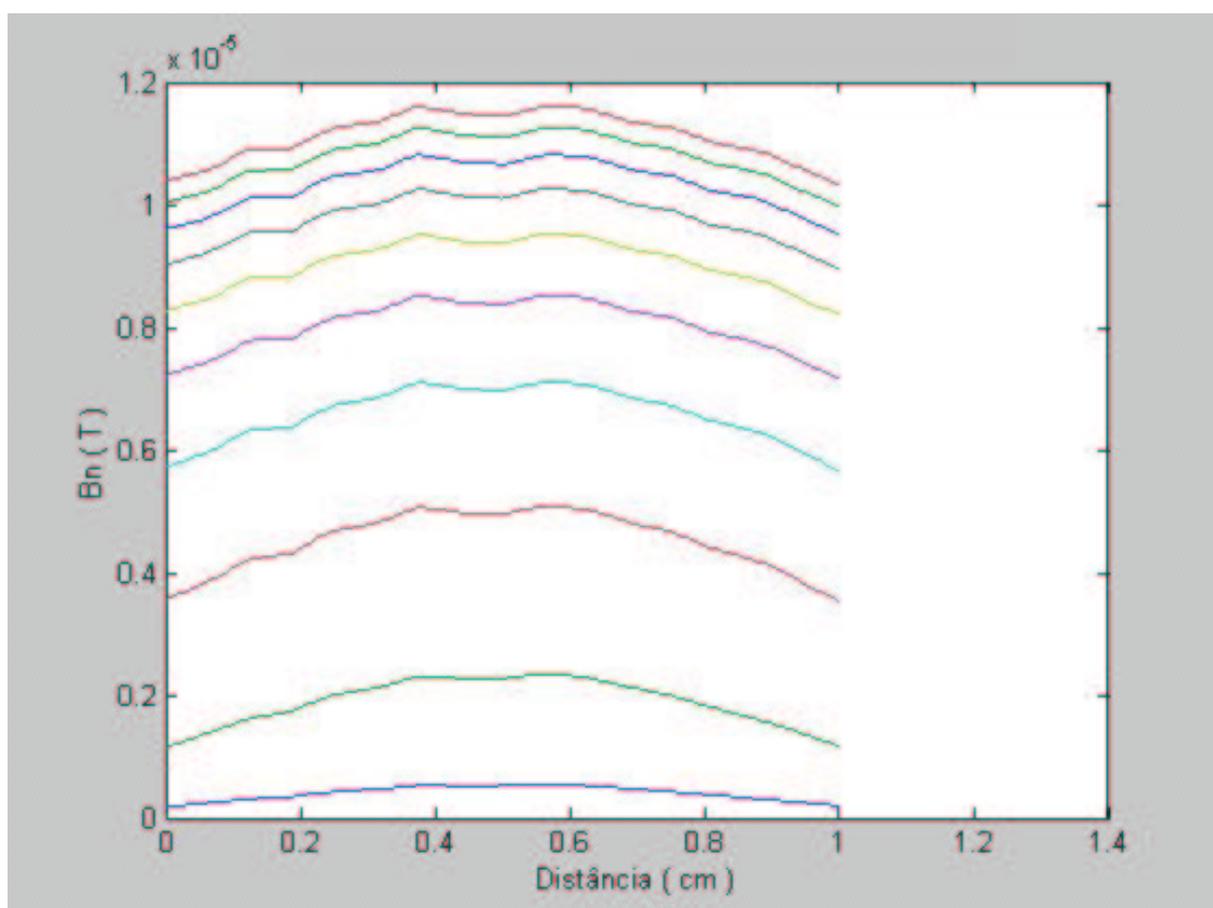


Figura 5.11: Gráficos dos desvios da indução magnética na região da bobina para uma posição do sensor, referentes a dez defeitos com uma mesma altura.

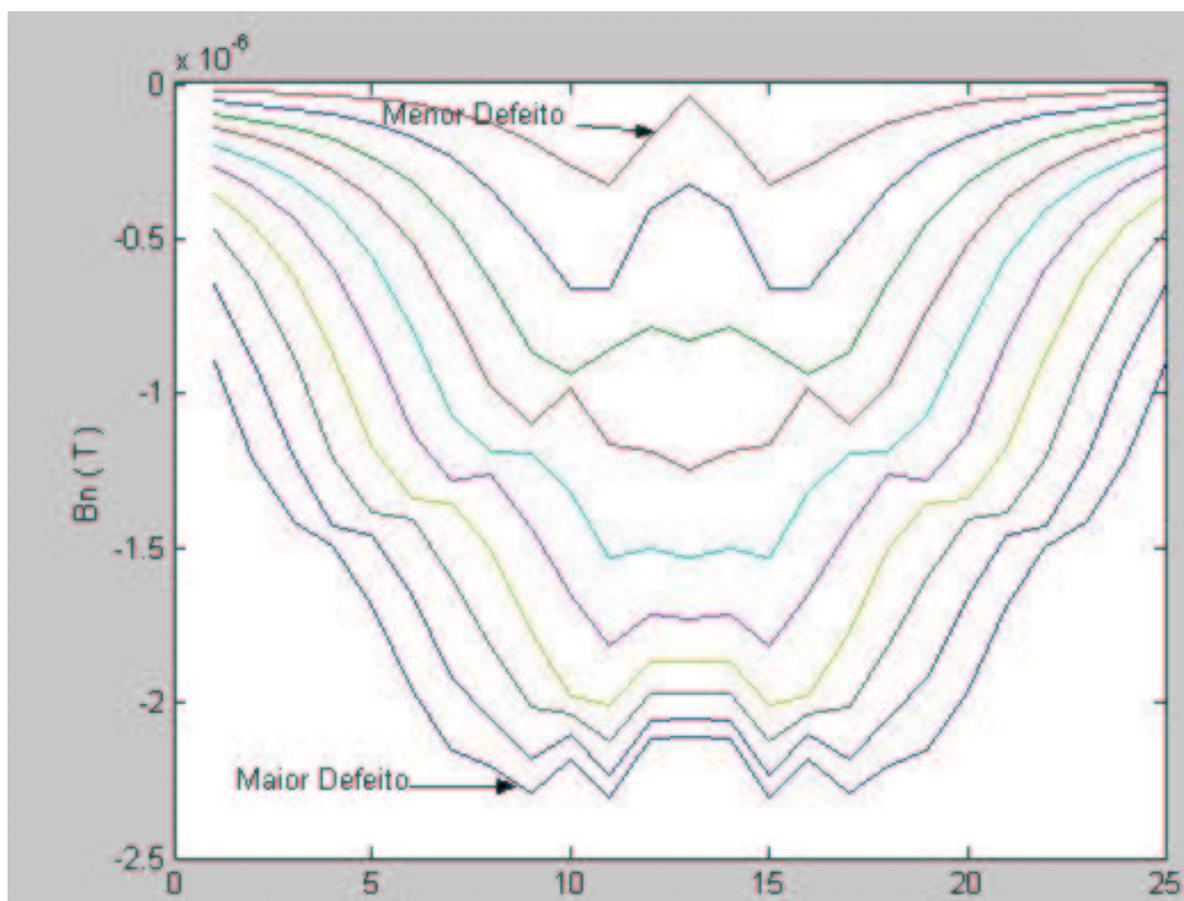


Figura 5.12: Gráfico dos desvios da indução magnética nas 25 posições do sensor, para os defeitos de altura igual a 1 mm

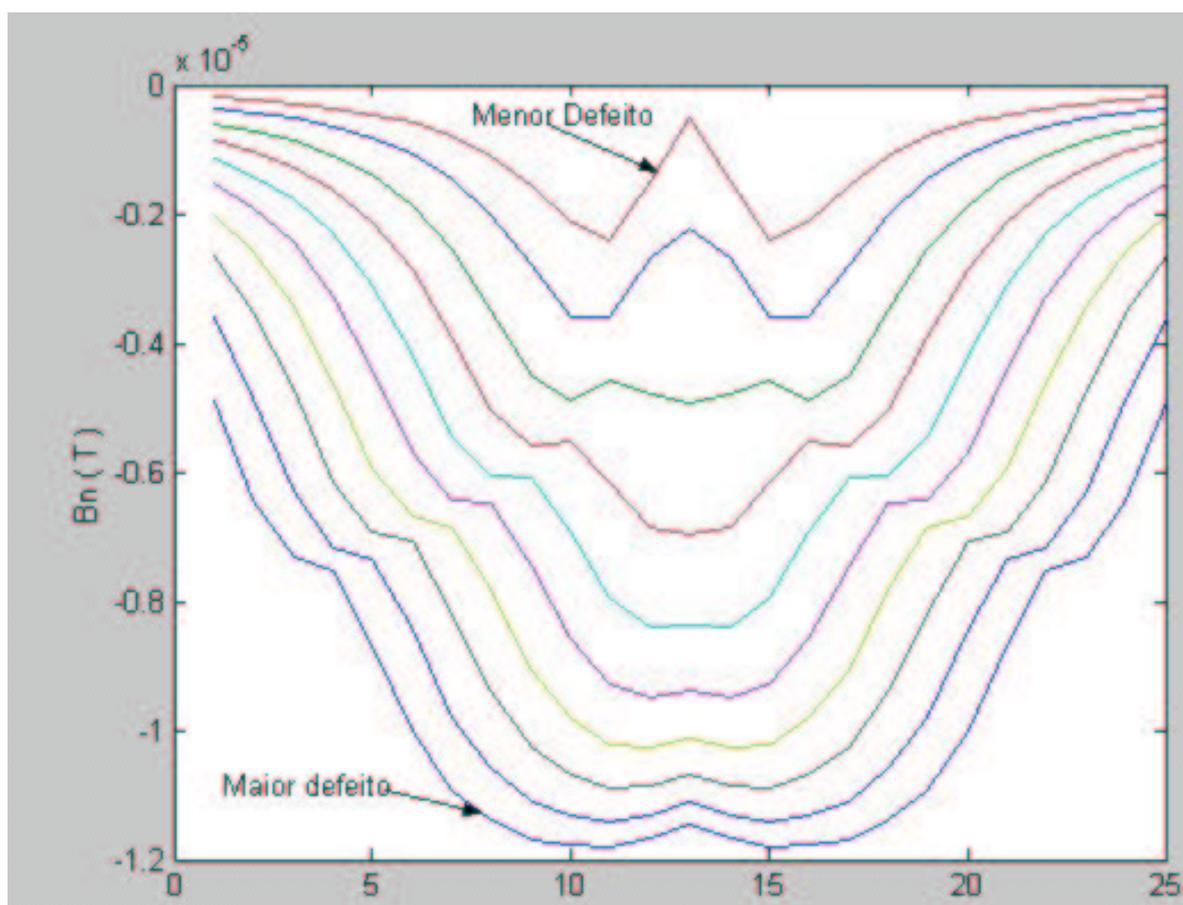


Figura 5.13: Gráfico dos desvios da indução magnética nas 25 posições do sensor, para os defeitos de altura igual a 4 mm

Primeira Camada Escondida	Segunda Camada Escondida	Terceira Terceira Escondida	ERM(%)
15	–	–	13,860
15	–	–	12,460
15	–	–	12,300
20	–	–	12,020
20	–	–	11,710
20	–	–	9,830
15	5	–	5,190
15	5	–	0,570
15	5	–	0,350
15	10	–	2,610
15	10	–	0,670
15	10	–	0,530
15	10	5	0,170
15	10	5	0,090
15	10	5	0,005

Tabela 5.3: Valores dos erros relativos médios obtidos durante diversas seções de treinamento das redes neurais

### Definição da arquitetura e Treinamento da Rede Neural Artificial

Como foi visto no capítulo 4, as redes neurais podem ser utilizadas para a classificação de padrões e também como um aproximador de funções. Neste trabalho foi utilizada a rede Perceptron Multicamadas. A principal justificativa para a utilização da rede Perceptron Multicamadas é que ela pode ser utilizada para os dois propósitos, ou seja, como um aproximador de funções, já mostrado em Chen [22], e como um classificador de padrões, que Pandya [29] fala em sua obra.

Uma vez selecionada a arquitetura, os parâmetros da rede devem ser definidos, tais como o número de camadas intermediárias e os números de neurônios por camadas, assim como as entradas e saídas. O número de neurônios na camada de saída é 2 ( dois ) pois trata-se de uma rede com duas saídas binárias. Cada número binário corresponde a um determinado padrão. Neste trabalho, tem-se três padrões definidos através dos valores binários 00, 01 e 11. Os defeitos do tipo 00 são defeitos pequenos e correspondem aos 5 menores defeitos gerados através do método dos elementos finitos. Os defeitos do tipo 11 são os maiores defeitos e correspondem aos 5 maiores defeitos gerados através do método dos elementos finitos. Os demais defeitos são considerados defeitos médios e possuem valor numérico igual a 01. A tabela 5.3 mostra os valores dos erros relativos médios de várias arquiteturas de redes que foram testadas. Dentre estas redes, a que apresentou melhor resultado foi a rede neural com três camadas intermediárias, sendo que a primeira com 15 neurônios, a segunda camada escondida com 10 neurônios e a terceira, com 5 neurônios.

### **Treinamento da Rede Neural**

Foram gerados 40 vetores com os valores de  $\vec{B}$ , sendo que cada vetor corresponde a um defeito. Para o treinamento da rede neural perceptron multicamadas com o algoritmo de treinamento Levenberg-Marquardt foram separados 4 vetores para a validação cruzada, ou seja, para a validação da rede neural. Assim, o treinamento da rede foi realizado com 36 vetores com 25 elementos cada um. Estes vetores foram apresentados a rede e, após a convergência do algoritmo, foram encontrados os seguintes dados percentuais: erro relativo médio igual a 0,005% e desvio-padrão do erro relativo igual a 0,0016% . A precisão utilizada foi de 0,00001 e o número máximo de épocas de treinamento igual a 200. O critério de parada utilizado foram dois. O treinamento é interrompido quando o erro quadrático médio atinge o valor da precisão ou quando o número de épocas torna-se superior ao número máximo de épocas de treinamento. Na validação cruzada, os quatro vetores utilizados foram classificados corretamente, ou seja, a classificação obteve 100% de acerto.

Defeitos	alturas dos defeitos (mm)	comprimentos dos defeitos (mm)	Valores esperados	Valores obtidos
1	3,0000	35,2600	0 1	0 1
2	1,0000	84,2300	0 0	0 0
3	4,0000	81,5500	1 1	1 1

Tabela 5.4: Valores obtidos e esperados para novos defeitos apresentados à rede neural

Para o treinamento da rede neural artificial foi utilizado o pacote computacional **Neural Networks Toolbox do Matlab**.

### Classificação dos Defeitos e Análise dos Resultados

Após o treinamento da rede neural e da validação cruzada foram gerados 3 novos defeitos sendo um do tipo 1, um do tipo 2 e o último do tipo 3. Estes defeitos não participaram do processo de treinamento da rede neural artificial, assim como não participaram do processo de validação cruzada. Eles foram apresentados à rede neural a fim de que ela os classificasse. Os resultados obtidos estão apresentados na tabela 5.4 e pode-se observar que a rede neural classificou os novos defeitos de uma forma coerente o que indica o potencial desta técnica na classificação de defeitos em tubulações metálicas.

## 5.3 Segunda Análise - Estimação das Dimensões dos Defeitos

Nesta segunda análise, o objetivo é detectar os defeitos e também verificar quais as suas dimensões. Os procedimentos são semelhantes à análise anterior,

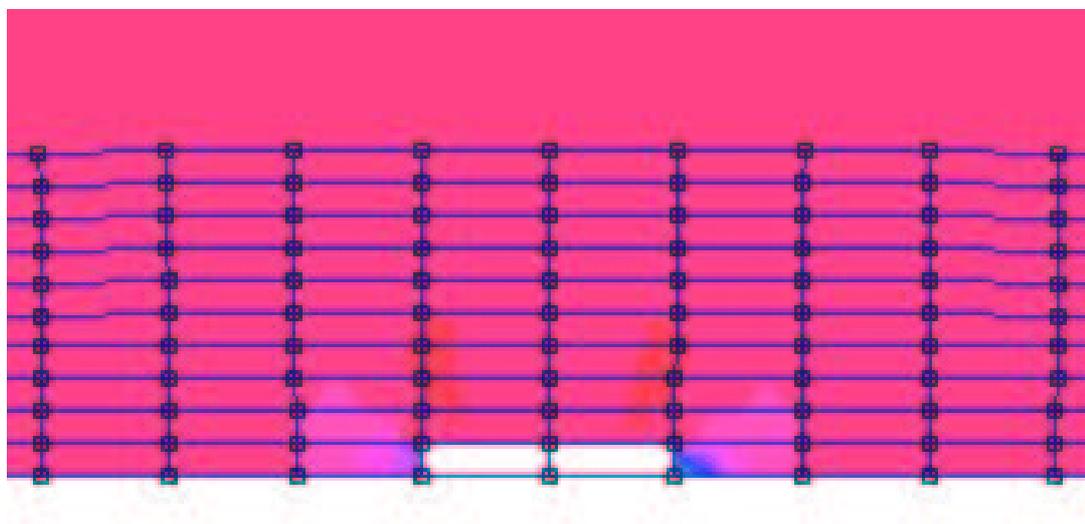


Figura 5.14: Fragmento da parede da tubulação com um defeito de 3,87 mm de comprimento por 0,5 mm de altura

porém, neste caso, a rede neural artificial funciona como um interpolador de funções.

### Dispositivo com fluxo confinado - Geração dos defeitos

Com esta geometria, foram gerados 300 defeitos retangulares, sendo que o menor defeito tem 3,87 mm de comprimento e 0,5 mm de altura e o maior defeito tem 116,2 mm de comprimento e 5 mm de altura. Os defeitos foram gerados da menor altura para a maior altura e do centro para as extremidades. Neste caso, o dispositivo sensor permaneceu estático, variando, somente, as dimensões dos defeitos simulados. A figura 5.18 ilustra o menor defeito simulado. Cada camada possui 30 defeitos, como tem-se 10 camadas, logo tem-se 300 defeitos que, por sua vez, gera 300 vetores de treinamento com 11 elementos em cada um pois, neste caso, foram considerados onze pontos de amostra na região entre o núcleo de ferro e a parede da tubulação, como mostra a figura 5.2.

### **Análise dos Resultados Obtidos**

De forma semelhante à primeira análise, é necessário verificar a coerência dos valores de indução magnética obtidos através das simulações com o método dos elementos finitos. Novamente, isto é feito construindo-se gráficos com um conjunto de curvas representando desvios de indução magnética para famílias de defeitos, como pode ser visto nas figuras 5.15, 5.16, 5.17 e 5.18, as curvas apresentam comportamentos semelhantes, o que indica que os valores obtidos são coerentes. Se alguma curva estivesse fora do padrão, por exemplo um pico fora da posição central, isto indicaria que as simulações de elementos finitos correspondentes àquele defeito específico deveriam ser refeitas, pois é muito provável que tenha havido algum tipo de erro nos cálculos.

### **Definição da arquitetura e Treinamento da Rede Neural Artificial**

O processo para a determinação da arquitetura da rede neural é o mesmo que foi apresentado na análise anterior. A rede neural **Perceptron Multicamadas**, aqui, é utilizada como um aproximador de funções que relaciona a indução magnética com as dimensões dos defeitos. O domínio da função corresponde aos valores de indução magnética que estão entre os valores que dizem respeito ao menor e ao maior defeito apresentado. Esta rede foi capaz de fazer o mapeamento da função, possibilitando, assim, a estimação das dimensões de novos defeitos que se encontram entre as dimensões do maior e do menor defeito.

A arquitetura da rede consiste de 4 camadas. A primeira camada com 11 neurônios, a última camada com 2 neurônios, a primeira camada escondida com 30 e a segunda camada escondida com 22. As tabelas 5.5, 5.6 e 5.7 mostram os resultados da validação cruzada da arquitetura da rede apresentada. Para o treinamento da rede foram utilizados 225 vetores, ou 75% dos dados disponíveis. Dos 300 vetores originais, 25% foram utilizados para o processo de validação da rede. A figura 5.24 ilustra a convergência do algoritmo de treinamento de acordo com o número de épocas.

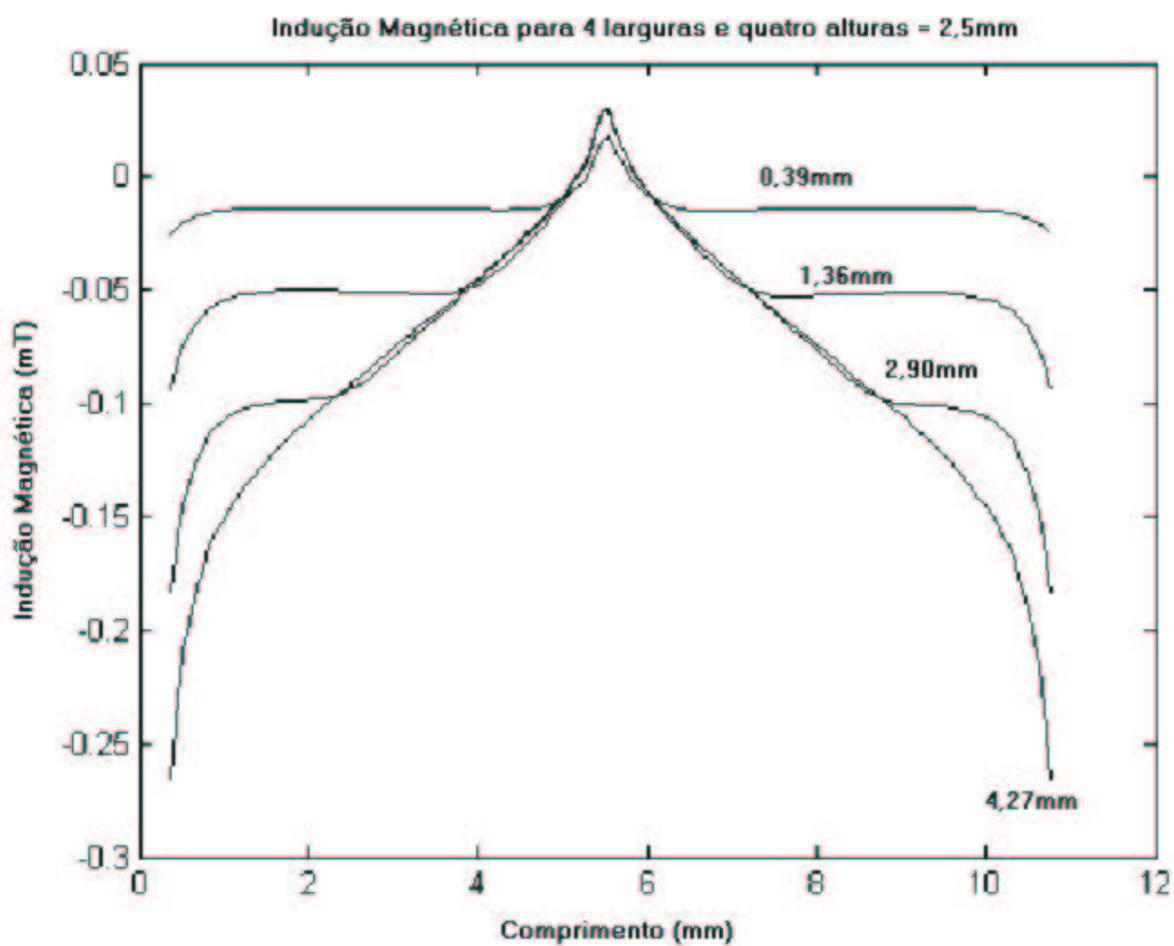


Figura 5.15: Indução magnética para 4 defeitos com altura fixa igual a 2,50 mm e larguras de 0,39 mm; 1,36 mm; 2,90 mm e 4,27 mm.

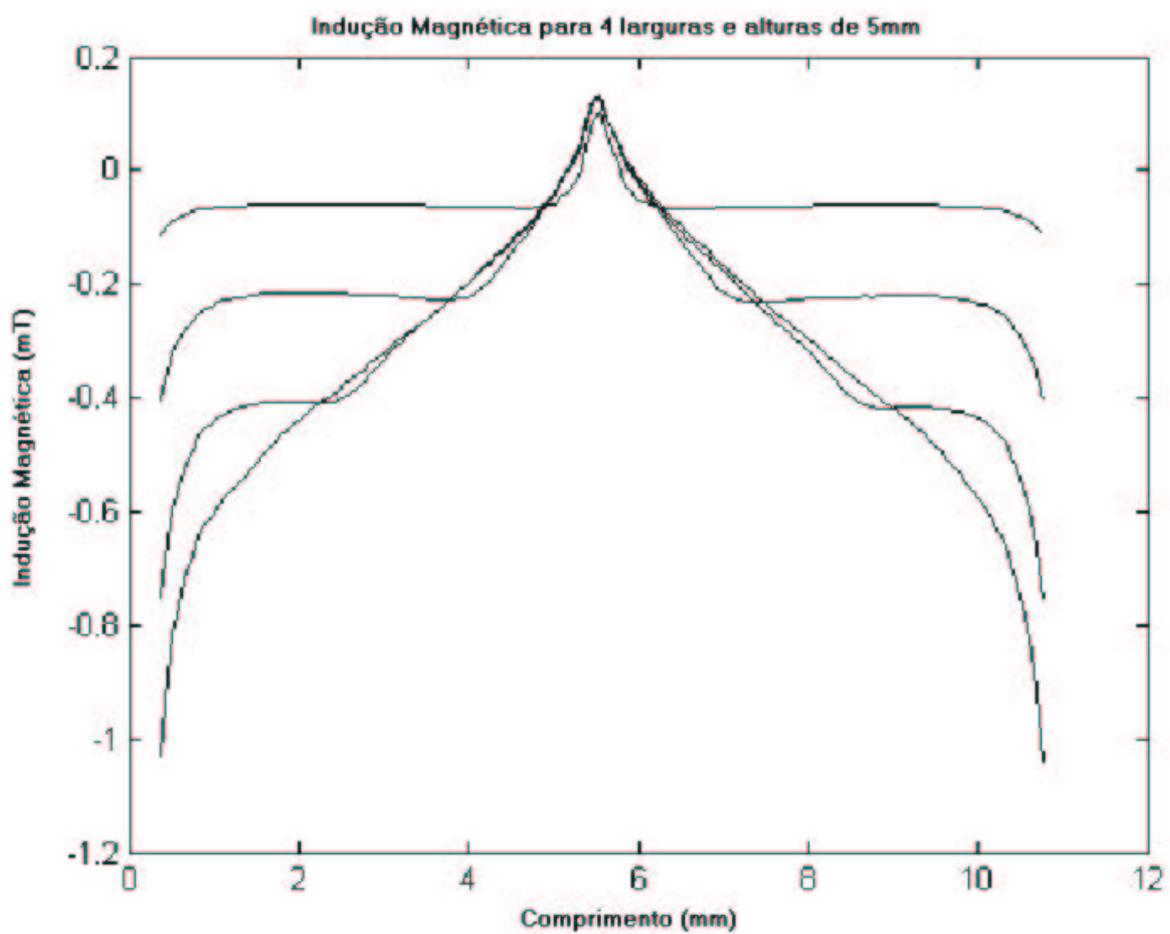


Figura 5.16: Indução magnética para 4 defeitos com altura fixa igual a 5,00 mm e larguras de 0,39 mm; 1,36 mm; 2,90 mm e 4,27 mm

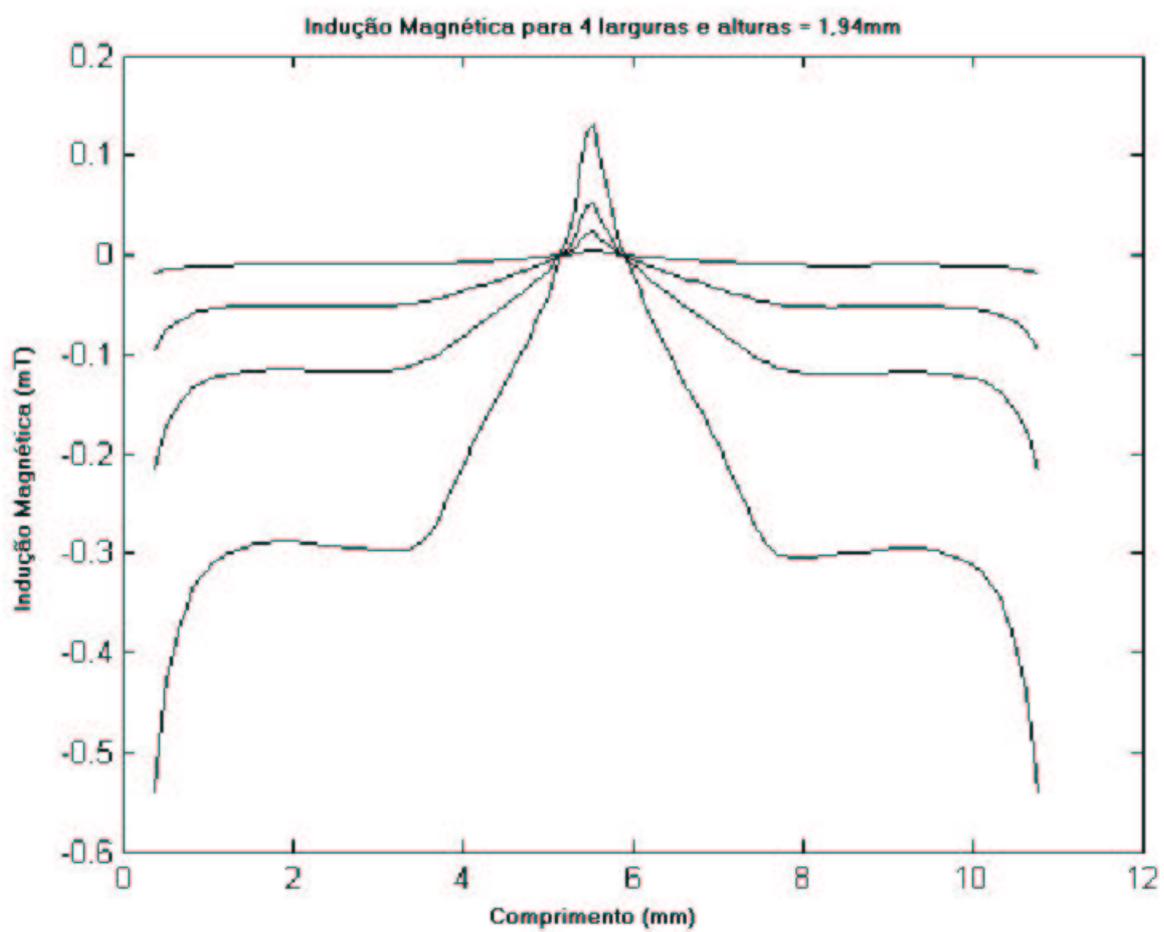


Figura 5.17: Indução magnética para 4 defeitos com largura fixa igual a 1,94 mm e 4 alturas diferentes

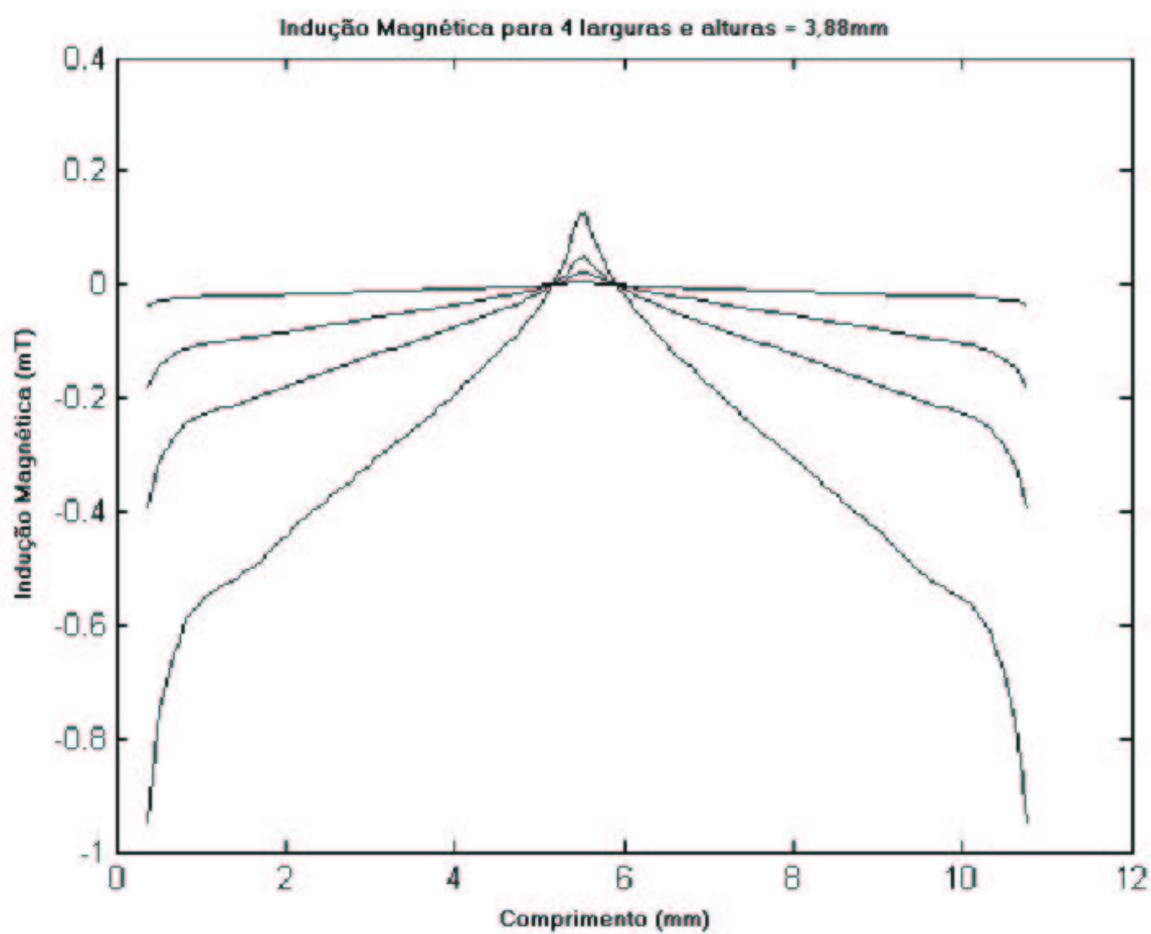


Figura 5.18: Indução magnética para 4 defeitos com largura fixa igual a 3,88 mm e 4 alturas diferentes

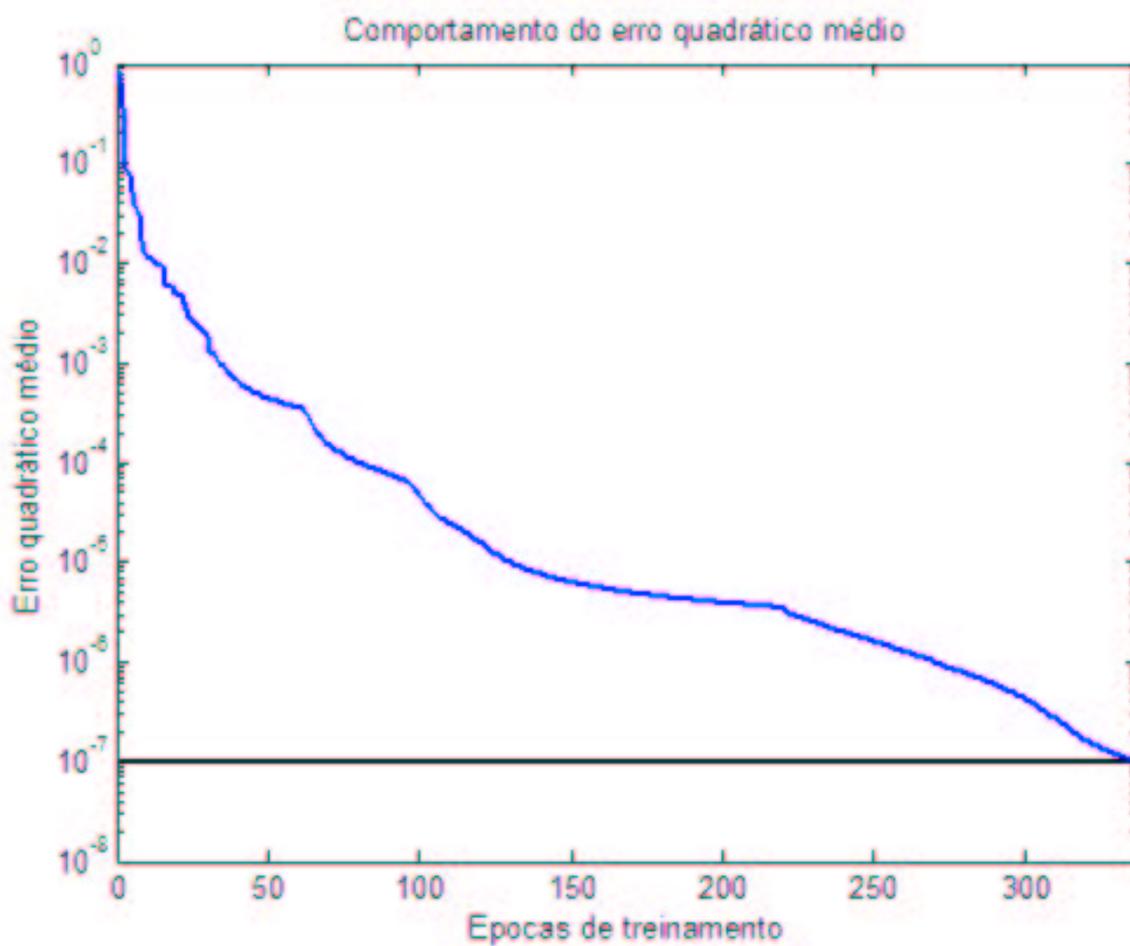


Figura 5.19: Convergência do erro quadrático médio em uma seção de treinamento da rede neural artificial.

	AD(mm)	CD(mm)	A(mm)	C(mm)	ERA(%)	ERC(%)
1	0,0500	0,7760	0,0500	0,7807	0,0323	0,6057
2	0,0500	1,5520	0,0500	1,5553	0,0162	0,2143
3	0,0500	2,3280	0,0500	2,3279	0,0003	0,0045
4	0,0500	3,1040	0,0500	3,1056	0,0001	0,0517
5	0,0500	3,8800	0,0500	3,8800	0,0001	0,0010
6	0,0500	4,6560	0,0500	4,6608	0,0001	0,1027
7	0,0500	5,4320	0,0500	5,3775	0,0002	1,0031
8	0,1000	0,3880	0,1010	0,2668	1,0357	31,2417
9	0,1000	1,1640	0,1000	1,1684	0,0020	0,3776
10	0,1000	1,9400	0,1000	1,9405	0,0366	0,0268
11	0,1000	2,7160	0,1000	2,7181	0,0118	0,0763
12	0,1000	3,4920	0,1000	3,4896	0,0248	0,0682
13	0,1000	4,2680	0,1000	4,2673	0,0125	0,0162
14	0,1000	5,0440	0,1000	5,0491	0,0292	0,1015
15	0,1000	5,8200	0,0999	5,8196	0,1072	0,0075
16	0,1500	0,7760	0,1499	0,7711	0,0654	0,6265
17	0,1500	1,5520	0,1499	1,5507	0,0342	0,0832
18	0,1500	2,3280	0,1500	2,3294	0,0333	0,0595
19	0,1500	3,1040	0,1500	3,1031	0,0199	0,0275
20	0,1500	3,8800	0,1500	3,8821	0,0271	0,0544
21	0,1500	4,6560	0,1499	4,6548	0,0410	0,0258
22	0,1500	5,4320	0,1500	5,4348	0,0129	0,0511
23	0,2000	0,3880	0,1997	0,3976	0,1381	2,4787
24	0,2000	1,1640	0,2000	1,1614	0,0150	0,2275
25	0,2000	1,9400	0,2000	1,9389	0,0230	0,0550
26	0,2000	2,7160	0,2000	2,7152	0,0144	0,0313
27	0,2000	3,4920	0,2000	3,4940	0,0095	0,0576
28	0,2000	4,2680	0,2000	4,2666	0,0181	0,0336
29	0,2000	5,0440	0,2000	5,0445	0,0207	0,0106
30	0,2000	5,8200	0,2000	5,8200	0,0181	0,0000

Tabela 5.5: Erro relativo médio (ERM) dos 75 vetores de validação, onde AD é a altura desejada, CD o comprimento desejado, A é a altura respondida pela rede, C é o comprimento fornecido pela rede, ERA é o erro relativo dos valores das alturas e ERC é o erro relativo dos valores dos comprimentos.

	AD(mm)	CD(mm)	A(mm)	C(mm)	ERA(%)	ERC(%)
31	0,2500	0,7760	0,2499	0,7753	0,0254	0,0960
32	0,2500	1,5520	0,2500	1,5509	0,0085	0,0723
33	0,2500	2,3280	0,2500	2,3272	0,0115	0,0334
34	0,2500	3,1040	0,2500	3,1014	0,0146	0,0826
35	0,2500	3,8800	0,2500	3,8787	0,0001	0,0339
36	0,2500	4,6560	0,2499	4,6564	0,0310	0,0078
37	0,2500	5,4320	0,2499	5,4475	0,0304	0,2850
38	0,3000	0,3880	0,3007	0,3882	0,2230	0,0468
39	0,3000	1,1640	0,3000	1,1679	0,0143	0,3345
40	0,3000	1,9400	0,2999	1,9362	0,0222	0,1953
41	0,3000	2,7160	0,3000	2,7153	0,0110	0,0243
42	0,3000	3,4920	0,3000	3,4863	0,0028	0,1646
43	0,3000	4,2680	0,2999	4,2648	0,0171	0,0748
44	0,3000	5,0440	0,3000	5,0692	0,0003	0,4997
45	0,3000	5,8200	0,2999	5,8200	0,0236	0,0000
46	0,3500	0,7760	0,3496	0,7749	0,1208	0,1451
47	0,3500	1,5520	0,3501	1,5506	0,0266	0,0875
48	0,3500	2,3280	0,3500	2,3265	0,0033	0,0633
49	0,3500	3,1040	0,3501	3,0906	0,0339	0,4321
50	0,3500	3,8800	0,3500	3,8801	0,0011	0,0036
51	0,3500	4,6560	0,3500	4,6582	0,0035	0,0469
52	0,3500	5,4320	0,3500	5,4947	0,0092	1,1534
53	0,4000	0,3880	0,4020	0,3676	0,5006	5,2560
54	0,4000	1,1640	0,4004	1,1575	0,1043	0,5553
55	0,4000	1,9400	0,3998	1,9395	0,0412	0,0233
56	0,4000	2,7160	0,4000	2,7127	0,0118	0,1230
57	0,4000	3,4920	0,4000	3,4861	0,0107	0,1700
58	0,4000	4,2680	0,4000	4,2651	0,0033	0,0679
59	0,4000	5,0440	0,3990	5,2491	0,2420	4,0655
60	0,4000	5,8200	0,3999	5,8200	0,0175	0,0000

Tabela 5.6: Erro relativo médio (ERM) dos 75 vetores de validação, onde AD é a altura desejada, CD o comprimento desejado, A é a altura respondida pela rede, C é o comprimento fornecido pela rede, ERA é o erro relativo dos valores das alturas e ERC é o erro relativo dos valores dos comprimentos

	AD(mm)	CD(mm)	A(mm)	C(mm)	ERA(%)	ERC(%)
61	0,4500	0,7760	0,4501	0,7647	0,0189	1,4524
62	0,4500	1,5520	0,4499	1,5570	0,0183	0,3227
63	0,4500	2,3280	0,4499	2,3297	0,0141	0,0709
64	0,4500	3,1040	0,4500	3,1009	0,0011	0,0991
65	0,4500	3,8800	0,4500	3,8935	0,0078	0,3485
66	0,4500	4,6560	0,4502	4,6536	0,0422	0,0513
67	0,4500	5,4320	0,4500	5,5103	0,0102	1,4406
68	0,5000	0,3880	0,4980	0,5039	0,4045	29,8627
69	0,5000	1,1640	0,5000	1,1813	0,0012	1,4876
70	0,5000	1,9400	0,5000	1,9180	0,0011	1,1326
71	0,5000	2,7160	0,5000	2,7272	0,0013	0,4124
72	0,5000	3,4920	0,5000	3,4929	0,0010	0,0272
73	0,5000	4,2680	0,5000	4,2742	0,0008	0,1448
74	0,5000	5,0440	0,5000	5,0090	0,0002	0,6936
75	0,5000	5,8200	0,5000	5,8200	0,0009	0,0000

Tabela 5.7: Erro relativo médio (ERM) dos 75 vetores de validação, onde AD é a altura desejada, CD o comprimento desejado, A é a altura respondida pela rede, C é o comprimento fornecido pela rede, ERA é o erro relativo dos valores das alturas e ERC é o erro relativo dos valores dos comprimentos

Defeitos	alturas desejadas (mm)	alturas obtidas (mm)	comprimentos desejados (mm)	comprimentos obtidos (mm)
1	0,0750	0,0749	2,910	2,909
2	0,1750	0,1752	4,462	4,460
3	0,3250	0,3247	4,850	4,853
4	0,5750	0,3247	2,522	2,521
5	0,7250	0,7246	4,080	4,078

Tabela 5.8: Dimensões dos novos defeitos apresentados e os respectivos resultado da rede neural

### **Estimação das Dimensões dos Defeitos e Análises dos Resultados**

Nesta análise, assim como na análise anterior, após o treinamento da rede neural e de sua validação, novos defeitos foram gerados através do método dos elementos finitos a fim de se verificar o funcionamento da rede neural artificial. Como mostra a tabela 5.8, pode-se verificar que a rede determinou com sucesso as dimensões dos novos defeitos apresentados.

## Capítulo 6

### Conclusões e Sugestões

Este trabalho apresentou um estudo que propões uma associação entre o Método dos Elementos Finitos e as Redes Neurais Artificiais para a detecção de defeitos em tubulações metálicas utilizando o método da Dispersão do Fluxo Magnético.

O método dos elementos finitos foi utilizado para simular defeitos e gerar dados de treinamento baseado em duas arquiteturas de dispositivos; a primeira, uma bobina de corrente com um sensor *Hall* em seu centro geométrico e a segunda um núcleo de ferro em U com diversos sensores *Hall* distribuídos eqüidistantemente. A primeira arquitetura foi utilizada para detectar e classificar defeitos de acordo com padrões pré-determinados enquanto que a segunda foi utilizada para estimar as dimensões dos defeitos. A rede neural perceptron multicamadas foi utilizada nos dois casos. Com o primeiro dispositivo ela foi utilizada como um classificador de padrões enquanto que no segundo, como um interpolador de funções.

Na análise do primeiro sistema de identificação de defeitos, ou seja, no sistema classificador que utiliza o dispositivo sensor com fluxo disperso no ar, os resultados apresentados, embora encorajadores, não podem ser considerados conclusivos pois a quantidade de vetores para o treinamento da rede neural foi insuficiente. Para este sistema, foram gerados apenas 40 vetores de treinamento e somente 4 foram utilizados na validação cruzada. Na tabela 5.4, três novos defeitos foram classificados adequadamente mas nada pode ser dito sobre o comportamento da rede quando submetida a novos defeitos. Já a arquitetura em forma de U obteve excelentes resultados. Resultados, estes, significativos pois a quantidade de vetores para o treinamento e validação foram suficientes para a confiança nos resultados. Foram gerados 300 vetores, sendo que 75 foram utilizados no processo de validação cruzada e 225 utilizados no treinamento. Pode-se concluir, portanto, que a metodologia para a identificação de defeitos aqui analisada merece mais estudos pois os resultados da segunda arquitetura proposta foram encorajadores e confiáveis.

Em se tratando da aplicação prática desta metodologia, uma alteração no programa computacional que estão nos equipamentos comerciais tais como o

*MagneScan<sup>TM</sup>* e o *TranScan<sup>TM</sup>* ou similares possibilitaria uma utilização real desta técnica. É bom ressaltar que este trabalho é um estudo inicial e demanda maiores análises antes de uma aplicação prática.

O principal objetivo futuro é a construção de um protótipo que se utilize da metodologia aqui apresentada. Para isto, uma análise em três dimensões se faz necessária, objetivando fazer com que o modelo fique o mais próximo possível de uma situação real. Uma análise com cálculos de campos variáveis no tempo também se faz necessária para simular a translação do dispositivo nas paredes da tubulação. As simulações, também, devem levar em conta uma possível variação da distância entre o dispositivo sensor e a parede da tubulação metálica. Uma vez construído o protótipo poder-se-á verificar se a metodologia apresentada é eficiente ou não no processo de detecção de defeitos em tubulações metálicas.

## Capítulo 7

### Referências Bibliográficas

# Referências Bibliográficas

- [1] KATRAGADDA, G.; LORD, W.; SUN, Y.S.; UDPA, S.; UDPA, L. Alternative Magnetic Flux Leakage Modalities for Pipeline Inspection. **IEEE Transactions on Magnetics**, Vol. 32, No. 3 May 1996.
- [2] KATRAGADDA, G.; SI, J.T.; LORD, W.; SUN, Y.S.; UDPA, S.; UDPA, L. A Comparative Study of 3D and Axisymmetric Magnetizer Assemblies Used in magnetic Flux Leakage Inspection of Pipelines. **IEEE Transactions on Magnetics**, Vol. 32, No. 3, May 1996.
- [3] ALCANTARA JR., N. P DE ; CARVALHO, A. M. A Methodology Based on FEM and Artificial Neural Networks for Defects Identification in Metallic Tubes. **In: V INDUSCON - Conferência de Aplicações Industriais**, Salvador - Bahia, Anais Eletrônicos, 2002, p. 191-196.
- [4] ALCANTARA JR., N. P.; CARVALHO A. M. ; ULSON J. A. C. Investigations Into the Use of the Finite Element Method and Artificial Neural Networks in the Non-Destructive Analysis of Metallic Tubes. **In : IJCNN2002 - International Joint Conference on Neural Networks**, 2002, Honolulu/USA, Anais Eletrônicos, Honolulu:IEEE, 2002 p. 1450-1454.
- [5] ALCANTARA JR., N. P DE ; CARVALHO, A. M. ; ULSON, J. A. Defect Identification in Metallic Walls using ANN and FEM. **In: APPLIED INFORMATICS-International Symposium on Artificial Intelligence**

- and Applications**, 2002, Innsbruck/Áustria. Anais... Innsbruck: IASTED,2002 p. 68-72.
- [6] ZAOUI, F.; MARCHAND, C.; RAZEK, A. Localization and Shape Classification of Defects using the Finite Element Method and the Neural Networks. August, 1999, Vol. 4 No. 8. Disponível em < [http : //www.ndt.net](http://www.ndt.net) >. Acesso em 14 de Agosto de 2002.
- [7] FIORI, S.; BURRASCANO, P.; CARDELLI, E. A neural network approach to ECT data inversion for materials quality evaluation, **Neural Networks for Signal Processing XI**, 2001. Proceedings of the 2001 IEEE Signal Processing Society Workshop , 2001 Page(s): 519 -528.
- [8] BARCERINI, S.; CIPICCIA, L.; MAGGI, M.; FIORI, S.; BURRASCANO, P. Non-destructive test by the Hopfield network, *Neural Networks*, 2000. **IJCNN 2000, Proceedings of the IEEE-INNS-ENNS International Joint Conference on** , Volume: 6 , 2000 Page(s): 381 -386 vol.6.
- [9] LEE, H.; KIM, D. Numerical analysis of eddy current NDT for a tube with cracks using 3D indirect BIEM, **Magnetics, IEEE Transactions on** , Volume: 35 Issue: 5 Part: 2 , Sept. 1999 Page(s): 3724 -3726.
- [10] BOWLER, J., Eddy-Current Inversion for the Determination of Crack Geometry. **New Applications in Modelling and Inversion Techniques for Non-Destructive Testing, IEE Colloquium on**, 1999 Page(s): 8/1 -8/4 (Ref. No. 1999/020).
- [11] KRAUS, J.D. **Electromagnetics**, Fourth Edition. McGraw-Hill International Editions, 1992.
- [12] JIN, J. **The Finite Element Method in Electromagnetics**. John Wiley & Sons, Inc., 1993.

- [13] MEEKER, D. **Finite Element Method Magnetics User's Manual Version 3.1**, January 13, 2002. Disponível em < <http://femm.berlios.de> . Acesso em 14 de Agosto de 2002.
- [14] GOLUB, G.H.; LOAN, C.F.V. **Matrix Computations**. The Johns Hopkins University Press, 1989, Second Edition.
- [15] HAYKIN, S. **Neural Networks: A Comprehensive Foundation**, Second Edition. Prentice-Hall, Inc., 1999.
- [16] WIENER, N. **Cybernetics or Control and Communication in the Animal and the Machine**, MIT Press, 1948,1961.
- [17] HEBB, D.O. **The Organization of Behavior**, 1949, Wiley, New York.
- [18] ASHBY, W.R. **Design for a Brain**, 1952, New York, Wiley.
- [19] MINSKY, M.L. **Theory of neural-analog reinforcement systems and its application to the brain-model problem**, Ph.D. thesis, Princeton University, Princeton, NJ, 1954.
- [20] MINSKY, M.L.; PAPERT, S.A. **Perceptrons**, 1969, Cambridge, MA:MIT Press.
- [21] GOMES, N.R. **Algoritmo Seqüencial para Reconhecimento de Numerais Manuscritos Desconectados Utilizando Redes Neurais**. Dissertação de Mestrado - Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica, 1996.
- [22] CHEN, D.S.; JAIN, R.C. A Robust Back Propagation Learning Algorithm for Function Approximation, **Neural Networks, IEEE Transactions on** , Volume: 5 Issue: 3 , May 1994 Page(s): 467 -479.
- [23] SAAD, E.W.; PROKHOROV, D.V.; WUNSCH, D.C., II. Comparative Study of Stock Trend Prediction Using Time Delay, Recurrent and Probabilistic Neural Networks. **Neural Networks, IEEE Transactions on** , Volume: 9 Issue: 6 , Nov. 1998 Page(s): 1456 -1470.

- [24] MELO, H.M.; CAVALCANTI, J.H.F.; SILVA, J.F. e SILVA, V.P.R. Sistemas de Previsão Inteligente. **Proceedings of the IV Brazilian Conference on Neural Networks**, pp. 303-307, July 20-22, 1999 - ITA, São José dos Campos - SP - Brazil.
- [25] EBNER, TH.; MAGELE, CH.; BRANDSTATTER, B.R.; RICHTER, K.R. Utilizing Feed Forward Neural Networks for Acceleration of Global Optimization Procedures, **IEEE Transactions on Magnetics**, vol. 34, No. 5, September 1998.
- [26] FAROTIMI, O.; DEMBO, A.; KAITATH, T., A General Weigh Matrix Formulation Using Optimal Control, **IEEE Transactions on Neural Networks**. vol.2, no. 3, May 1991.
- [27] GONÇALVES, M. R., **Uma Arquitetura Neural Modular para Classificação de Imagens Multiespectrais de Sensoriamento Remoto**, Novembro de 1997, Dissertação apresentada à Universidade Estadual de Campinas, UNICAMP, para a obtenção do título de Mestre em Engenharia Elétrica.
- [28] CAMPANHA, J.R., **Determinação dos Parâmetros de Ordem de Redes Neurais pelo Método dos Cumulantes**, Julho de 1994, Tese apresentada à Faculdade de Engenharia Elétrica da Universidade Estadual de Campinas, UNICAMP, como parte dos requisitos para a obtenção do título de Doutor em Engenharia Elétrica.
- [29] PANDYA, A.S.; MACY, R.B., **Pattern Recognition with Neural Networks in C++**, 1996, CRC Press & IEEE Press.
- [30] BAZARRA, M.S.; SHERALI, H.D.; SHETTY, C.M. **Nonlinear Programming, Theory and Algorithms**, Second Edition, 1993, John Wiley & Sons, Inc.
- [31] ABID, S.; FNAIECH, F.; NAJIM, M., A Fast Feedforward Training Algorithm Using a Modified Form of the Standard Backpropagation Algorithm, **IEEE Transactions on Neural Networks**, Vol. 12, No. 2, March 2001.

- [32] HAGAN, M.T.; MENHAJ, M.B. Training Feedforward Networks with the Marquardt Algorithm. **IEEE Transactions on Neural Networks**, Vol. 5, No. 6, November 1994.
- [33] PARISI, F.; CLAUDIO, E. D. D.; ORLANDI, G., Rao; BHASKAR, D. A Generalized Learning Paradigm Exploiting the Structure of Feedforward Neural Networks, **IEEE Transactions on Neural Networks**, Vol. 7, No. 6, November 1996.
- [34] WILAMOWSKI, B.M.; IPLIKCI, S.; KAYNAK, O.; EFE, M.O. An Algorithm for Fast Convergence in Training Neural Networks, **Neural Networks, 2001. Proceedings. IJCNN '01. International Joint Conference on** , Volume: 3 , 2001 Page(s): 1778 -1782 vol.3.
- [35] DUDA, R.O.; HART, P.E.; STORK, D.G. **Pattern Classification**, Second Edition, Wiley, 2001.

# Apêndice A

## Descrição do Sistema Computacional FEMM

Este programa é distribuído gratuitamente, incluindo o seu código fonte e pode ser encontrado em ; <http://femm.berlios.de> ;. É muito versátil e de fácil utilização e também, muito poderoso para aplicações em duas dimensões, pois não há limitação no número de nós da geometria analisada. As principais características deste programa são:

1. Utiliza formulação variacional de problemas de campos eletromagnéticos resolvidos pelo método dos elementos finitos [13] [12];
2. Discretiza o domínio com elementos triangulares de primeira ordem [13] [12];
3. O algoritmo de triangulação é o de Delaunay [13] com possibilidade de refinamento da malha em regiões onde isto se faz necessário;
4. A função de aproximação é de primeira ordem, ou seja, linear [12] [13];
5. Utiliza os métodos do Conjugado-Gradiente [14] [13] e Newton-Rapson para a

solução dos sistemas de equações algébricas resultantes da formulação por elementos finitos.

Sistemas computacionais, destinados a análises eletromagnéticas através do Método dos Elementos Finitos, são compostos por três blocos básicos: pré-processamento, processamento e o pós-processamento. O primeiro é responsável pela modelagem geométrica, caracterização de materiais e fontes de corrente, bem como pela discretização do problema. O segundo executa os cálculos necessários para a solução dos sistemas de equações e o terceiro permite a visualização e exploração dos resultados. Abaixo, tem-se uma descrição de cada etapa.

## A.1 O Pré-Processador

Nesta fase, deve-se desenhar a geometria a ser estudada, definir o tipo de material que constitui o dispositivo analisado, informar suas características elétricas, discretizar o domínio e informar as condições de contorno do problema.

Na figura A.1 tem-se o desenho da parede de um tubo metálico preparado para representar até 10 defeitos diferentes. O modelo da bobina de corrente também está representado neste desenho.

A figura A.2 mostra a geometria discretizada com elementos triangulares de primeira ordem [13]. A figura A.3 mostra uma lista com materiais disponíveis. O programa também possibilita que as características tanto elétricas quanto magnéticas de um dado material sejam alteradas, bem como permite a inclusão de novos materiais como mostram as figuras A.4 e A.5.

A figura A.6 mostra a janela para a edição da curva de magnetização de um material magnético caso isto seja necessário.

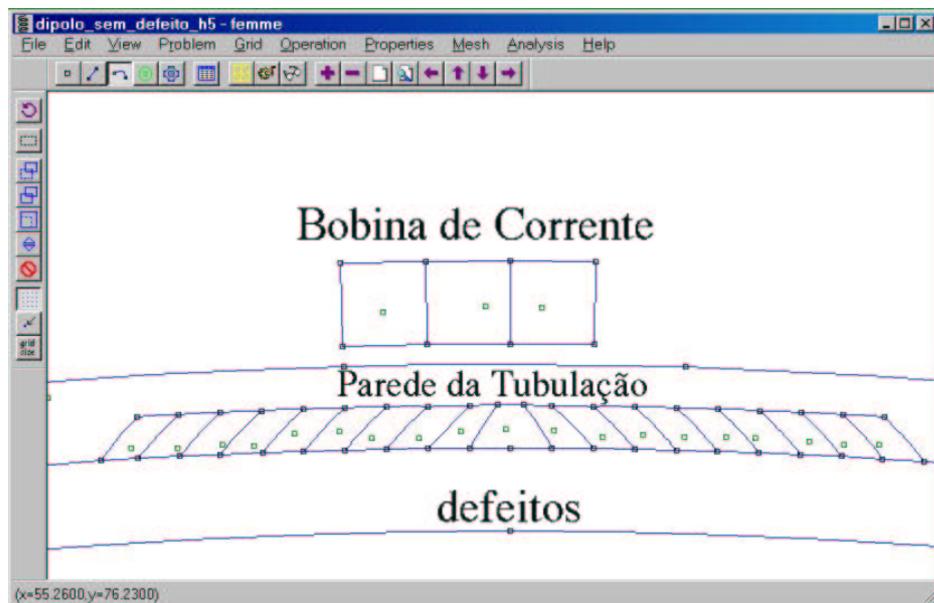


Figura A.1: Pré-processador - Desenho da Geometria.

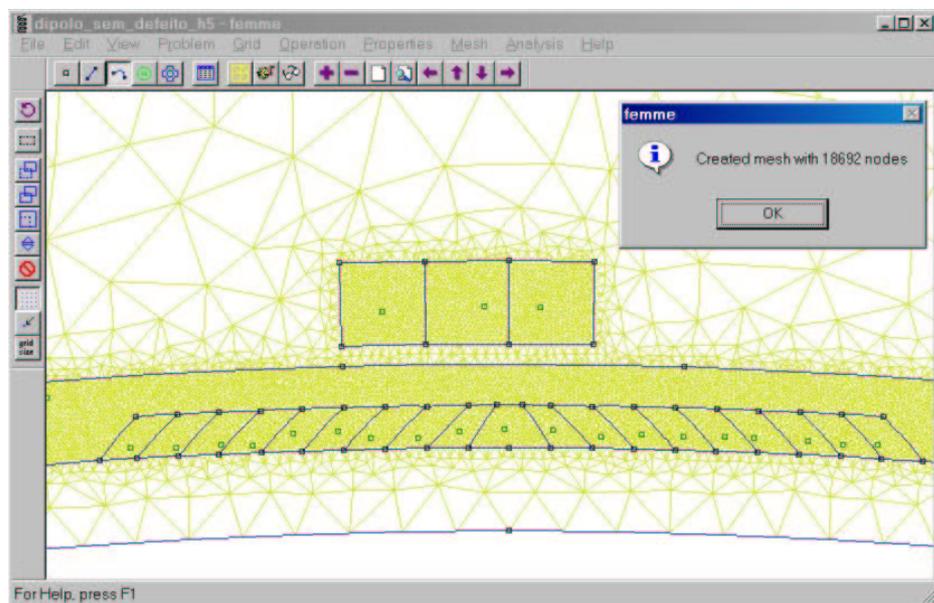


Figura A.2: Pré-processador - Discretização da Geometria em Elementos Triangulares de Primeira Ordem.

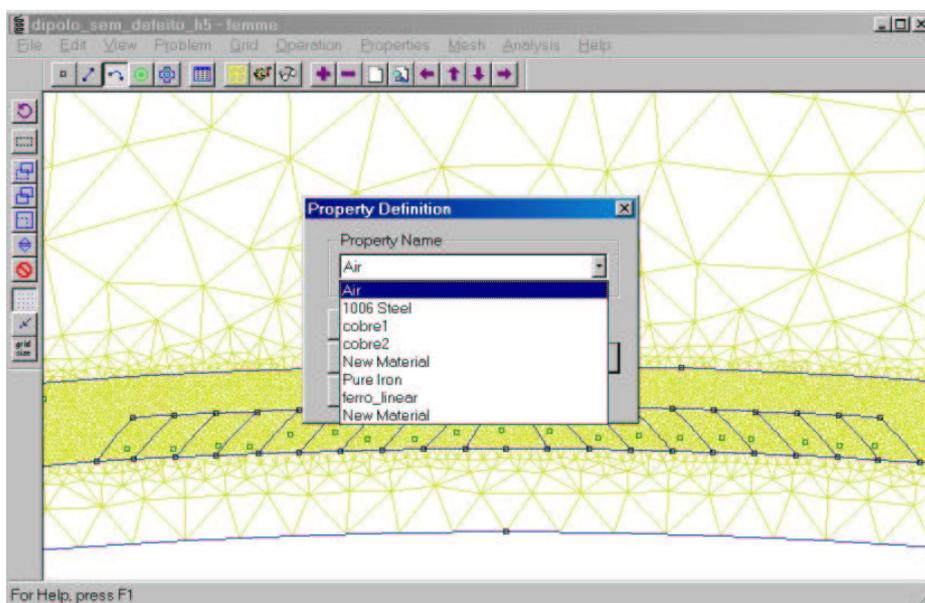


Figura A.3: Pré-processador - Materiais Disponíveis

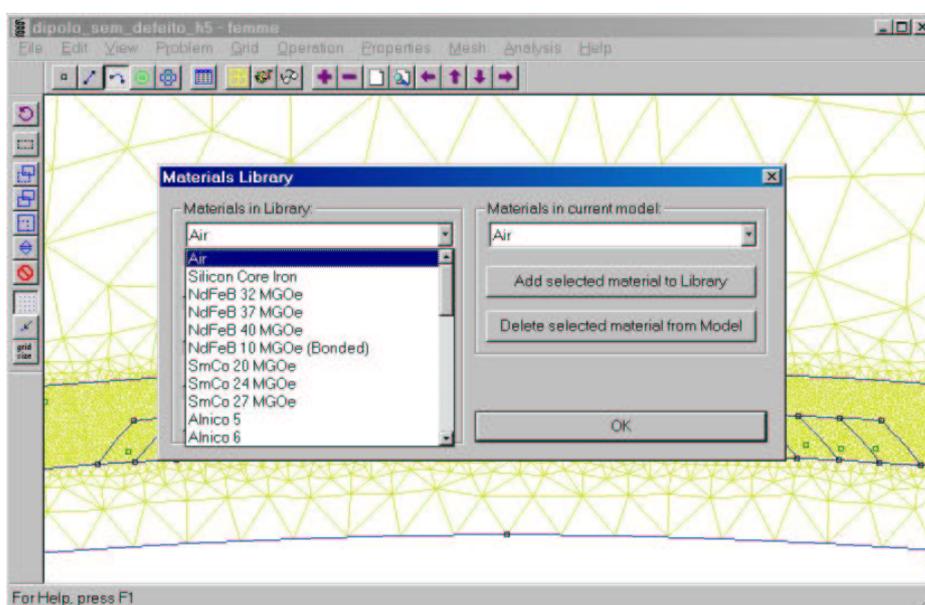


Figura A.4: Pré-processador - Biblioteca de Materiais

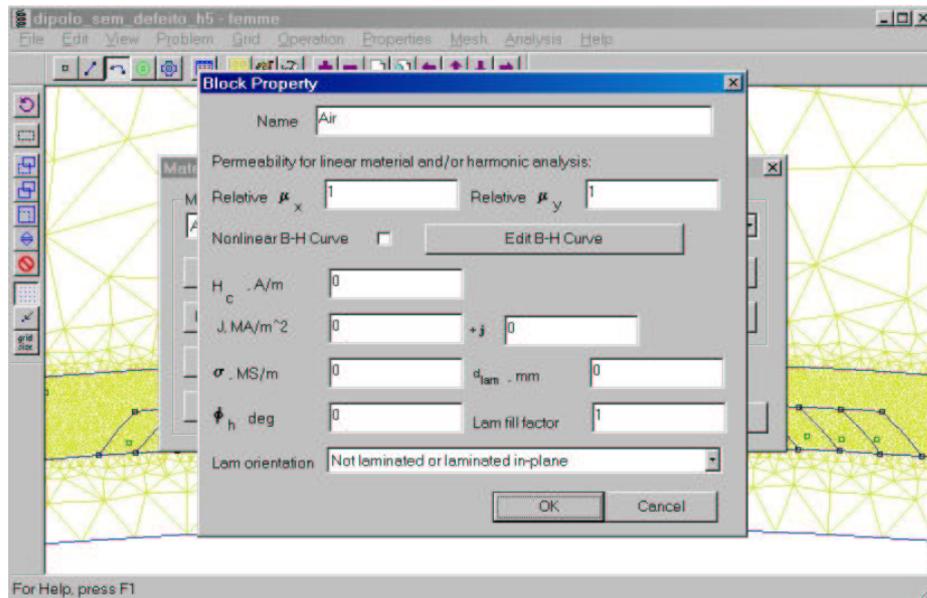


Figura A.5: Pré-processador - Edição das Características de um Dado Material

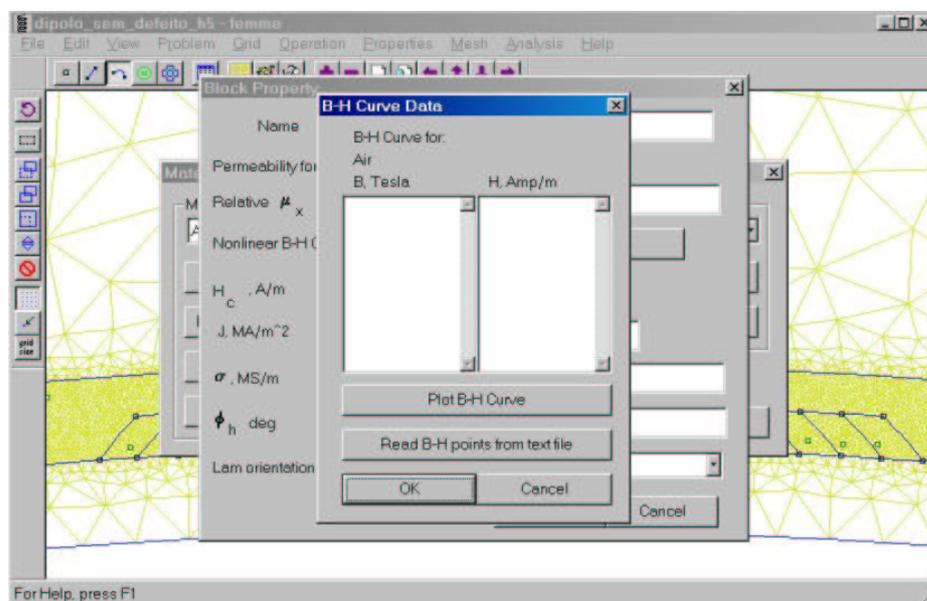


Figura A.6: Pré-processador - Edição da Curva B-H de um Determinado Material

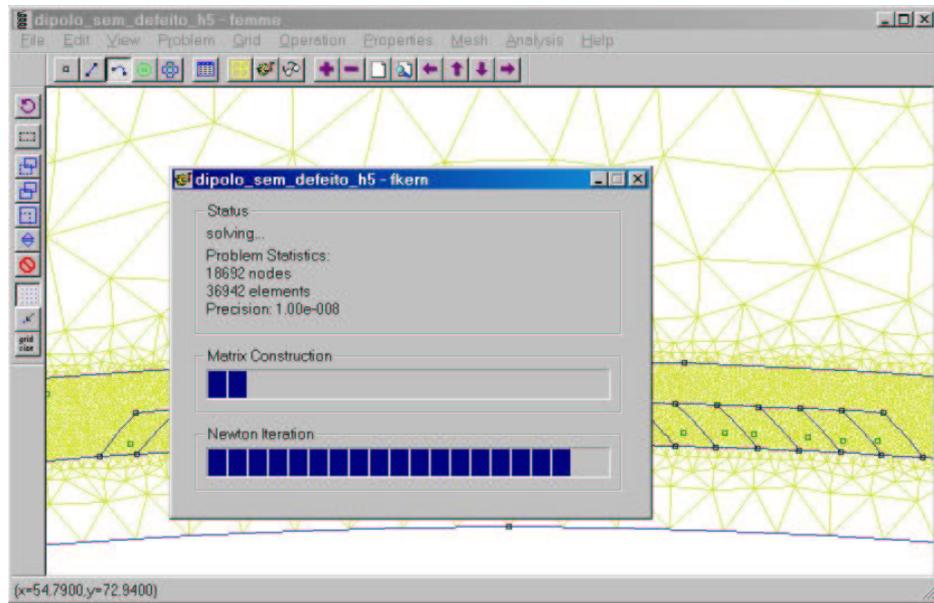


Figura A.7: Processador - Utilização do Método de Newton

## A.2 O Processador

Nesta fase, a geometria já está totalmente configurada, os materiais já foram definidos, as condições de contorno impostas e a discretização realizada [13]. O sistema de equações é gerado e resolvido pelos métodos numéricos citados anteriormente. As figuras A.7 e A.8 apresentam as janelas que permitem acompanhar visualmente o progresso da solução do sistema de equações. Em alguns casos, é possível que a solução do sistema de equações não convirja pois a mesma é iterativa. Através da visualização destas janelas, o usuário poderá perceber isto e interromper a execução do programa, gerando uma nova discretização, na tentativa de se obter uma solução. Durante a execução deste trabalho, este fato ocorreu em situações muito raras.

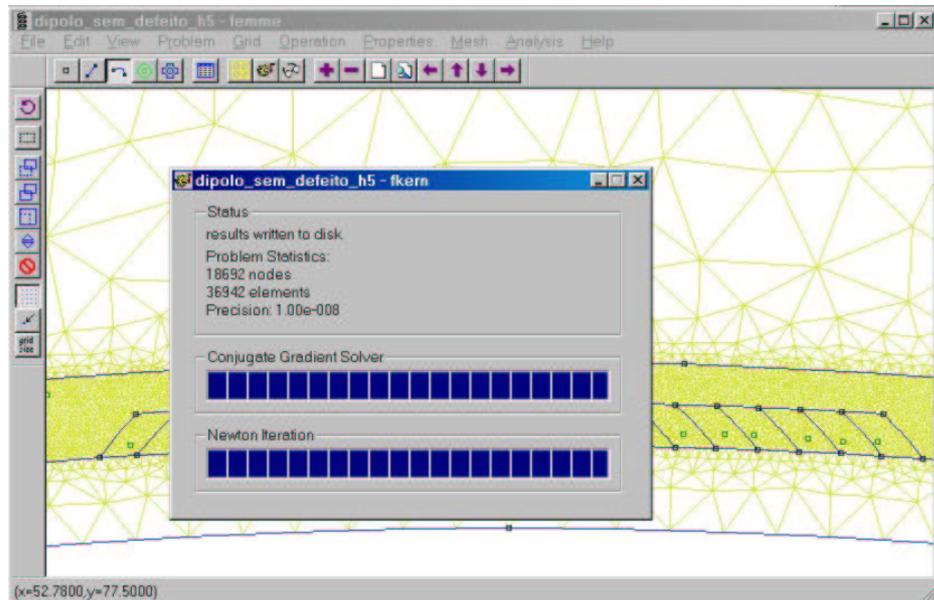


Figura A.8: Processador - Utilização do Método do Conjugado-Gradiente

### A.3 O Pós-Processador

No Pós-processamento os resultados podem ser visualizados através de gráfico de cores ( figura A.9 ) e gráfico de linhas ( figura A.10 ). Pode-se verificar, também, valores pontuais das grandezas de interesse, assim como elaborar gráficos tal como mostrado na figura A.11. Também é possível gravar resultados numéricos em arquivos do tipo texto durante a fase de pós-processamento. Isto foi muito utilizado durante a execução deste trabalho.

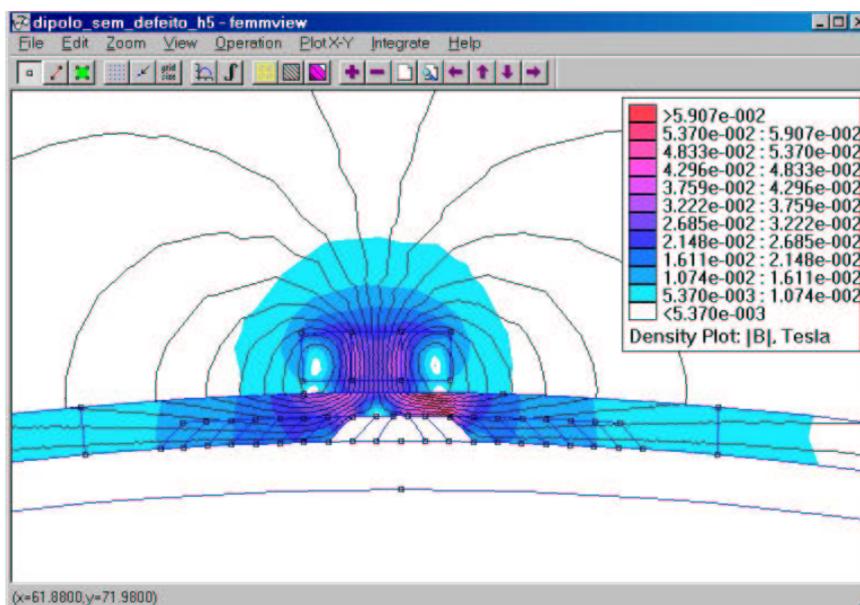


Figura A.9: Pós-Processador - Gráfico de Cores

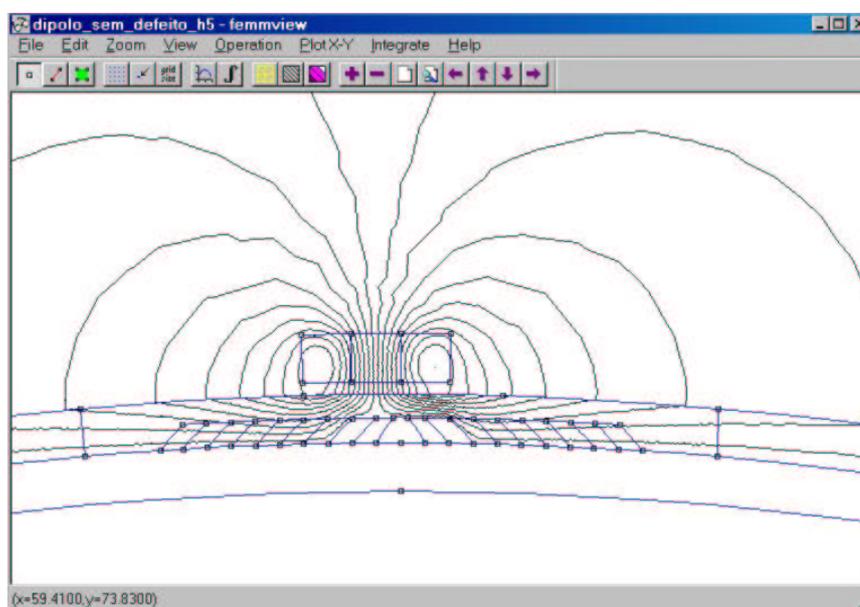


Figura A.10: Pós-Processador - Gráfico de Linhas

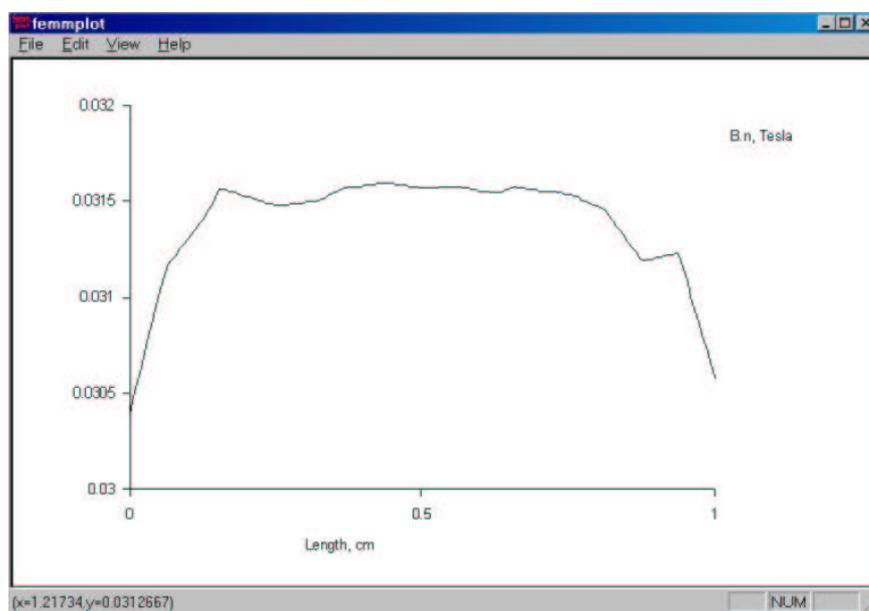


Figura A.11: Pós-Processador - Gráfico do valor do campo magnético normal à superfície da parede metálica sem defeito. Valor medido no centro da bobina de corrente.