



Antonio Cesar de Oliveira Pitta Botelho

**Modelo Inteligente para Otimização da
Sensibilidade de Amostras GMI**

Dissertação de Mestrado

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da PUC-Rio como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica.

Orientadora: Profa. Marley M. B. R. Vellasco
Co-orientador: Prof. Carlos Roberto Hall Barbosa

Rio de Janeiro

Abril de 2014



Antonio Cesar de Oliveira Pitta Botelho

**Modelo Inteligente para Otimização da Sensibilidade
de Amostras GMI**

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Engenharia Elétrica do Departamento de Engenharia Elétrica do Centro Técnico Científico da PUC-Rio. Aprovada pela Comissão Examinadora abaixo assinada.

Profa. Marley Maria Bernades Rebuszi Vellasco
Orientador
Departamento de Engenharia Elétrica – PUC-Rio

Prof. Carlos Roberto Hall Barbosa
Co-Orientador
Programa de Pós-Graduação em Metrologia – PUC-Rio

Profa. Elisabeth Costa Monteiro
Programa de Pós-Graduação em Metrologia – PUC-Rio

Prof. Eduardo Costa da Silva
Departamento de Engenharia Elétrica – PUC-Rio

Prof. José Franco Machado do Amaral
UERJ

Prof. José Eugenio Leal
Coordenador Setorial do Centro
Técnico Científico

Rio de Janeiro, 15 de abril de 2014

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, do autor e da orientadora.

Antonio Cesar de Oliveira Pitta Botelho

Graduado em Engenharia Elétrica (ênfase em Eletrônica) pela Universidade Federal do Rio de Janeiro. Pós-graduado em Petróleo e Gás pela COPPE/UFRJ e em Sistemas Inteligentes de Apoio à Decisão em Negócios pela Pontifícia Universidade Católica do Rio de Janeiro.

Ficha Catalográfica

Botelho, Antonio Cesar de Oliveira Pitta

Modelo inteligente para otimização da sensibilidade de Amostras GMI / Antonio Cesar de Oliveira Pitta Botelho; orientador: Marley Maria Bernardes Rebuszi Vellasco, co-orientador: Carlos Roberto Hall Barbosa. – 2014.

168 f. ; 30 cm

Dissertação (mestrado) – Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Elétrica, 2014.

Inclui bibliografia

1. Engenharia elétrica – Teses. 2. Algoritmos genéticos. 3. Redes neurais artificiais. 4. Perceptron multicamadas. 5. Sensor magnético. 6. Magnetoimpedância gigante. 7. Fase da impedância. I. Vellasco, Marley Maria Bernardes Rebuszi. II. Barbosa, Carlos Roberto Hall. III. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Elétrica. IV. Título.

CDD: 621.3

À minha querida avó, Maria Cândida, que me ensinou o verdadeiro valor do conhecimento e sem seu incentivo e apoio não teria sido possível chegar até aqui.

À minha mãe, Sônia, presença constante em minha vida.

À minha esposa, Adlucy, que, com muito amor, sempre me incentivou a superar os desafios.

Agradecimentos

À minha avó, Maria Cândida, pelo amor, incentivo e apoio constante, fundamentais para o meu crescimento pessoal e profissional.

À minha mãe, Sônia, que sempre acreditou em mim.

À minha esposa, Adlucy, pelo amor a mim dedicado e pelo incentivo nas horas difíceis.

À minha orientadora, professora Marley Vellasco, e ao coorientador, professor Carlos Hall, por toda a ajuda na elaboração deste trabalho. Expresso aqui minha admiração, gratidão e respeito.

Aos professores Eduardo Costa, Elisabeth Monteiro e José Franco por terem aceitado o convite para participar da banca e pelas sugestões e contribuições dadas em suas avaliações.

Resumo

Botelho, Antonio Cesar de Oliveira Pitta; Vellasco, Marley Maria Bernardez Rebuszi (Orientadora); Barbosa, Carlos Roberto Hall (Co-orientador). **Modelo Inteligente para Otimização da Sensibilidade de Amostras GMI**. Rio de Janeiro, 2014. 168p. Dissertação de Mestrado - Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

Sensores capazes de detectar campos magnéticos são largamente aplicados nas mais variadas áreas da engenharia. Um magnetômetro é um dispositivo que, baseado na utilização de um sensor magnético, é capaz de medir a magnitude e/ou direção de um campo magnético. Magnetômetros GMI são transdutores magnéticos cujos elementos sensores se baseiam no efeito da Magnetoimpedância Gigante (Giant Magnetoimpedance - GMI) que se caracteriza pela grande variação da impedância (módulo e fase) de uma amostra de material ferromagnético quando submetida a um campo magnético externo. A sensibilidade dos transdutores magnéticos está diretamente associada à sensibilidade de seus elementos sensores. No caso de amostras GMI, a sensibilidade é afetada por diversos parâmetros, e essa dependência ainda não é bem modelada quantitativamente. Esta dissertação apresenta um modelo computacional baseado em Redes Neurais MLP e em Algoritmos Genéticos que determina a sensibilidade ótima da fase da impedância do efeito GMI em função do campo magnético externo, para ligas ferromagnéticas amorfas de composição $\text{Co}_{70}\text{Fe}_5\text{Si}_{15}\text{B}_{10}$, a partir dos seguintes parâmetros que as afetam: comprimento das amostras, nível CC e frequência da corrente de excitação além do campo magnético externo.

Palavras-chave

Algoritmos Genéticos; Redes Neurais Artificiais; Perceptron Multicamadas; Sensor Magnético; Magnetoimpedância Gigante; Fase da Impedância.

Abstract

Botelho, Antonio Cesar de Oliveira Pitta; Vellasco, Marley Maria Bernardes Rebuzzi (Advisor); Barbosa, Carlos Roberto Hall (Co-advisor). **Intelligent Optimization Model for Sensitivity of GMI Samples**. Rio de Janeiro, 2014. 168p. MSc. Dissertation - Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

Sensors capable of detecting magnetic fields are widely applied in many areas of engineering. A magnetometer is a device that based on the use of a magnetic sensor is capable of measuring the magnitude and direction of a magnetic field. Magnetometers GMI are magnetic transducers which sensors elements are based on the Giant Magnetoimpedance effect (Giant Magnetoimpedance - GMI) that is characterized by large variation of the impedance (magnitude and phase) of a sample of ferromagnetic material when subjected to an external magnetic field. The magnetic transducers sensitivity is directly affected by the sensitivity of its sensor elements. In the case of GMI samples, the sensitivity is affected by several parameters, and this dependence is not well modeled quantitatively. This dissertation presents a computational model based on feedforward Multilayer Perceptron Neural Networks and Genetic Algorithms that determines the optimal impedance phase sensitivity of the GMI effect, as functions of the magnetic field, for $\text{Co}_{70}\text{Fe}_5\text{Si}_{15}\text{B}_{10}$ ferromagnetic amorphous alloys, The proposed model is based on some of the main parameters that affect it: length of the samples, DC level and frequency of the excitation current and the external magnetic field.

Keywords

Genetic Algorithms; Artificial Neural Networks; Perceptron Multilayers; Magnetic Sensor; Giant Magnetoimpedance; Impedance Phase.

Sumário

1	Introdução	24
1.1.	Motivação	27
1.2.	Magnetismo	29
1.2.1.	Grandezas Magnéticas	31
1.2.2.	Materiais Magnéticos Amorfos	33
1.2.3.	Técnica de Fabricação <i>Melt Spinning</i>	35
1.3.	Magnetoimpedância Gigante (GMI)	37
1.3.1.	Contexto Histórico	37
1.3.2.	Efeito GMI por Regime de Frequências	40
1.3.3.	Geometria da GMI	41
1.3.4.	Magnetoimpedância Longitudinal	42
1.3.5.	GMI Assimétrica	44
1.3.6.	Caracterização de Amostras GMI	45
1.4.	Estruturação	46
2	Inteligência Computacional	47
2.1.	Redes Neurais Artificiais	47
2.1.1.	Funções de Ativação	48
2.1.2.	Arquitetura de Rede	50
2.1.3.	Tipos de Aprendizado	52
2.1.4.	Redes Multilayer Perceptron (MLP)	53
2.1.4.1.	Treinamento	54
2.2.	Algoritmos Genéticos	55
2.2.1.	Representações das Soluções	56
2.2.2.	Decodificação do Cromossoma	56
2.2.3.	Avaliação	56
2.2.4.	Seleção	56
2.2.5.	Reprodução	57
2.2.6.	Operadores Genéticos	58
2.2.7.	População Inicial	60
2.2.8.	Parâmetros e Critérios de Parada	61
3	Modelo Computacional para Otimização da Sensibilidade de Amostras GMI	62
3.1.	Dados Experimentais	62
3.2.	Desenvolvimento das Redes Neurais	84
3.2.1.	Normalização	84
3.2.2.	Topologia	87
3.3.	Cálculo da Sensibilidade de Fase	91
3.3.1.	Diferenciação por Diferenças Centrais	91
3.4.	Desenvolvimento do Algoritmo Genético	92
4	Resultados e Análises	95
4.1.	Resultados das Redes Neurais MLP	95
4.1.1.	Redes MLP Específicas por Comprimento de Amostra	95
4.1.2.	Rede MLP Única	119
4.3.	Resultados da Derivação das Redes Neurais MLP	131

4.4. Resultados do Algoritmo Genético	138
5 Conclusões e Trabalhos Futuros	158
Referências bibliográficas	161

Lista de Figuras

Figura 1.1 – Magnetismo atômico. (a) Momento magnético global nulo. (b) Momento magnético global não nulo. Adaptado de (Filardo, 200-).	30
Figura 1.2 – (a) Domínios magnéticos desalinhados (campo magnético total em qualquer direção é nulo) (b) Domínios magnéticos alinhados (sob a ação de um campo magnético externo). Adaptado de (Araújo, 2009).	31
Figura 1.3 – Representação esquemática do processo de <i>melt spinning</i> .	36
Figura 1.4 – Equipamento utilizado, na UFPE, para produção de amostras GMI (Costa Silva, 2010).	36
Figura 1.5 – Detalhes do interior do equipamento apresentado na Figura 1.4 (Costa Silva, 2010).	37
Figura 1.6 – Configurações da Geometria da GMI. (a) Longitudinal. (b) Perpendicular. (c) Transversal.	42
Figura 1.7 – Desenho esquemático de uma amostra em forma de fita, sendo submetida à passagem de uma corrente elétrica alternada e na presença de um campo magnético (Cavalcanti, 2005).	42
Figura 1.8 – Curvas típicas da variação de $ Z \times H$ para uma fita de $(\text{Fe}_{0.053}\text{Co}_{0.947})_{70}\text{Si}_{12}\text{B}_{18}$, na faixa de frequência de 900 kHz, com corrente aplicada de 5 mA (a) antes de sofrer tratamento térmico (sem <i>annealing</i>) e (b) depois de passar por tratamento térmico (com <i>annealing</i>). Adaptado de (Cavalcanti, 2005).	44
Figura 2.1 – Modelo de um neurônio artificial (Haykin, 2001).	47
Figura 2.2 – Funções de ativação: (a) função linear. (b) função degrau. (c) função sigmoide e (d) tangente hiperbólica (Lorena, 2004).	50
Figura 2.3 – Rede <i>feedforward</i> totalmente conectada com uma camada oculta e uma camada de saída (Haykin, 2001).	51
Figura 2.4 – Rede recorrente com neurônios ocultos (Haykin, 2001).	51
Figura 2.5 – Rede MLP com uma camada escondida.	53
Figura 2.6 – <i>Crossover</i> de um ponto de corte (Cardoso, 1998).	58
Figura 2.7 – <i>Crossover</i> multi-ponto (Cardoso, 1998).	59
Figura 2.8 – <i>Crossover</i> multi-ponto (Cardoso, 1998).	59

Figura 2.9 – Processo de mutação em um cromossoma (Cardoso, 1998).	60
Figura 3.1 – Diagrama de blocos do sistema utilizado na obtenção dos dados experimentais (Costa Silva, 2010).	64
Figura 3.2 – Bobina de Helmholtz com a fita GMI posicionada em seu centro (Costa Silva, 2010).	65
Figura 3.3 – Histograma do nível CC da corrente de condicionamento (comprimento de fita 1 cm).	66
Figura 3.4 – Histograma da frequência da corrente de condicionamento (comprimento de fita 1 cm).	67
Figura 3.5 – Histograma do campo magnético externo (comprimento de fita 1 cm).	67
Figura 3.6 – Histograma do nível CC da corrente de condicionamento (comprimento de fita 3 cm).	68
Figura 3.7 – Histograma da frequência da corrente de condicionamento (comprimento de fita 3 cm).	69
Figura 3.8 – Histograma do campo magnético externo (comprimento de fita 3 cm).	69
Figura 3.9 – Histograma do nível CC da corrente de condicionamento (comprimento de fita 5 cm).	70
Figura 3.10 – Histograma da frequência da corrente de condicionamento (comprimento de fita 5 cm).	71
Figura 3.11 – Histograma do campo magnético externo (comprimento de fita 5 cm).	71
Figura 3.12 – Histograma do nível CC da corrente de condicionamento (comprimento de fita 15 cm).	72
Figura 3.13 – Histograma da frequência da corrente de condicionamento (comprimento de fita 15 cm).	73
Figura 3.14 – Histograma do campo magnético externo (comprimento de fita 15 cm).	73
Figura 3.15 – Histograma do nível CC da corrente de condicionamento.	74
Figura 3.16 – Histograma da frequência da corrente de condicionamento.	74
Figura 3.17 – Histograma do campo magnético externo.	75

Figura 3.18 – Curva de Histerese (Costa Silva, 2010).	76
Figura 3.19 – Fase da impedância em função do campo magnético externo para uma fita GMI de comprimento 1 cm submetida a uma corrente de nível CC de 80 mA e frequência de 500 kHz.	77
Figura 3.20 – Fase da impedância em função do campo magnético externo para uma fita GMI de comprimento 1 cm submetida a uma corrente de nível CC de 40 mA e frequência de 100 kHz.	77
Figura 3.21 – Fase da impedância em função do campo magnético externo para uma fita GMI de comprimento 3 cm submetida a uma corrente de nível CC de 80 mA e frequência de 300 kHz.	78
Figura 3.22 – Fase da impedância em função do campo magnético externo para uma fita GMI de comprimento 3 cm submetida a uma corrente de nível CC de 40 mA e frequência de 2 MHz.	78
Figura 3.23 – Fase da impedância em função do campo magnético externo para uma fita GMI de comprimento 5 cm submetida a uma corrente de nível CC de 80 mA e frequência de 3,5 MHz.	79
Figura 3.24 – Fase da impedância em função do campo magnético externo para uma fita GMI de comprimento 5 cm submetida a uma corrente de nível CC de 50 mA e frequência de 99 kHz.	80
Figura 3.25 – Fase da impedância em função do campo magnético externo para uma fita GMI de comprimento 15 cm submetida a uma corrente de nível CC de 100 mA e frequência de 10 MHz.	80
Figura 3.26 – Fase da impedância em função do campo magnético externo para uma fita GMI de comprimento 15 cm submetida a uma corrente de nível CC de 0 mA e frequência de 500 kHz.	81
Figura 3.27 – Representação do modelo computacional baseado em quatro redes neurais MLP.	82
Figura 3.28 – Representação das redes neurais MLP utilizadas para modelar o comportamento da fase da impedância de amostras GMI, em forma de fita, de comprimentos 1 cm, 3 cm, 5 cm e 15 cm.	83
Figura 3.29 – Representação do modelo computacional baseado em uma única rede neural MLP.	83
Figura 3.30 – Representação da rede neural MLP utilizada para modelar o comportamento da fase da impedância de amostras GMI em forma de fita.	84

- Figura 4.1 – Comparativo entre a saída (fase da impedância) da rede MLP, com uma camada escondida, e os dados experimentais (alvos) do conjunto de validação (amostras de comprimento 1 cm). 97
- Figura 4.2 – Comparativo entre a saída (fase da impedância) da rede MLP, com uma camada escondida, e os dados experimentais (alvos) do conjunto de teste (amostras de comprimento 1 cm). 97
- Figura 4.3 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida, para uma fita GMI de 1 cm submetida a uma corrente de nível CC de 80 mA e frequência de 500 kHz. 98
- Figura 4.4 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida, para uma fita GMI de 1 cm submetida a uma corrente de nível CC de 40 mA e frequência de 100 kHz. 99
- Figura 4.5 – Comparativo entre a saída (fase da impedância) da rede MLP, com uma camada escondida, e os dados experimentais (alvos) do conjunto de validação (amostras de comprimento 3 cm). 99
- Figura 4.6 – Comparativo entre a saída (fase da impedância) da rede MLP, com uma camada escondida, e os dados experimentais (alvos) do conjunto de teste (amostras de comprimento 3 cm). 100
- Figura 4.7 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida, para uma fita GMI de 3 cm submetida a uma corrente de nível CC de 80 mA e frequência de 300 kHz. 101
- Figura 4.8 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida, para uma fita GMI de 3 cm submetida a uma corrente de nível CC de 40 mA e frequência de 2 MHz. 101
- Figura 4.9 – Comparativo entre a saída (fase da impedância) da rede MLP, com uma camada escondida, e os dados experimentais (alvos) do conjunto de validação (amostras de comprimento 5 cm). 102
- Figura 4.10 – Comparativo entre a saída (fase da impedância) da rede MLP, com uma camada escondida, e os dados experimentais (alvos) do conjunto de teste (amostras de comprimento 5 cm). 102

- Figura 4.11 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida, para uma fita GMI de 5 cm submetida a uma corrente de nível CC de 80 mA e frequência de 3,5 MHz. 103
- Figura 4.12 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida, para uma fita GMI de 5 cm submetida a uma corrente de nível CC de 50 mA e frequência de 99 kHz. 104
- Figura 4.13 – Comparativo entre a saída (fase da impedância) da rede MLP, com uma camada escondida, e os dados experimentais (alvos) do conjunto de validação (amostras de comprimento 15 cm). 104
- Figura 4.14 – Comparativo entre a saída (fase da impedância) da rede MLP, com uma camada escondida, e os dados experimentais (alvos) do conjunto de teste (amostras de comprimento 15 cm). 105
- Figura 4.15 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida, para uma fita GMI de 15 cm submetida a uma corrente de nível CC de 100 mA e frequência de 10 MHz. 106
- Figura 4.16 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida, para uma fita GMI de 15 cm submetida a uma corrente de nível CC de 0 mA e frequência de 500 kHz. 106
- Figura 4.17 – Comparativo entre a saída (fase da impedância) da rede MLP com duas camadas escondidas e os dados experimentais (alvos) do conjunto de validação (amostras de comprimento 1 cm). 108
- Figura 4.18 – Comparativo entre a saída (fase da impedância) da rede MLP com duas camadas escondidas e os dados experimentais (alvos) do conjunto de teste (amostras de comprimento 1 cm). 108
- Figura 4.19 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas, para uma fita GMI de 1 cm submetida a uma corrente de nível CC de 80 mA e frequência de 500 kHz. 109

- Figura 4.20 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas, para uma fita GMI de 1 cm submetida a uma corrente de nível CC 40 mA e frequência de 100 kHz. 110
- Figura 4.21 – Comparativo entre a saída (fase da impedância) da rede MLP com duas camadas escondidas e os dados experimentais (alvos) do conjunto de validação (amostras de comprimento 3 cm). 110
- Figura 4.22 – Comparativo entre a saída (fase da impedância) da rede MLP com duas camadas escondidas e os dados experimentais (alvos) do conjunto de teste (amostras de comprimento 3 cm). 111
- Figura 4.23 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas, para uma fita GMI de 3 cm submetida a uma corrente de nível CC de 80 mA e frequência de 300 kHz. 112
- Figura 4.24 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas, para uma fita GMI de 3 cm submetida a uma corrente de nível CC de 40 mA e frequência de 2 MHz. 112
- Figura 4.25 – Comparativo entre a saída (fase da impedância) da rede MLP com duas camadas escondidas e os dados experimentais (alvos) do conjunto de validação (amostras de comprimento 5 cm). 113
- Figura 4.26 – Comparativo entre a saída (fase da impedância) da rede MLP com duas camadas escondidas e os dados experimentais (alvos) do conjunto de teste (amostras de comprimento 5 cm). 113
- Figura 4.27 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas, para uma fita GMI de 5 cm submetida a uma corrente de nível CC de 80 mA e frequência de 3,5 MHz. 115
- Figura 4.28 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas, para uma fita GMI de 5 cm submetida a uma corrente de nível CC de 50 mA e frequência de 99 kHz. 115
- Figura 4.29 – Comparativo entre a saída (fase da impedância) da rede MLP com duas camadas escondidas e os dados experimentais (alvos) do conjunto de validação (amostras de comprimento 15 cm). 116

- Figura 4.30 – Comparativo entre a saída (fase da impedância) da rede MLP com duas camadas escondidas e os dados experimentais (alvos) do conjunto de teste (amostras de comprimento 15 cm). 116
- Figura 4.31 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas, para uma fita GMI de 15 cm submetida a uma corrente de nível CC de 100 mA e frequência de 10 MHz. 117
- Figura 4.32 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas, para uma fita GMI de 15 cm submetida a uma corrente de nível CC de 0 mA e frequência de 500 kHz. 118
- Figura 4.33 – Comparativo entre a saída (fase da impedância) da rede MLP, com uma camada escondida (rede MLP única), e os dados experimentais (alvos) do conjunto de validação. 120
- Figura 4.34 – Comparativo entre a saída (fase da impedância) da rede MLP, com uma camada escondida (rede MLP única), e os dados experimentais (alvos) do conjunto de teste. 121
- Figura 4.35 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida (rede MLP única), para uma fita GMI de comprimento 1 cm submetida a uma corrente de nível CC de 80 mA e frequência de 500 kHz. 121
- Figura 4.36 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP com uma camada escondida (rede MLP única), para uma fita GMI de comprimento 1 cm submetida a uma corrente de nível CC de 40 mA e frequência de 100 kHz. 122
- Figura 4.37 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida (rede MLP única), para uma fita GMI de comprimento 3 cm submetida a uma corrente de nível CC de 80 mA e frequência de 300 kHz. 122
- Figura 4.38 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida (rede MLP única), para uma fita GMI de comprimento 3 cm submetida a uma corrente de nível CC de 40 mA e frequência de 2 MHz. 123

- Figura 4.39 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida (rede MLP única), para uma fita GMI de comprimento 5 cm submetida a uma corrente de nível CC de 80 mA e frequência de 3,5 MHz. 123
- Figura 4.40 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida (rede MLP única), para uma fita GMI de comprimento 5 cm submetida a uma corrente de nível CC de 50 mA e frequência de 99 kHz. 124
- Figura 4.41 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida (rede MLP única), para uma fita GMI de comprimento 15 cm submetida a uma corrente de nível CC de 100 mA e frequência de 10 MHz. 124
- Figura 4.42 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida (rede MLP única), para uma fita GMI de comprimento 15 cm submetida a uma corrente de nível CC de 0 mA e frequência de 500 kHz. 125
- Figura 4.43 – Comparativo entre a saída (fase da impedância) da rede MLP, com duas camadas escondidas (rede MLP única), e os dados experimentais (alvos) do conjunto de validação. 126
- Figura 4.44 – Comparativo entre a saída (fase da impedância) da rede MLP, com duas camadas escondidas (rede MLP única), e os dados experimentais (alvos) do conjunto de teste. 127
- Figura 4.45 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas (rede MLP única), para uma fita GMI de comprimento 1 cm submetida a uma corrente de nível CC de 80 mA e frequência de 500 kHz. 127
- Figura 4.46 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas (rede MLP única), para uma fita GMI de comprimento 1 cm submetida a uma corrente de nível CC de 40 mA e frequência de 100 kHz. 128
- Figura 4.47 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas (rede MLP única), para uma fita GMI de comprimento 3 cm submetida a uma corrente de nível CC de 80 mA e frequência de 300 kHz. 128

- Figura 4.48 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas (rede MLP única), para uma fita GMI de comprimento 3 cm submetida a uma corrente de nível CC de 40 mA e frequência de 2 MHz. 129
- Figura 4.49 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas (rede MLP única), para uma fita GMI de comprimento 5 cm submetida a uma corrente de nível CC de 80 mA e frequência de 3,5 MHz. 129
- Figura 4.50 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas (rede MLP única), para uma fita GMI de comprimento 5 cm submetida a uma corrente de nível CC de 50 mA e frequência de 99 kHz. 130
- Figura 4.51 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas (rede MLP única), para uma fita GMI de comprimento 15 cm submetida a uma corrente de nível CC de 100 mA e frequência de 10 MHz. 130
- Figura 4.52 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas (rede MLP única), para uma fita GMI de comprimento 15 cm submetida a uma corrente de nível CC de 0 mA e frequência de 500 kHz. 131
- Figura 4.53 – Sensibilidade de fase em função do campo magnético externo para uma fita GMI de comprimento 1 cm submetida a uma corrente de nível CC de 80 mA e frequência de 500 kHz (campo magnético variando entre -5,0 Oe e 5,0 Oe). 132
- Figura 4.54 – Sensibilidade de fase em função do campo magnético externo para uma fita GMI de comprimento 1 cm submetida a uma corrente de nível CC de 40 mA e frequência de 100 kHz (campo magnético variando entre -5,0 Oe e 5,0 Oe). 133
- Figura 4.55 – Sensibilidade de fase em função do campo magnético externo para uma fita GMI de comprimento 3 cm submetida a uma corrente de nível CC de 80 mA e frequência de 300 kHz (campo magnético variando entre -5,0 Oe e 5,0 Oe). 133
- Figura 4.56 – Sensibilidade de fase em função do campo magnético externo para uma fita GMI de comprimento 3 cm submetida a uma corrente de nível CC de 40 mA e frequência de 2 MHz (campo magnético variando entre -2,0 Oe e 2,0 Oe). 134

- Figura 4.57 – Sensibilidade de fase em função do campo magnético externo para uma fita GMI de comprimento 5 cm submetida a uma corrente de nível CC de 80 mA e frequência de 3,5 MHz (campo magnético variando entre -2,0 Oe e 2,0 Oe). 135
- Figura 4.58 – Sensibilidade de fase em função do campo magnético externo para uma fita GMI de comprimento 5 cm submetida a uma corrente de nível CC de 50 mA e frequência de 99 kHz (campo magnético variando entre -2,0 Oe e 2,0 Oe). 135
- Figura 4.59 – Sensibilidade de fase em função do campo magnético externo para uma fita GMI de comprimento 15 cm submetida a uma corrente de nível CC de 100 mA e frequência de 10 MHz (campo magnético variando entre -2,0 Oe e 2,0 Oe). 136
- Figura 4.60 – Sensibilidade de fase em função do campo magnético externo para uma fita GMI de comprimento 15 cm submetida a uma corrente de nível CC de 0 mA e frequência de 500 kHz (campo magnético variando entre -2,0 Oe e 2,0 Oe). 137
- Figura 4.61 – *Fitness* médio e melhor *fitness* por geração e indivíduo com melhor *fitness* (condicionamento ótimo), para uma amostra GMI de comprimento 1 cm submetida a uma corrente de nível CC de 80 mA e frequência de 500 kHz. 139
- Figura 4.62 – *Fitness* médio e melhor *fitness* por geração e indivíduo com melhor *fitness* (condicionamento ótimo), para uma amostra GMI de comprimento 1 cm submetida a uma corrente de nível CC de 40 mA e frequência de 100 kHz. 140
- Figura 4.63 – *Fitness* médio e melhor *fitness* por geração e indivíduo com melhor *fitness* (condicionamento ótimo), para uma amostra GMI de comprimento 3 cm submetida a uma corrente de nível CC de 80 mA e frequência de 300 kHz. 141
- Figura 4.64 – *Fitness* médio e melhor *fitness* por geração e indivíduo com melhor *fitness* (condicionamento ótimo), para uma amostra GMI de comprimento 3 cm submetida a uma corrente de nível CC de 40 mA e frequência de 2 MHz. 142
- Figura 4.65 – *Fitness* médio e melhor *fitness* por geração e indivíduo com melhor *fitness* (condicionamento ótimo), para uma amostra GMI de comprimento 5 cm submetida a uma corrente de nível CC de 80 mA e frequência de 3,5 MHz. 143
- Figura 4.66 – *Fitness* médio e melhor *fitness* por geração e indivíduo com melhor *fitness* (condicionamento ótimo), para uma amostra GMI de comprimento 5 cm submetida a uma corrente de nível CC de 50 mA e frequência de 99 kHz. 144

- Figura 4.67 – *Fitness* médio e melhor *fitness* por geração e indivíduo com melhor *fitness* (condicionamento ótimo), para uma amostra GMI de comprimento 15 cm submetida a uma corrente de nível CC de 100 mA e frequência de 10 MHz. 145
- Figura 4.68 – *Fitness* médio e melhor *fitness* por geração e indivíduo com melhor *fitness* (condicionamento ótimo), para uma amostra GMI de comprimento 15 cm submetida a uma corrente de nível CC de 0 mA e frequência de 500 kHz. 146
- Figura 4.69 – S_{fas} x F x H , para uma fita GMI de comprimento 1 cm, submetida a uma corrente de nível CC de 40 mA (faixa de frequência entre 100 kHz e 500 kHz e campo magnético entre -5,0 Oe e 5,0 Oe). 147
- Figura 4.70 – Mapa de cores $|S_{fas}|$ x F x H para uma fita GMI de comprimento 1 cm, submetida a uma corrente de nível CC de 40 mA (faixa de frequência entre 100 kHz e 500 kHz e campo magnético entre -5,0 Oe e 5,0 Oe). 148
- Figura 4.71 – *Fitness* médio e melhor *fitness* por geração e indivíduo com melhor *fitness* (condicionamento ótimo), para uma amostra GMI de comprimento 1 cm submetida a uma corrente de nível CC de 40 mA (faixa de frequência entre 100 kHz e 500 kHz e campo magnético entre -5,0 Oe e 5,0 Oe). 149
- Figura 4.72 – S_{fas} x F x H , para uma fita GMI de comprimento 3 cm, submetida a uma corrente de nível CC de 80 mA (faixa de frequência entre 75 kHz e 500 kHz e campo magnético entre -5,0 Oe e 5,0 Oe). 150
- Figura 4.73 – Mapa de cores $|S_{fas}|$ x F x H , para uma fita GMI de comprimento 3 cm, submetida a uma corrente de nível CC de 80 mA (faixa de frequência entre 75 kHz e 500 kHz e campo magnético entre -5,0 Oe e 5,0 Oe). 150
- Figura 4.74 – *Fitness* médio e melhor *fitness* por geração e indivíduo com melhor *fitness* (condicionamento ótimo), para uma amostra GMI de comprimento 3 cm submetida a uma corrente de nível CC de 80 mA (faixa de frequência entre 75 kHz e 500 kHz e campo magnético entre -5,0 Oe e 5,0 Oe). 151
- Figura 4.75 – S_{fas} x F x H , para uma fita GMI de comprimento 5 cm, submetida a uma corrente de nível CC de 80 mA (faixa de frequência entre 1 MHz e 4,5 MHz e campo magnético entre -2,0 Oe e 2,0 Oe). 152
- Figura 4.76 – Mapa de cores $|S_{fas}|$ x F x H , para uma fita GMI de comprimento 5 cm, submetida a uma corrente de nível CC de 80 mA (faixa de frequência entre 1 MHz e 4,5 MHz e campo magnético entre -2,0 Oe e 2,0 Oe). 152

Figura 4.77 – <i>Fitness</i> médio e melhor <i>fitness</i> por geração e indivíduo com melhor <i>fitness</i> (condicionamento ótimo), para uma amostra GMI de comprimento 5 cm submetida a uma corrente de nível CC de 80 mA (faixa de frequência entre 1 MHz e 4,5 MHz e campo magnético entre -2,0 Oe e 2,0 Oe).	153
Figura 4.78 – $S_{fas} \times F \times H$, para uma fita GMI de comprimento 15 cm, submetida a uma corrente de nível CC de 0 mA (faixa de frequência entre 100 kHz e 2 MHz e campo magnético entre -2,0 Oe e 2,0 Oe).	154
Figura 4.79 – Mapa de cores $ S_{fas} \times F \times H$, para uma fita GMI de comprimento 15 cm, submetida a uma corrente de nível CC de 0 mA (faixa de frequência entre 100 kHz e 2 MHz e campo magnético entre -2,0 Oe e 2,0 Oe).	154
Figura 4.80 – <i>Fitness</i> médio e melhor <i>fitness</i> por geração e indivíduo com melhor <i>fitness</i> (condicionamento ótimo), para uma amostra GMI de comprimento 15 cm submetida a uma corrente de nível CC de 0 mA (faixa de frequência entre 100 kHz e 2 MHz e campo magnético entre -2,0 Oe e 2,0 Oe).	155
Figura 4.81 – <i>Fitness</i> médio e melhor <i>fitness</i> por geração e indivíduo com melhor <i>fitness</i> (condicionamento ótimo), para uma amostra GMI de comprimento 1 cm.	156
Figura 4.82 – <i>Fitness</i> médio e melhor <i>fitness</i> por geração e indivíduo com melhor <i>fitness</i> (condicionamento ótimo), para uma amostra GMI de comprimento 15 cm.	157

Lista de Tabelas

Tabela 1.1 – Grandezas magnéticas e suas unidades nos sistemas CGS e SI.	33
Tabela 3.1 – Total de dados experimentais por comprimento de fita GMI.	63
Tabela 3.2 – Limites experimentais, para fins de normalização, dos parâmetros de interesse das redes neurais MLP específicas por comprimento de fita 1 cm, 3 cm, 5 cm e 15 cm.	86
Tabela 3.3 – Limites experimentais, para fins de normalização, dos parâmetros de interesse da rede neural MLP única.	86
Tabela 3.4 – Total de padrões, por comprimento de fita, dos conjuntos de treinamento, validação e teste (rede neural MLP por comprimento de fita).	88
Tabela 3.5 – Total de padrões dos conjuntos de treinamento, validação e teste (rede MLP única).	88
Tabela 3.6 – Total de simulações realizadas por topologia de rede MLP.	89
Tabela 4.1 – Parâmetros das redes MLP, com uma camada escondida, que apresentaram melhor desempenho na modelagem da fase da impedância do efeito GMI, para amostras de comprimentos 1 cm, 3 cm, 5 cm e 15 cm.	96
Tabela 4.2 – Parâmetros das redes MLP, com duas camadas escondidas, que apresentaram melhor desempenho na modelagem da fase da impedância do efeito GMI, para amostras de comprimentos 1 cm, 3 cm, 5 cm e 15 cm.	107
Tabela 4.3 – Comparativo entre os valores de RMSE e MAPE das redes neurais MLP, com uma e duas camadas escondidas, para os comprimentos de amostra 1 cm, 3 cm, 5 cm e 15 cm.	119
Tabela 4.4 – Parâmetros da rede MLP, com uma camada escondida, que apresentou melhor desempenho na modelagem da fase da impedância do efeito GMI (rede MLP única).	119
Tabela 4.5 – Parâmetros da rede MLP, com duas camadas escondidas, que apresentou melhor desempenho na modelagem da fase da impedância do efeito GMI (rede MLP única).	125
Tabela 4.6 – Campo magnético ótimo e sensibilidade máxima de fase, calculada pelo método de aproximação por diferenças centrais.	137

Tabela 4.7 – Sensibilidade de fase e campo magnético ótimos determinados pelo AG.

146

1 Introdução

Sensores capazes de detectar campos magnéticos são largamente aplicados nas mais variadas áreas da engenharia. Um magnetômetro é um dispositivo que, baseado na utilização de um sensor magnético, é capaz de medir a magnitude e/ou direção de um campo magnético (Lenz, 1990; Ripka, 2001; Mahdi et al., 2003; Lenz & Edelstein, 2006).

Fitas e fios de ligas ferromagnéticas moles têm atraído considerável atenção devido às suas propriedades físicas e aplicações tecnológicas. Um dos fenômenos mais interessantes observados nesses elementos é a Magnetoimpedância Gigante (GMI – *Giant Magnetoimpedance*). O efeito GMI começou a ser estudado na década de 1990 e se caracteriza pela grande variação da impedância (módulo e fase) de uma amostra de material ferromagnético quando submetida a um campo magnético externo. Magnetômetros baseados no efeito GMI têm uma grande vantagem em comparação aos demais transdutores magnéticos devido a seu baixo custo para produção em escala, excelente sensibilidade, portabilidade e grande faixa de frequências de operação (desde CC até centenas de MHz) (Mendes, 2000; Cavalcanti, 2005; Gonçalves, 2006).

A maximização da sensibilidade dos transdutores magnéticos está diretamente associada à otimização da sensibilidade de seus elementos sensores. No caso de amostras GMI como elementos sensores, a sensibilidade é afetada por diversos parâmetros, sendo que a combinação ótima desses parâmetros é, usualmente, pesquisada de forma empírica (Hauser et al., 2001; Knobel & Pirota, 2002; Pirota et al., 2002; Kraus, 2003; Mahdi et al., 2003; Lenz & Edelstein, 2006; Phan & Peng, 2008).

O desenvolvimento de um transdutor magnético de elevada sensibilidade que utiliza fitas GMI como elementos sensores implica em maximizar as sensibilidades de módulo e/ou fase da impedância, em função do campo magnético, destes elementos. Estas, por sua vez, são afetadas por vários parâmetros como amplitude, nível CC e frequência da corrente de excitação; dimensões (comprimento, largura, espessura) e composição física do material da amostra; campo magnético de polarização (gerado por uma fonte externa a fim de

garantir que o sensor opere em sua faixa mais sensível); temperatura ambiente; dentre outros (Costa Silva, 2010, 2013). Assim, o comportamento da impedância das amostras GMI deve ser experimentalmente analisado de forma a se verificar qual é o conjunto que gera a sensibilidade ótima e, tendo em vista o grande número de variáveis, uma busca exaustiva por todo o espaço amostral torna-se inviável.

Os magnetômetros GMI até então desenvolvidos por pesquisadores de todo o mundo eram baseados nas características de módulo da impedância do efeito GMI (Hauser et al., 2001; Mahdi et al., 2003; Gusmão et al., 2005; Lenz & Edelstein, 2006; Ramos Louzada et al., 2006, 2007; Phan & Peng, 2008; Cavalcanti et al., 2006, 2008; Geliang et al., 2011; Zhao et al., 2012). No entanto, pesquisas recentes conduzidas pelo Laboratório de Biometrologia da PUC-Rio (LaBioMet) verificaram que transdutores magnéticos baseados nas características de fase da impedância do efeito GMI têm o potencial de elevar os valores de sensibilidade em pelo menos 100 vezes, quando comparados àqueles baseados em módulo (Costa Silva et al., 2008a, b, 2009a, b, c, d, 2010, 2013). De acordo com Costa Silva (2013), o nível de sensibilidade alcançado considerando as características da fase permite vislumbrar a aplicação de magnetômetros GMI na medição de campos magnéticos ultra-fracos. Assim, o comportamento da impedância das amostras GMI deve ser experimentalmente analisado de forma a se verificar qual é o condicionamento da amostra que leva a maximização de sua sensibilidade.

Costa Silva (2013), a partir da caracterização experimental de amostras GMI em forma de fita com composição $\text{Co}_{70}\text{Fe}_5\text{Si}_{15}\text{B}_{10}$, determinou o conjunto de parâmetros de condicionamento que mais afeta a impedância das amostras analisadas. Realizaram-se análises em amostras de comprimentos 1 cm, 3 cm, 5 cm e 15 cm, para correntes CC variando entre 0 mA e 100 mA e para frequências entre 75 kHz e 30 MHz. Os resultados obtidos por Costa Silva (2013) indicaram que as variáveis que mais afetam a impedância das amostras analisadas são comprimento da amostra, nível CC e frequência da corrente de excitação, além do campo magnético externo. Costa Silva (2013) observou que a adição de níveis CC a correntes de condicionamento puramente alternadas pode elevar consideravelmente a sensibilidade de fase das amostras e que a variação dos

comprimentos das amostras afeta de forma não linear a dependência da fase em relação à frequência e ao nível CC da corrente de excitação.

Hoje, os modelos quantitativos propostos para o efeito GMI ainda não são amplamente aceitos pela comunidade científica devido às simplificações adotadas (Hauser et al., 2001; Knobel & Pirota, 2002; Pirota et al., 2002; Kraus, 2003; Phan & Peng, 2008). Isto, de certa forma, inviabiliza a utilização de um método de otimização convencional, em virtude do modelo não retratar, de forma fidedigna, o fenômeno em si. Por sua vez, o procedimento experimental de caracterização das amostras GMI para determinar a melhor combinação dos diversos parâmetros de influência demanda tempo e uma busca exaustiva por todo o espaço amostral é, experimentalmente, inviável. Primeiro, deve-se obter, experimentalmente, a curva de fase da impedância (θ) em função do campo magnético para, então, se determinar sua sensibilidade de fase ($\frac{d\theta}{dH}$). Em contrapartida, técnicas de inteligência computacional, tais como redes neurais e algoritmos genéticos, têm sido cada vez mais utilizadas com sucesso, em diversas áreas de aplicação, resolvendo problemas que eram difíceis de serem solucionados pelos métodos convencionais ou mesmo sem solução.

As Redes Neurais (RNAs) são modelos computacionais não lineares, inspirados nas estruturas neurais biológicas, e procuram reproduzir características do comportamento humano tais como aprendizado, generalização, associação e abstração (Fausett, 1994; Haykin, 2001; Braga et al., 2007). As RNAs são compostas por unidades de processamento interconectadas (neurônios artificiais), de modo que todo processamento básico é realizado de forma distribuída entre eles, onde cada qual envia o seu resultado para as outras unidades através de suas conexões (sinapses). O principal atrativo de uma RNA é a sua capacidade de aprender por meio de exemplos (dados conhecidos) e generalizar a informação aprendida, apresentando respostas coerentes para entradas não vistas durante a fase de aprendizado (dados desconhecidos).

Os Algoritmos Genéticos (AGs), por sua vez, são algoritmos probabilísticos que fornecem um mecanismo de busca paralela e adaptativa baseado no princípio Darwiniano de sobrevivência dos mais aptos e na reprodução genética (Holland, 1975, 1992; Goldberg, 1989; Davis, 1990; Fogel; 1994; Michalewicz, 1996; Mitchell, 1996). Eles são utilizados na resolução de problemas de otimização

(numérica, combinatorial) que apresentam espaços de busca muito grandes, de difícil representação (o modelo matemático que representa o problema não é conhecido ou é difícil de se obter) ou para os quais ainda não há um algoritmo de otimização eficiente. Entre as suas principais vantagens, destacam-se uma maior probabilidade de encontrar o ótimo global por realizar buscas simultâneas em várias regiões do espaço de busca, facilidade de hibridização, flexibilidade e simplicidade na implementação. Os AGs trabalham com uma população de indivíduos (soluções do problema) que evoluem através de sucessivas gerações (sobrevivência do mais forte) até encontrar a solução ótima.

A partir da utilização de tais técnicas, desenvolveu-se um modelo computacional que torna a busca pelo condicionamento ótimo da amostra GMI mais rápida e abrangente. Assim, este trabalho propõe a utilização de um modelo computacional baseado em Redes Neurais Artificiais *Multilayer Perceptron* e Algoritmos Genéticos para a otimização da sensibilidade de fase da impedância do efeito GMI, em função do campo magnético externo, para ligas ferromagnéticas amorfas de composição $\text{Co}_{70}\text{Fe}_5\text{Si}_{15}\text{B}_{10}$. O modelo proposto permite a obtenção da sensibilidade ótima de fase a partir dos seguintes parâmetros que a afetam: comprimento das amostras, nível CC e frequência da corrente de excitação, além do campo magnético externo. A RNA é responsável por modelar o comportamento da fase da impedância em função dos parâmetros acima mencionados, tendo como padrões de entrada, os dados coletados, experimentalmente, da característica de fase da impedância em função do campo magnético externo, para diversas combinações possíveis destes parâmetros. O AG é responsável pela otimização da sensibilidade de fase da amostra GMI e determinação do seu condicionamento ótimo e tem, como função de avaliação, a derivada da rede neural em relação ao campo magnético externo.

1.1

Motivação

A intensidade de campo magnético pode ser medida usando diferentes técnicas. Cada técnica possui propriedades únicas que a torna mais adequada a determinadas aplicações. Estas aplicações podem variar desde a detecção da presença ou variação de campo magnético até a medição de suas propriedades

vetoriais e escalares. Sensores capazes de detectar campos magnéticos são largamente aplicados nas mais variadas áreas da engenharia. Um magnetômetro é um dispositivo que, baseado na utilização de um sensor magnético, é capaz de medir a magnitude e/ou direção de um campo magnético. Os magnetômetros existentes exploram vários conceitos físicos e são bem diferentes entre si nos aspectos de construção e custo (Boll & Overshot, 1989; Lenz, 1990; Ripka, 2001, 2003; Mahdi et al., 2003; Lenz & Edelstein, 2006; Clarke & Braginski, 2004, 2006).

Os magnetômetros GMI são transdutores magnéticos cujos elementos sensores se baseiam no efeito da Magnetoimpedância Gigante (GMI), que se caracteriza pela grande variação da impedância (módulo e fase) de uma amostra de material ferromagnético quando submetida a um campo magnético externo. Apesar de sua recente descoberta (década de 1990), este fenômeno tem sido objeto de intensos estudos, tanto do ponto de vista de sua física básica quanto das enormes perspectivas de aplicações tecnológicas. Dentre as áreas de aplicação em que já foram desenvolvidos magnetômetros baseados no fenômeno GMI, destacam-se: detectores de presença (Valenzuela et al., 1996), controle de processos industriais (Hauser et al., 2000), sistemas de navegação (Honkura, 2002), memórias de alta densidade e HDs (Delooze et al., 2004), controle de tráfego (Uchiyawa et al., 2000), detecção de fissuras em materiais (Kim et al., 2002; Tehranchi et al., 2011) e aplicações biológicas e biomédicas (Kurlyandskaya et al., 2003; Totsu et al., 2004; Chiriac et al., 2005; Cavalcanti, 2005; Ramos Louzada et al., 2006, 2007; Kurlyandskaya & Myar, 2007; Uchiyama et al., 2009). As vantagens dos magnetômetros GMI em comparação aos demais são o seu baixo custo para produção em escala, a boa sensibilidade e a grande faixa de frequências de operação (Mendes, 2000; Mahdi et al., 2003; Cavalcanti, 2005; Gonçalves, 2006; Costa Silva, 2010).

A maximização da sensibilidade dos transdutores magnéticos está diretamente associada à otimização da sensibilidade de seus elementos sensores. No caso de elementos sensores GMI, a sensibilidade é afetada por diversos parâmetros, sendo que a combinação ótima desses parâmetros, que leva à maximização da sensibilidade é, usualmente, pesquisada de forma empírica. Isto faz com que a busca pelo condicionamento ótimo seja inviável em função do grande número de variáveis envolvidas. Modelos quantitativos do efeito GMI têm

sido propostos nos últimos anos, porém, todos apresentam uma série de simplificações e não consideram todos os parâmetros que o afetam. Portanto, o desenvolvimento de um modelo alternativo que auxilie na determinação do condicionamento ótimo de uma amostra GMI é fundamental para o desenvolvimento de um transdutor magnético GMI de elevada sensibilidade, capaz de detectar campos ultra fracos. O Laboratório de Biometrologia da PUC-Rio (LaBioMet), em colaboração com o Departamento de Física da Universidade Federal de Pernambuco (DF-UFPE), vem se dedicando, há mais de 7 anos, ao desenvolvimento de protótipos de magnetômetros GMI para aplicação biomédica, que em muitos casos, requer uma sensibilidade para detecção de campos magnéticos da ordem de 100 pT. Com o intuito de apoiar este trabalho, é proposto nesta dissertação um modelo computacional, baseado em redes neurais e algoritmos genéticos, que auxilia na determinação do condicionamento ótimo de amostras GMI em forma de fita. O modelo se beneficia das características inerentes a cada um dos métodos de inteligência computacional empregados: no caso de redes neurais, aprendizado e generalização, e no caso de algoritmos genéticos, paralelismo na busca pela solução ótima.

Desta forma, o modelo proposto determina a sensibilidade de fase e o condicionamento ótimo de uma amostra GMI em forma de fita a partir dos seguintes parâmetros que a afetam: comprimento das amostras, nível CC e frequência da corrente de excitação, além do campo magnético externo. As redes neurais, a partir do aprendizado adquirido com os padrões experimentais conhecidos, têm a capacidade de generalizar este conhecimento e com isto inferir o comportamento da fase da impedância do efeito GMI para situações não testadas experimentalmente. A determinação do condicionamento ótimo, de forma que o sensor opere em uma região onde sua sensibilidade seja máxima, é atribuição do algoritmo genético.

1.2 Magnetismo

O magnetismo é uma propriedade básica de qualquer material. Todas as substâncias, sejam sólidas, líquidas ou gasosas, apresentam alguma característica magnética, em todas as temperaturas (Sinnecker, 2000).

As propriedades magnéticas dos materiais têm sua origem no movimento dos elétrons nos átomos. Do ponto de vista clássico, são de dois tipos os movimentos, associados ao elétron, que podem explicar a origem dos momentos magnéticos: o momento angular orbital do elétron e o momento angular do *spin* do elétron nos íons e átomos que compõem o material (Araújo, 2009).

É sabido que no máximo dois elétrons podem ocupar o mesmo nível energético de um átomo isolado. Esses dois elétrons têm *spins* opostos e, como cada elétron, quando girando em torno de si mesmo, é equivalente a uma carga se movendo, cada elétron atua como um ímã extremamente pequeno, com os correspondentes polos norte e sul. Em geral, o número de elétrons que têm um certo *spin* é igual ao número de elétrons que têm o *spin* oposto e o efeito global é uma estrutura magneticamente insensível ou neutra. Entretanto, em um elemento com subníveis internos não totalmente preenchidos, o número de elétrons com *spin* num sentido é diferente do número de elétrons com *spin* contrário. Dessa forma, esses elementos têm um momento magnético global não nulo (Figura 1.1) (Filardo, 200-).

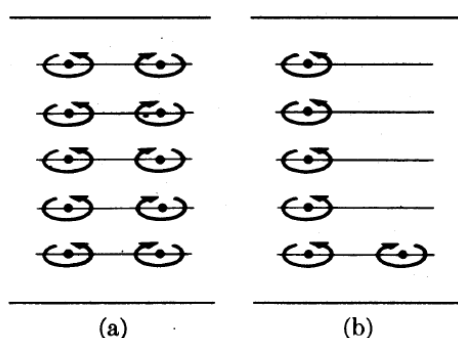


Figura 1.1 – Magnetismo atômico. (a) Momento magnético global nulo. (b) Momento magnético global não nulo. Adaptado de (Filardo, 200-).

Um material magnético é subdividido em domínios magnéticos com diferentes orientações de magnetização. A Figura 1.2 ilustra a ideia de domínios magnéticos. A região de transição entre domínios magnéticos adjacentes é denominada parede de domínio. Dentro de um domínio os momentos magnéticos apresentam um alinhamento unidirecional, ou seja, um vetor campo magnético próprio. Em um material magnético desmagnetizado os domínios estão orientados ao acaso, de forma que seus momentos magnéticos se anulam. Quando um campo magnético externo é aplicado ao material, os domínios tendem a se alinhar na direção deste campo, magnetizando o material, uma vez que o vetor soma dos

momentos magnéticos individuais não é mais nulo. Este alinhamento dos domínios magnéticos pode permanecer ou não após a retirada do campo magnético externo.

Os processos de magnetização em materiais podem ocorrer basicamente de duas formas: por deslocamento das paredes de domínios magnéticos e/ou por rotação da magnetização local dentro dos domínios. Em ambos os casos, as mudanças na magnetização dependem fortemente de imperfeições no material.




Figura 1.2 – (a) Domínios magnéticos desalinhados (campo magnético total em qualquer direção é nulo) (b) Domínios magnéticos alinhados (sob a ação de um campo magnético externo). Adaptado de (Araújo, 2009).

1.2.1 Grandezas Magnéticas

Os momentos magnéticos de um material tendem a se alinhar quando o material é colocado sob a influência de um campo magnético (\vec{H}) externo, situação em que o material é dito magnetizado. A intensidade magnética de um material magnetizado, chamada de magnetização (\vec{M}), depende da densidade do momento magnético distribuído pelo volume e é definida pela razão entre a soma de todos os momentos magnéticos elementares (\vec{m}_i) e o volume total que eles ocupam (V) (Araújo, 2009).

A magnetização é uma propriedade do material que pode surgir de fontes magnéticas internas ou ser induzida por um campo magnético externo. Assim como o campo magnético externo, a magnetização é uma grandeza vetorial (Craсто, 2003).

O fluxo magnético ($\vec{\phi}$) é definido como a quantidade de linhas de campo que atingem perpendicularmente uma dada superfície. As linhas de campo representam geometricamente um campo magnético e são linhas envoltórias imaginárias fechadas que nunca se cruzam.

A indução magnética, ou densidade de fluxo magnético, indicada por \vec{B} , é uma grandeza vetorial determinada pela relação entre o fluxo magnético ($\vec{\phi}$) e a

área de uma dada superfície perpendicular à direção do fluxo magnético (A). A direção da densidade de fluxo magnético é sempre tangente às linhas de campo magnético em qualquer ponto e o sentido é sempre o mesmo das linhas de campo. Assim:

$$\vec{B} = \frac{\vec{\phi}}{A} \quad (1.1)$$

O número de linhas de campo magnético que atravessam perpendicularmente uma dada superfície é proporcional ao módulo da densidade de fluxo magnético na região considerada. Assim, onde as linhas de campo estão muito próximas umas das outras, o valor da densidade de fluxo magnético é alto.

A resposta de um material a um campo aplicado pode ser representada por suas permeabilidade magnética e susceptibilidade magnética. A permeabilidade magnética (μ) de um material expressa intrinsecamente sua capacidade de se mostrar mais ou menos suscetível à passagem de fluxo magnético e é definida por

$$\mu = \frac{\vec{B}}{\vec{H}} \quad (1.2)$$

A relação entre a permeabilidade magnética (μ) de um dado material e a permeabilidade do vácuo (μ_0) é chamada de permeabilidade relativa e é definida por:

$$\mu_r = \frac{\mu}{\mu_0} \quad (1.3)$$

A susceptibilidade magnética (χ), por sua vez, expressa a resposta do material ao campo aplicado e é definida pela razão entre magnetização e campo aplicado:

$$\chi = \frac{\vec{M}}{\vec{H}} \quad (1.4)$$

Assim, a Equação (1.5) descreve a relação entre campo magnético, densidade de fluxo magnético e magnetização do material, onde μ_0 é a permeabilidade magnética do vácuo, constante universal de valor $4\pi \times 10^{-7} \text{ H}\cdot\text{m}^{-1}$.

$$\vec{B} = \mu_0(\vec{H} + \vec{M}) \quad (1.5)$$

A Tabela 1.1 apresenta as principais grandezas magnéticas referenciadas nessa dissertação, suas unidades nos sistemas CGS e SI e suas conversões para o SI.

Na literatura, o sistema comumente utilizado, no que se refere ao efeito GMI, é o CGS. Em função disso, na presente dissertação, a unidade para campo magnético é oersted (Oe), e para sensibilidade de fase, graus por oersted ($^{\circ}\cdot\text{Oe}^{-1}$).

Tabela 1.1 – Grandezas magnéticas e suas unidades nos sistemas CGS e SI.

Grandeza		Unidade		Conversão
Nome	Símbolo	CGS	SI	
<i>Fluxo Magnético</i>	ϕ	<i>maxwell</i> (Mx)	<i>weber</i> (Wb)	$1 \text{ Mx} = 10^{-8} \text{ Wb}$
<i>Densidade de Fluxo Magnético</i>	B	<i>gauss</i> (G)	<i>tesla</i> (T)	$1 \text{ G} = 10^{-4} \text{ T}$
<i>Campo Magnético</i>	H	<i>oersted</i> (Oe)	<i>ampère por metro</i> (A·m ⁻¹)	$1 \text{ Oe} = (10^3/4\pi) \text{ A}\cdot\text{m}^{-1}$
<i>Magnetização</i>	M	e.m.u. cm ⁻³	<i>ampère por metro</i> (A·m ⁻¹)	$1 \text{ e.m.u. cm}^{-3} = 10^3 \text{ A}\cdot\text{m}^{-1}$
<i>Permeabilidade Magnética</i>	μ	<i>adimensional</i>	<i>henry por metro</i> (H·m ⁻¹)	-
<i>Susceptibilidade Magnética</i>	χ	<i>adimensional</i>	<i>adimensional</i>	-

1.2.2 Materiais Magnéticos Amorfos

As ligas metálicas amorfas, também chamadas de vidros metálicos, são comumente fabricadas a partir de técnicas de solidificação ultra-rápida dos seus constituintes em fase líquida. A obtenção do primeiro vidro metálico, a partir da liga Au₇₅Si₂₅, foi reportada por Duwez e seus colaboradores, W. Klement Jr. e R. H. Willens, no Instituto de Tecnologia da Califórnia, USA, na década de 60. Desde então, as ligas metálicas amorfas começaram a despertar muito interesse na

comunidade científica devido a suas propriedades físicas e químicas, tais como alta resistência mecânica, elevadas condutividades elétrica e térmica, elevada dureza, alta tenacidade, alta resistência à corrosão e expansão térmica reduzida (Lopes, 2013).

Ao contrário de um material cristalino, os átomos em um material amorfo não apresentam um ordenamento espacial que se repete por todo o volume do material. Estes materiais são desordenados do ponto de vista da estrutura formada pelos seus átomos, que estão distribuídos aleatoriamente, porém, podem ser muito bem ordenados do ponto de vista magnético, ou seja, os momentos magnéticos constituintes estão ordenados de alguma forma periódica. Ligas de metais de transição (Fe, Co, Ni) com elementos metalóides (B, C, Si, Ge, P) são exemplos desta classe de materiais (Pirota, 2000).

Materiais magnéticos amorfos são produzidos nas mais variadas formas, tais como filmes finos, fitas, fios, microfios cobertos com vidro e em forma de pó. As aplicações tecnológicas mais relevantes envolvendo tais materiais são baseadas em suas características magnéticas doces: alta permeabilidade magnética, baixo campo coercivo e alta magnetização de saturação. Além disso, possuem elevada resistividade elétrica, fazendo com que as perdas por correntes parasitas sejam fortemente reduzidas. Em virtude de possuírem alta permeabilidade magnética e alta resistividade elétrica, podem ser utilizados na fabricação de transformadores elétricos, cabeçotes de gravadores e transdutores magnéticos (Pirota, 2000; Lopes, 2013).

Estes materiais apresentam também um importante fenômeno, chamado Magnetoimpedância Gigante, descoberto na década de 1990, e que tem sido objeto de intensos estudos, tanto do ponto de vista de sua física básica quanto das enormes perspectivas de aplicações tecnológicas. O fenômeno da Magnetoimpedância Gigante é explicado em detalhes na seção 1.3.

As ligas metálicas amorfas são fabricadas por meio de várias técnicas, tais como *sputtering* (Xiao et al., 1999; Panina & Mohri, 2000), eletrodeposição (Sinnecker et al., 2000a, b; Garcia et al., 2001; Atalay et al., 2006), *melt spinning* (Mehrabian et al., 1978; Coisson et al., 2002), entre outras. Destas, a mais comum é a de *melt spinning*. Os dados experimentais utilizados nesta dissertação foram obtidos a partir de amostras GMI em forma de fita, fabricadas pelo Departamento

de Física da Universidade Federal de Pernambuco (UFPE). As fitas GMI foram produzidas pela técnica de *melt spinning*, a qual é explicada a seguir.

1.2.3 Técnica de Fabricação *Melt Spinning*

A técnica de fabricação *melt spinning* é um processo de solidificação ultra rápida que consiste no resfriamento abrupto (10^5 a 10^9 °C/s) de uma liga metálica, ainda em estado líquido (*melt*), quando esta entra em contato com um substrato de resfriamento (*chill block*) em movimento. Tanto a taxa de resfriamento inicial quanto a geometria final da fita dependem da natureza da massa líquida. (Dorneles, 1997).

Nesse método, a liga é previamente fundida em um forno de indução e em seguida ejetada por um orifício, pela pressão de um gás (argônio ou nitrogênio). O metal líquido atinge a superfície externa de um cilindro de cobre resfriado, que gira com uma determinada velocidade angular. O metal líquido, ao entrar em contato com o cilindro, é resfriado rapidamente e solidificado em forma de fita. As dimensões da fita variam de acordo com o diâmetro do orifício de ejeção, a velocidade angular do disco de cobre, a pressão do gás de ejeção e a temperatura do material no momento da ejeção (Liebermann, & Graham, 1976; Pirota, 2002).

A técnica de *melt spinning* possibilita a obtenção de fitas de espessuras inferiores a 50 µm e largura variando de 2 mm a 300 mm. A Figura 1.3 apresenta uma representação esquemática do processo de *melt spinning*.




Figura 1.3 – Representação esquemática do processo de *melt spinning*.

As Figuras 1.4 e 1.5 exibem o equipamento utilizado na UFPE para produção de amostras GMI.



Figura 1.4 – Equipamento utilizado, na UFPE, para produção de amostras GMI (Costa Silva, 2010).



Figura 1.5 – Detalhes do interior do equipamento apresentado na Figura 1.4 (Costa Silva, 2010).

1.3 Magnetoimpedância Gigante (GMI)

Magnetômetros GMI são dispositivos que utilizam sensores magnéticos baseados no efeito da Magnetoimpedância Gigante (*Giant Magnetoimpedance* – GMI), que se caracteriza pela grande variação da impedância (módulo e fase) de uma amostra de material ferromagnético quando submetida a um campo magnético externo. Apesar de sua recente descoberta (década de 1990), este fenômeno tem sido objeto de intensos estudos, tanto do ponto de vista de sua física básica quanto das enormes perspectivas de aplicações tecnológicas (Machado et al., 1993; Beach & Berkowitz, 1994a; Pirota, 2000; Knobel & Pirota, 2002; Pirota et al., 2002).

O fenômeno da Magnetoimpedância Gigante é explicado em detalhes a seguir.

1.3.1 Contexto Histórico

O fenômeno da Magnetoimpedância Gigante passou a ser intensamente estudado a partir da década de 1990, tendo como ponto de partida os estudos de magnetoresistência em filmes multicamadas, nos quais foi observada uma

diminuição da resistência elétrica de um filme quando este foi submetido a um campo magnético externo constante (Machado et al., 1993, 1994, 1995).

Em 1993 um grupo de pesquisadores de Recife, chefiado pelo Prof. Fernando Machado, publicou resultados da variação da resistência com campo magnético externo em fitas amorfas de composição $\text{Co}_{70.4}\text{Fe}_{4.6}\text{Si}_{15}\text{B}_{10}$ (50 μm de espessura, 1,5 mm de largura e 1,5 cm de comprimento) (Machado et al., 1993). No mesmo ano, os indianos K. Mandal e S. K. Ghatak publicaram resultados semelhantes (resistência elétrica em função do campo externo aplicado) em fios amorfos (120 μm de diâmetro e 10 cm de comprimento) de $\text{Co}_{68.1}\text{Fe}_{4.4}\text{Si}_{12.5}\text{B}_{15}$ (Mandal & Ghatak, 1993). Em ambos os trabalhos, os resultados obtidos foram interpretados como uma variação do efeito GMR, ou seja, a variação da resistência das amostras seria devida à variação de suas resistividades em função da mudança no movimento dos elétrons quando seus *spins* são afetados pela orientação da magnetização do material.

No ano seguinte, o efeito da GMI foi explicado teoricamente no trabalho de Beach & Berkowitz (1994a) que, além de batizarem o fenômeno pelo nome conhecido até os dias de hoje, também foram os primeiros que explicaram o efeito com base na teoria da eletrodinâmica clássica (equações de Maxwell), mostrando que a variação da impedância devida à aplicação de um campo magnético externo é, na verdade, reflexo da variação da profundidade de penetração de ondas eletromagnéticas, que depende da frequência angular da onda (ω), da permeabilidade magnética do material (μ) e de sua condutividade elétrica (σ). Resolvendo as equações de Maxwell para o problema de cálculo da impedância de um fio ferromagnético doce por onde passa uma corrente elétrica I de frequência angular ω , eles encontraram a expressão (Duque, 2005)

$$Z = R + iX = \frac{1}{2} R_{cc} ka \frac{J_0(ka)}{J_1(ka)} \quad (1.6)$$

onde

$$k = \frac{(1+i)}{\delta} \quad \text{e} \quad \delta = \frac{c}{\sqrt{2\pi\omega\sigma\mu_0}} \quad (1.7)$$

e, c é a velocidade da luz no vácuo, J_0 e J_1 são funções de Bessel de primeiro tipo, R_{CC} é a resistência CC do fio, σ é a condutividade elétrica do material, μ_0 é a permeabilidade magnética circunferencial, a é o raio do fio e δ é a profundidade de penetração magnética, responsável pelo efeito *skin*, o qual determina a profundidade, a partir da superfície do fio, por onde a corrente efetivamente flui.

Observa-se que o efeito da magnetoimpedância gigante em materiais magnéticos amorfos é devido ao fato da impedância de um dado material ser inversamente proporcional à profundidade de penetração da corrente, em consequência do efeito *skin*, que por sua vez depende da frequência da corrente aplicada, da geometria e da permeabilidade magnética do material, a qual pode variar em função do campo magnético externo e da amplitude da corrente que atravessa a amostra. Isto faz com que, em amostras de materiais de alta permeabilidade, mesmo em uma faixa intermediária de frequências, possa-se esperar uma variação da impedância em função do campo magnético. Assim, o fenômeno GMI reflete basicamente a dependência da permeabilidade magnética com o campo magnético aplicado (Duque, 2005).

Na literatura, as medidas de GMI são geralmente normalizadas por um valor de referência, sendo que, na maioria dos trabalhos, utiliza-se apenas o módulo da impedância ($|Z|$) para determinação da variação percentual do efeito GMI em função do campo magnético externo aplicado (H). Tipicamente, o valor de referência (H_{ref}) é um campo magnético suficientemente alto (campo de saturação) para o qual o módulo da impedância Z está saturado. Assim, define-se a GMI(%) (Mendes, 2000; Gonçalves, 2006; Costa Silva, 2010) como sendo a medida relativa da variação do módulo da impedância Z da amostra em função do campo magnético externo H aplicado, ou seja,

$$GMI(\%) = \frac{|Z(H)| - |Z(H_{ref})|}{|Z(H_{ref})|} \times 10^2 \quad (1.8)$$

O modelo computacional proposto nesta dissertação se baseia nas características de fase da impedância do efeito GMI. Como a GMI(%) permite inferir somente sobre as variações de módulo da impedância, esta medida, de uso comum na literatura para determinação da variação percentual do efeito GMI, não

foi utilizada na presente dissertação. No caso, para fins de análise, utilizou-se as próprias curvas experimentais de fase (θ) da impedância em função do campo magnético externo obtidas a partir dos dados fornecidos pelo Laboratório de Biometrologia (LaBioMet) da PUC-Rio.

Conforme mencionado anteriormente, a profundidade de penetração magnética depende da frequência da corrente usada para excitar a amostra. Para frequências muito baixas, a profundidade de penetração pode se tornar maior do que as dimensões transversais da amostra, até mesmo se o material possuir uma alta permeabilidade magnética. Por outro lado, para frequências muito altas, a profundidade de penetração pode, muitas vezes, ser muito menor do que as dimensões transversais da amostra, fazendo com que a corrente se propague próxima à superfície da amostra e, neste caso, a impedância passa a depender muito fortemente de efeitos de superfície (Duque, 2005). Devido a esse fato, o efeito GMI é, na maioria das vezes, classificado de acordo com o regime de frequências no qual se realizam as medidas. Este assunto é abordado na próxima seção.

1.3.2 Efeito GMI por Regime de Frequências

A frequência (f) da corrente de excitação constitui um parâmetro importante na medição da GMI, uma vez que ela determina a profundidade de penetração da corrente (δ). Diferentes modelos podem ser derivados de acordo com a faixa de frequências utilizada. Usualmente, tem-se:

- a) **Regime de baixas frequências** (até alguns kHz): para frequências muito baixas a profundidade de penetração torna-se muito maior do que as dimensões transversais da amostra. Neste caso, o efeito *skin* é desprezível e somente a componente imaginária da impedância muda com a aplicação do campo magnético externo, uma vez que não há mudança da área da seção transversal por onde a corrente efetivamente flui. Nesta situação, o efeito é muitas vezes chamado de magnetointutivo (Mohri et al., 1993; Panina et al., 1995; Duque, 2005).
- b) **Regime de frequências intermediárias** (entre 100 kHz e alguns MHz): nesse intervalo de frequências, a GMI é explicada com base na variação

da profundidade de penetração da corrente (δ) em função do campo magnético externo devido às grandes variações na permeabilidade magnética (Beach & Berkowitz, 1994b; Duque, 2005).

- c) **Regime de altas frequências** (dezenas de MHz até alguns GHz): para frequências muito altas o efeito da GMI tem muita similaridade com os processos de ressonância ferromagnética (FMR). Tem sido mostrado tanto teoricamente quanto experimentalmente que as medidas de GMI são completamente análogas ao experimento de FMR. Esse intervalo de frequências é caracterizado pelo aparecimento de efeitos dinâmicos sobre os processos de magnetização e pelo fato do efeito *skin* ser muito forte (a corrente flui através de uma região muito próxima à superfície da amostra) (Yelon et al., 1996; Duque, 2005).

1.3.3

Geometria da GMI

A geometria da GMI é determinada pela direção relativa entre o campo magnético externo (\vec{H}) e a corrente alternada de excitação (\vec{I}) utilizada para a medição da impedância. A direção do campo magnético externo aplicado pode ser longitudinal, perpendicular ou transversal à direção da corrente alternada de excitação (Figura 1.6).

- a) **Magnetoimpedância Longitudinal** (*Longitudinal Magnetoimpedance*): configuração mais utilizada em estudos relacionados a GMI. O campo magnético externo é aplicado na mesma direção da maior dimensão da amostra e paralelo à corrente de excitação (Machado et al., 1993; Mandal & Gatak, 1993; Beach & Berkowitz, 1994a, b; Panina et al., 1995; Yelon et al., 1996);
- b) **Magnetoimpedância Perpendicular** (*Perpendicular Magnetoimpedance*): configuração na qual o campo magnético externo é perpendicular à corrente de excitação e no mesmo plano da fita. Pesquisas mostram que há pouca sensibilidade magnética nesta configuração.
- c) **Magnetoimpedância Transversal** (*Transversal Magnetoimpedance*): configuração na qual o campo magnético externo é aplicado

transversalmente à amostra (\vec{H} e \vec{I} ortogonais entre si) (Sommer & Chien, 1995, 1996).




Figura 1.6 – Configurações da Geometria da GMI. (a) Longitudinal. (b) Perpendicular. (c) Transversal.

1.3.4 Magnetoimpedância Longitudinal

Como descrito na seção anterior, a Magnetoimpedância Longitudinal (LMI) é um caso particular do efeito GMI, no qual o campo magnético externo (\vec{H}) é aplicado na mesma direção da maior dimensão da amostra, paralelo à corrente de excitação (\vec{I}). Por meio da medição da tensão V induzida nas extremidades da amostra pode-se calcular a impedância (Figura 1.7).



Figura 1.7 – Desenho esquemático de uma amostra em forma de fita, sendo submetida à passagem de uma corrente elétrica alternada e na presença de um campo magnético (Cavalcanti, 2005).

Neste caso particular, considerando a descrição por fasores da tensão e corrente AC e arbitrando-se a fase da corrente ϕ_I como nula, tem-se que a impedância da amostra é (Cavalcanti, 2005)

$$Z = \frac{|V|e^{j\phi_V}}{|I|e^{j\phi_I}} = \frac{|V|}{|I|} e^{j\phi} = |Z| e^{j\phi} \quad (1.9)$$

Assim, a impedância complexa (Z) é definida por duas componentes: a real, atribuída à parte resistiva, e a imaginária, atribuída à parte reativa.

Como foi dito anteriormente, o efeito GMI está relacionado à dependência da profundidade de penetração de corrente com a permeabilidade magnética transversal, a qual é função do campo magnético externo, da frequência e magnitude da corrente que atravessa a amostra. Assim, para uma amostra em forma de fita, tem-se (Costa Silva, 2010)

$$Z = (1 - j) \frac{L}{2\omega\sigma\delta} \frac{1}{1 - e^{-(1-j)\frac{t}{2\delta}}} \quad (1.10)$$

$$\delta = c \left(\sqrt{\frac{1}{2\pi\omega\mu_t\sigma}} \right) \quad (1.11)$$

onde L é o comprimento da fita, t a espessura da fita, δ profundidade de penetração da corrente, σ a condutividade do material, μ_t a permeabilidade magnética transversal, ω a frequência angular da corrente e c a velocidade da luz no vácuo.

A Figura 1.8 mostra curvas típicas da variação do módulo da impedância $|Z|$ em função do módulo do campo magnético externo $|\vec{H}|$. Dependendo da anisotropia da amostra as curvas podem apresentar pico único ou pico duplo. O exemplo dado refere-se a uma fita de $(\text{Fe}_{0.053}\text{Co}_{0.947})_{70}\text{Si}_{12}\text{B}_{18}$, na faixa de frequência de 900 kHz, com corrente aplicada de 5 mA (a) antes de sofrer tratamento térmico e (b) depois de passar por tratamento térmico (Cavalcanti, 2005).

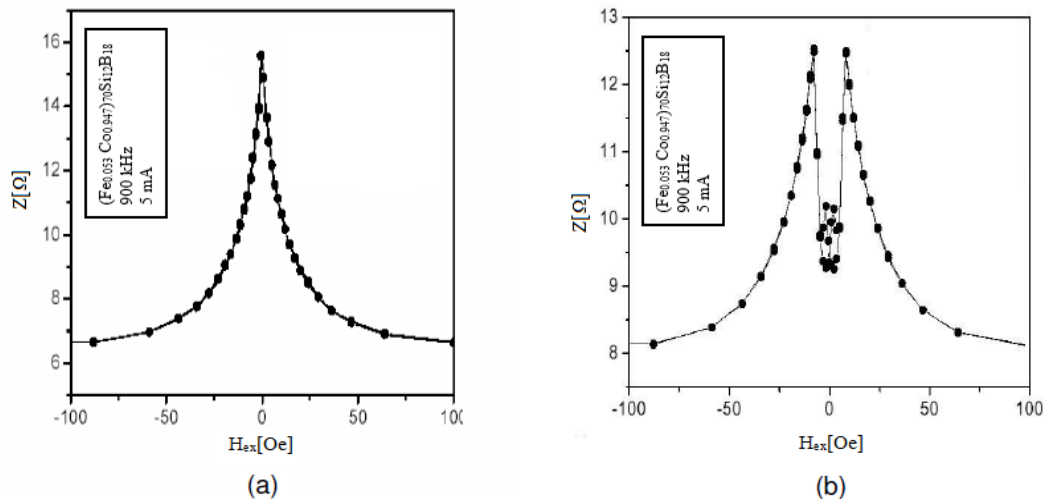


Figura 1.8 – Curvas típicas da variação de $|Z| \times H$ para uma fita de $(\text{Fe}_{0.053}\text{Co}_{0.947})_{70}\text{Si}_{12}\text{B}_{18}$, na faixa de frequência de 900 kHz, com corrente aplicada de 5 mA (a) antes de sofrer tratamento térmico (sem *annealing*) e (b) depois de passar por tratamento térmico (com *annealing*). Adaptado de (Cavalcanti, 2005).

1.3.5 GMI Assimétrica

As curvas GMI de variação da impedância em função do campo magnético externo são geralmente simétricas em relação a esse campo magnético. No entanto, certos fatores favorecem o aparecimento de uma assimetria nas curvas GMI, que é caracterizada pelo incremento de um dos picos (ou vales) da curva GMI em detrimento do outro. Este fenômeno é conhecido como Magnetoimpedância Gigante Assimétrica (AGMI). Dentre os fatores que favorecem o aparecimento desta assimetria, destacam-se: AGMI induzida por corrente CC (aplicação, em amostras GMI em forma de fio, de uma corrente CC paralela à direção de propagação da corrente de excitação CA e ao campo magnético externo, induzido um campo magnético CC circunferencial ao comprimento da amostra) (Machado et al., 1999; Byon et al., 2001; Phan et al., 2003; Phan & Peng, 2008; Costa Silva, 2010); AGMI induzida por campo magnético CA, observada em amostras GMI em forma de fio submetidas a um campo magnético CA helicoidal (Markhnovskty et al., 2000, 2001; Phan & Peng, 2008; Costa Silva, 2010) e AGMI induzida ao se aplicar um processo de recozimento (*annealing*), na presença de ar, em amostras GMI em forma de fita (Kim et al., 1999; Phan & Peng, 2008; Costa Silva, 2010).

Por meio da AGMI pode-se aumentar a sensibilidade de uma amostra GMI e conseqüentemente aumentar a sensibilidade do magnetômetro. No procedimento

de caracterização para obtenção dos dados experimentais, a AGMI foi induzida por meio de um componente CC na corrente de excitação.

1.3.6 Caracterização de Amostras GMI

A maximização da sensibilidade de um magnetômetro GMI está diretamente associada à otimização da sensibilidade de seus elementos sensores. Isto implica em maximizar as sensibilidades de módulo e/ou fase da impedância do efeito GMI em função do campo magnético aplicado, as quais são afetadas por diversos parâmetros, tais como:

- a) Amplitude da corrente CA de excitação.
- b) Frequência da componente CA da corrente de excitação.
- c) Nível CC da corrente de excitação.
- d) Dimensões da amostra: comprimento, largura e espessura.
- e) Composição física do material da amostra.
- f) Campo magnético de polarização.
- g) Temperatura do ambiente em que se localiza a amostra.

No entanto, essa dependência ainda não é bem modelada quantitativamente, e a busca do condicionamento ótimo é, usualmente, empírica (Costa Silva, 2010). Assim, o comportamento da impedância das amostras GMI deve ser experimentalmente analisado de forma a se verificar qual é o condicionamento que gera a sensibilidade ótima de módulo e/ou fase.

Os magnetômetros GMI até então desenvolvidos por pesquisadores de todo o mundo eram baseados nas características de módulo da impedância do efeito GMI. No entanto, pesquisas recentes verificaram que transdutores magnéticos baseados nas características de fase da impedância do efeito GMI têm o potencial de elevar os valores de sensibilidade em pelo menos 100 vezes, quando comparados àqueles baseados em módulo. De acordo com Costa Silva (2013), o nível de sensibilidade alcançado considerando as características da fase da impedância permite vislumbrar a aplicação de magnetômetros GMI na medição de campos magnéticos ultra-fracos. Por este motivo, o presente trabalho está baseado nas características de fase da impedância do efeito GMI para determinação do

condicionamento ótimo da amostra que leve à maximização de sua sensibilidade de fase.

1.4 Estruturação

O texto deste trabalho encontra-se organizado da seguinte forma:

- Neste capítulo introduzem-se os objetivos do trabalho e sua importância. Apresenta-se uma revisão dos conceitos básicos em Magnetismo bem como uma explicação detalhada do fenômeno da Magnetoimpedância Gigante (GMI);
- O capítulo 2 contém uma breve descrição das técnicas de inteligência computacional utilizadas neste trabalho. Apresentam-se os fundamentos teóricos de Redes Neurais Artificiais e são explicados os conceitos e o funcionamento dos Algoritmos Genéticos;
- O capítulo 3 apresenta detalhes do modelo computacional desenvolvido, baseado em Redes Neurais Artificiais e Algoritmos Genéticos. O modelo determina o condicionamento ótimo de amostras GMI, em forma de fita, de modo que a sensibilidade de fase da impedância do efeito GMI seja máxima;
- No capítulo 4 são introduzidos os estudos de caso utilizados na avaliação do modelo, bem como os resultados obtidos;
- No último capítulo, resumem-se as principais conclusões do trabalho e abordam-se possíveis trabalhos futuros, seguido da bibliografia utilizada.

2 Inteligência Computacional

2.1 Redes Neurais Artificiais

Uma Rede Neural Artificial é um modelo computacional não-linear inspirado na funcionalidade dos neurônios biológicos e na capacidade do cérebro humano de reconhecer, associar e generalizar padrões.

Uma definição formal de uma rede neural encontra-se em Haykin (2001): “Uma rede neural é um processador paralelo maciçamente distribuído sendo constituído por unidades de processamento simples, denominadas neurônios, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela é similar ao cérebro humano em dois aspectos: o conhecimento é adquirido pela rede, a partir de seu ambiente, através de um processo de aprendizado; e a intensidade das ligações entre os neurônios, conhecida como ponderação sináptica, é a forma usada para armazenar o conhecimento”.

As principais áreas de aplicação das redes neurais artificiais são classificação e reconhecimento de padrões, previsão de séries temporais e aproximação de funções. O diagrama de blocos da Figura 2.1 mostra o modelo de um neurônio artificial.




Figura 2.1 – Modelo de um neurônio artificial (Haykin, 2001).

Os componentes do modelo de um neurônio artificial são:

1. x_1, x_2, \dots, x_m : representam as entradas de um neurônio, que podem ser os padrões de entrada da rede ou a saída de um neurônio da camada anterior;
2. $w_{k1}, w_{k2}, \dots, w_{km}$: representam os pesos ou parâmetros da rede em analogia às sinapses de um modelo conexionista biológico, representando a força de ligação entre as unidades de processamento. Sinapses (conexões) com pesos positivos, chamadas excitatórias, indicam o reforço na ativação do neurônio, e sinapses com pesos negativos, chamadas inibitórias, indicam a inibição na ativação do neurônio;
3. v_k : soma ponderada das entradas pelos pesos;
4. b_k : termo polarizador (*bias*) que define o domínio dos valores de saída.
5. $\varphi(\cdot)$: função de ativação, responsável por restringir a amplitude do intervalo de saída do neurônio;
6. y_k : saída do k -ésimo neurônio que depende do nível de ativação aplicado ao neurônio pela função de ativação.

Matematicamente, um neurônio pode ser representado pela equação

$$y_k = \varphi(v_k) \quad (2.1)$$

onde

$$v_k = \left(\sum_{j=1}^m x_j \cdot w_{kj} \right) + b_k \quad (2.2)$$

2.1.1 Funções de Ativação

A função de ativação determina o valor do estado de ativação do neurônio artificial e de acordo com a sua não-linearidade irá restringir a amplitude do intervalo de saída do neurônio. As funções de ativação mais utilizadas, ilustradas pela Figura 2.2, são (Lorena, 2004):

a) Função linear (Figura 2.2a): utilizada principalmente em neurônios da camada de saída. É definida pela Equação (2.3).

$$f(x) = ax; \quad (2.3)$$

b) Função degrau (Figura 2.2b): é da forma

$$f(x) = \begin{cases} 1 & \text{se } x > 0 \\ 0 & \text{se } x \leq 0 \end{cases}; \quad (2.4)$$

c) Função sigmoide (Figura 2.2c): também chamada de função logística, é uma função contínua, estritamente crescente, que varia entre 0 e 1. Esta função é utilizada quando a saída prevista pela rede assume somente valores positivos. É definida pela Equação (2.5).

$$f(x) = \frac{1}{1 + e^{-x}}; \quad (2.5)$$

d) Função tangente hiperbólica (Figura 2.2d): esta função é geralmente utilizada quando é desejável que a função de ativação se estenda de -1 a +1, assumindo uma forma anti-simétrica em relação à origem e caso queira se manter a característica de uma função sigmoide. É aplicável quando a saída prevista pela rede pode assumir valores positivos e negativos, e definida pela Equação (2.6).

$$f(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (2.6)$$

A escolha da função de ativação pode influenciar fortemente o desempenho da rede neural e esta escolha é fortemente dependente das características dos dados que estão sendo tratados.




Figura 2.2 – Funções de ativação: (a) função linear. (b) função degrau. (c) função sigmoide e (d) tangente hiperbólica (Lorena, 2004).

2.1.2 Arquitetura de Rede

As redes neurais podem ser classificadas quanto a sua arquitetura em dois tipos: *não-recorrentes* e *recorrentes*.

Nas redes neurais *não-recorrentes* os neurônios estão estruturados em camadas e não existe realimentação do sinal de saída de um neurônio de volta para a entrada de outros neurônios. A estrutura dessas redes pode ser formada por uma única camada ou por múltiplas camadas. As redes com uma única camada possuem uma camada de entrada, responsável por distribuir os padrões pela rede, que se projeta sobre uma camada de saída. No caso de redes com múltiplas camadas existe uma ou mais camadas intermediárias (ocultas) entre as camadas de entrada e saída da rede. Nestas redes as entradas de um neurônio são as saídas dos neurônios da camada imediatamente anterior, não havendo conexões entre neurônios de uma mesma camada ou entre um neurônio de uma camada com outro de uma camada anterior. Desta forma, o sinal de entrada se propaga através da rede sempre da entrada para a saída, ou seja, a rede é estritamente do tipo alimentada adiante (*feedforward*). *Perceptron* e *Multilayer Perceptron* (MLP) são

exemplos de modelos de redes não-recorrentes. A Figura 2.3 ilustra uma rede MLP *feedforward* com uma camada oculta.




Figura 2.3 – Rede *feedforward* totalmente conectada com uma camada oculta e uma camada de saída (Haykin, 2001).

As redes neurais *recorrentes* diferem das redes não-recorrentes pelo fato de possuírem pelo menos um laço de realimentação, ou seja, o sinal de saída de um neurônio volta para a entrada de outros neurônios ou é realimentada para a sua própria entrada. Estas redes não possuem uma organização rígida e seus neurônios podem se ligar a qualquer outro neurônio da estrutura, seja de uma camada precedente ou da mesma camada (Haykin, 2001). A Figura 2.4 ilustra um exemplo de rede recorrente com neurônios ocultos.




Figura 2.4 – Rede recorrente com neurônios ocultos (Haykin, 2001).

2.1.3 Tipos de Aprendizado

Conforme mencionado anteriormente, as redes neurais têm a capacidade de adquirir conhecimento por meio de um processo de aprendizado. Segundo Haykin (2001), aprendizado no contexto de redes neurais é um processo pelo qual os parâmetros livres de uma RNA são adaptados por meio de um processo de estimulação do ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela forma através da qual é efetuada a mudança nos parâmetros.

O aprendizado em um modelo de redes neurais artificiais é decorrente do treinamento da rede pela apresentação de um conjunto de padrões às suas unidades visíveis. O objetivo do treinamento consiste em atribuir valores apropriados aos parâmetros livres da rede (pesos sinápticos e *bias*), de modo a produzir o conjunto de saídas desejado ou no mínimo consistente, de acordo com um erro estabelecido. O conhecimento obtido pelas redes neurais é armazenado em seus parâmetros livres. Os procedimentos de aprendizado são classificados em três tipos: aprendizado supervisionado, aprendizado não-supervisionado e aprendizado por reforço.

O aprendizado supervisionado, também chamado de aprendizado com professor, se baseia em um conjunto de exemplos de entrada/saída apresentados à rede, denominado conjunto de treinamento. A partir do vetor de entrada, a rede realiza o seu processamento e a resposta efetivamente obtida da rede é comparada com a resposta que a mesma deveria apresentar para este vetor do conjunto de treino. O erro encontrado é realimentado através da rede e os pesos são ajustados de acordo com um algoritmo determinado a fim de minimizar o erro ou torná-lo aceitável. O algoritmo de aprendizado supervisionado mais utilizado é o algoritmo de retropropagação (*Backpropagation*).

O aprendizado não-supervisionado ou auto-organizado não requer o conhecimento de saídas desejadas e a aprendizagem de padrões ocorre apenas com os valores de entrada fornecidos. Durante o treinamento, os pesos da rede são modificados de forma que vetores de entrada similares produzam o mesmo padrão nas saídas. O processo de treinamento implica no agrupamento dos padrões de entrada em grupos com características similares ou na criação de novos grupos

automaticamente. Os algoritmos de aprendizado não-supervisionado mais importantes são Algoritmo de Hopfield e Mapas de Kohonen (Haykin, 2001).

O aprendizado por reforço utiliza uma estrutura composta de estados, ações, punições e recompensas, sendo que o aprendizado se dá a partir da interação contínua do agente com o ambiente. O ambiente é descrito por um conjunto de estados e o agente pode executar, para cada estado, uma ação dentro de um conjunto de ações possíveis, recebendo do ambiente um valor de reforço em resposta a ação tomada. Este reforço indica o valor imediato da transição estado-ação-novo estado. A cada transição estado-ação-novo estado, o agente recebe um valor de reforço do ambiente. O objetivo do aprendizado é minimizar uma função de custo, definida como a expectativa do custo cumulativo de ações tomadas ao longo de uma sequência de passos, em vez de simplesmente do custo imediato (Haykin, 2001). O aprendizado por reforço, diferencia-se dos aprendizados supervisionado e não-supervisionado, por ser um aprendizado por interação.

2.1.4. Redes Multilayer Perceptron (MLP)

As redes MLP (*Multilayer Perceptron*) são um dos modelos mais conhecidos de Redes Neurais Artificiais. Estas redes são não-recorrentes, com alimentação adiante (*feedforward*) e compostas de uma camada de entrada, uma ou mais camadas escondidas (ocultas) e uma camada de saída. A Figura 2.5 mostra uma rede MLP com uma camada oculta.




Figura 2.5 – Rede MLP com uma camada escondida.

O modelo de cada neurônio da rede inclui uma função de ativação não-linear e diferenciável. Uma função não-linear muito utilizada é a função sigmóide (logística).

Os parâmetros a serem estimados em uma rede neural são os pesos sinápticos e os *bias*.

2.1.4.1 Treinamento

O algoritmo de treinamento mais utilizado em redes MLP é o *Backpropagation*, algoritmo de treinamento supervisionado que se baseia na aprendizagem por correção do erro. Ao se apresentar um conjunto de padrões de entrada-saída à rede neural, um conjunto de saída é obtido (resposta real da rede). A partir da saída produzida pela rede é calculado um erro, representando a diferença entre o valor obtido (resposta real da rede) e o valor desejado. Este erro é propagado para as camadas anteriores (retropropagação do erro) e cada neurônio tem seus pesos ajustados de modo a minimizar o erro calculado na próxima saída da rede. O algoritmo de ajuste dos pesos baseia-se no método do gradiente descendente (os ajustes dos pesos são proporcionais ao gradiente do erro). A frequência com que estes ajustes são feitos depende do tipo de treinamento, que pode ser por padrão (*on-line*) onde a atualização é realizada após cada padrão ser apresentado à rede ou por ciclo (*batch* ou lote) onde a atualização é realizada após todos os padrões do conjunto de treinamento serem apresentados à rede (Haykin, 2001).

Os critérios de parada para terminar o processo de aprendizado podem ser: quando o erro for menor do que um valor pré-determinado; quando a variação do erro for satisfatoriamente pequena sendo insuficiente para melhorar o desempenho da rede; e aplicação do conjunto de treinamento um número determinado de vezes, ou seja, baseado no número de épocas. É comum se observar na prática uma combinação dos critérios acima (Haykin, 2001).

2.2 Algoritmos Genéticos

Algoritmos Genéticos (AGs) são algoritmos probabilísticos que fornecem um mecanismo de busca paralela e adaptativa baseado no princípio Darwiniano de sobrevivência dos mais aptos e na reprodução genética (Goldberg, 1989). Os AGs são modelos computacionais que buscam uma melhor solução para um determinado problema, por meio da evolução de populações de soluções codificadas por cromossomas artificiais (Pacheco, 1999).

Em um AG, um cromossoma (indivíduo) é uma estrutura de dados que representa uma das possíveis soluções dentro do espaço de busca do problema. A busca pelo melhor indivíduo, dado que cada cromossoma possui uma medida de aptidão, definida por meio de uma função de avaliação, é feita da seguinte forma: a cada iteração do algoritmo (geração), a população de indivíduos é submetida a um processo evolucionário que envolve avaliação, seleção, recombinação sexual (*crossover*) e mutação. Os novos indivíduos (novos pontos no espaço de busca), gerados através de recombinação sexual (*crossover*) e mutação, são avaliados e reintroduzidos na população. A cada geração, a população evolui, de tal modo que os melhores indivíduos sobrevivem em detrimento dos piores (sobrevivência do mais apto). As iterações são executadas até que um critério de parada seja satisfeito, retornando-se os melhores indivíduos encontrados, que constituem a melhor solução para o problema.

Os AGs podem ser caracterizados pelos seguintes componentes:

- Representação das soluções
- Decodificação do cromossoma
- Avaliação
- Seleção
- Reprodução
- Operadores Genéticos
- População inicial
- Parâmetros e critérios de parada

As subseções seguintes apresentam um detalhamento de cada um dos componentes que caracterizam um AG.

2.2.1 Representações das Soluções

A representação das possíveis soluções do espaço de busca de um problema define a estrutura do cromossoma a ser manipulado pelo algoritmo. A representação do cromossoma depende do tipo de problema e deve ser capaz de representar todo o espaço de busca que se deseja investigar (Fogel, 1994; Michalewicz, 1996; Pacheco, 1999). Os principais tipos de representação são:

- Binária para problemas numéricos e inteiros.
- Real para problemas numéricos.
- Lista para problemas baseados em ordem
- Vetor para problemas de agrupamento.

2.2.2 Decodificação do Cromossoma

Os cromossomas representam possíveis soluções do problema. A decodificação do cromossoma consiste em obter uma solução real do problema para que esta seja avaliada por uma função que melhor represente o problema (Pacheco, 1999).

2.2.3 Avaliação

A avaliação é, em conjunto com a escolha da representação, o ponto do AG mais dependente do problema em si, pois é necessário que o AG seja capaz de responder sobre quão boa uma resposta é para o problema proposto.

A avaliação é feita por uma função que melhor representa o problema em si e tem por objetivo fornecer uma medida de aptidão de cada indivíduo da população corrente (Pacheco, 1999).

2.2.4 Seleção

A seleção é responsável pela perpetuação de boas características na população. É no processo de seleção que os indivíduos são escolhidos para posterior cruzamento. A seleção de indivíduos em um AG tenta imitar o processo

de seleção natural da evolução *Darwiniana* e é baseada na medida de aptidão do indivíduo. Os indivíduos mais aptos têm maior probabilidade de serem escolhidos para se reproduzirem. Esta aptidão é calculada a partir da função de avaliação de cada indivíduo, e determina quão apto ele está para a reprodução em relação à população a que pertence.

A seleção em AGs é tipicamente implementada por uma roleta onde cada indivíduo é representado por uma fatia proporcional a sua aptidão relativa (Fogel, 1994; Michalewicz, 1996; Mitchell, 1996; Pacheco, 1999).

2.2.5 Reprodução

O critério de substituição dos indivíduos de uma população para a próxima geração é definido pela técnica de reprodução empregada. Existem basicamente os seguintes métodos de reprodução (Fogel, 1994; Michalewicz, 1996; Mitchell, 1996; Pacheco, 1999):

1. **Troca de toda população:** a cada ciclo, todos os indivíduos da população corrente são substituídos por novos indivíduos.
2. **Troca de toda a população com elitismo:** Todos os cromossomas são substituídos, sendo o cromossoma mais apto da população corrente copiado para a população seguinte. A técnica de elitismo é um método para preservar os melhores indivíduos de uma geração na geração seguinte, evitando que a nova população se torne pior do que a população atual.
3. **Troca parcial da população (*steady state*):** os piores M indivíduos da população corrente são substituídos por novos indivíduos e os indivíduos mais aptos são preservados. O número de indivíduos a serem substituídos é conhecido como *GAP*.
4. **Troca parcial da população (*steady state*) sem duplicados:** os piores M indivíduos da população corrente são substituídos por novos indivíduos e os indivíduos mais aptos são preservados, sem, no entanto, permitir a presença de indivíduos duplicados, que são descartados da população.

2.2.6 Operadores Genéticos

O objetivo dos operadores genéticos é encontrar novos indivíduos que tenham alta probabilidade de causar melhorias significativas no desempenho do sistema. Dentre os operadores genéticos, os de cruzamento e mutação têm um papel fundamental em um AG.

O operador genético do tipo cruzamento (*crossover*) imita o processo biológico de reprodução sexuada. Indivíduos selecionados na população corrente são recombinados para geração de novos indivíduos. A Figura 2.6 ilustra um procedimento simples de cruzamento. Na operação de cruzamento, pares de indivíduos são escolhidos aleatoriamente da população, com base em suas aptidões, e novos indivíduos são criados a partir da troca do material genético. Os descendentes serão diferentes de seus pais, mas com características genéticas de ambos os genitores (Holland, 1975; Davis, 1990; Michalewicz, 1996; Mitchell, 1996; Pacheco, 1999). A operação de *crossover* é aplicada com uma dada probabilidade (p_c) denominada taxa de *crossover* (60% a 90%). Durante a aplicação do operador, é gerado um número aleatório entre 0 e 1 e, se este número for menor que a taxa de *crossover*, o operador é aplicado, caso contrário os descendentes são iguais aos genitores. Os operadores genéticos do tipo cruzamento mais conhecidos são:

- **Crossover de um ponto:** genitores têm seus cromossomas cortados em uma posição aleatória, gerando duas caudas e duas cabeças, que são recombinadas (Figura 2.6).




Figura 2.6 – Crossover de um ponto de corte (Cardoso, 1998).

- **Crossover multi-ponto:** é uma generalização do operador de um ponto. Executa a recombinação de dois indivíduos a partir de n pontos de corte escolhidos aleatoriamente (Figura 2.7).




Figura 2.7 – Crossover multi-ponto (Cardoso, 1998).

- **Crossover uniforme:** este operador é capaz de recombinar quaisquer posições entre dois genitores. Cada gene dos descendentes é criado copiando o gene correspondente de um dos pais conforme uma máscara (palavra binária) gerada aleatoriamente. O *crossover* uniforme é ilustrado na Figura 2.8.



Figura 2.8 – Crossover multi-ponto (Cardoso, 1998).

- **Crossover aritmético:** operador aplicado em cromossomas com representação real. Neste operador os cromossomos descendentes, F_1 e F_2 , são gerados a partir de uma combinação linear dos cromossomos-pai (P_1 e P_2). A combinação linear que gera os cromossomos filhos F_1 e F_2 é dada pelas Equações 2.7 e 2.8, respectivamente, onde α é um número aleatório entre 0 e 1.

$$F_1 = \alpha.P_1 + (1 - \alpha).P_2 \quad (2.7)$$

$$F_2 = \alpha.P_2 + (1 - \alpha).P_1 \quad (2.8)$$

A mutação, por sua vez, é um operador exploratório que tem por objetivo aumentar a diversidade da população (Davis, 1990; Michalewicz, 1996; Mitchell, 1996). Esta operação explora novas regiões do espaço de busca, fazendo com que o AG não fique preso a uma única região do espaço. A mutação opera sobre os indivíduos resultantes do processo de cruzamento e introduz uma mudança aleatória no indivíduo, por meio da troca do conteúdo de uma posição do cromossoma (gene). A operação de mutação é aplicada em cada gene do cromossoma com uma dada probabilidade (p_m) denominada taxa de mutação. Em geral, a taxa de mutação é baixa (menor do que 1%). Durante a aplicação do

operador, é gerado um número aleatório entre 0 e 1 e, se este número for menor que a taxa de mutação, o operador é aplicado, caso contrário mantém-se o valor do gene. A Figura 2.9 ilustra o processo de mutação em um cromossoma.




Figura 2.9 – Processo de mutação em um cromossoma (Cardoso, 1998).

Os principais operadores de mutação são:

- **Mutação por inversão de bit:** utilizada em cromossomas com representação binária, este operador altera aleatoriamente um determinado bit de um gene de 0 para 1 ou de 1 para 0, com uma probabilidade p_m .
- **Mutação de real:** aplicada em cromossomas com representação real. Substitui cada número real em um cromossoma por um número real aleatório.
- **Mutação *creep*:** aplicada em cromossomas cuja representação é real. Um pequeno valor aleatório obtido de uma distribuição uniforme ou normal é somado ou subtraído do valor do gene. Este operador é menos destrutivo que os anteriores e é usado para explorar localmente o espaço de busca.

2.2.7 População Inicial

A geração da população inicial define os indivíduos que participarão do primeiro ciclo do AG. Os indivíduos da população inicial podem ser gerados aleatoriamente dentro do espaço de busca ou por meio de um processo heurístico. Assim como na natureza, para haver evolução é necessário que haja diversidade, e, portanto, é importante que a população inicial cubra a maior área possível do espaço de busca.

2.2.8 Parâmetros e Critérios de Parada

Em um AG, o processo de evolução é influenciado por vários parâmetros (Pacheco, 1999):

- **Tamanho da População:** número de indivíduos da população.
- **Taxa de *Crossover*:** probabilidade (p_c) de um indivíduo ser re combinado com outro.
- **Taxa de Mutação:** probabilidade (p_m) do conteúdo de uma posição do cromossoma (gene) ser alterado.
- **Número de Gerações:** total de ciclos de evolução de um AG.
- **Total de Indivíduos:** total de indivíduos avaliados em uma execução do AG, ou seja, número de indivíduos da população multiplicado pelo número de gerações que o algoritmo irá executar.

O tamanho da população afeta o desempenho global e a eficiência do AG. Com uma pequena população tem-se uma pequena cobertura do espaço de busca do problema, o que pode levar a soluções locais. Por outro lado, com uma população grande, embora se tenha uma cobertura representativa do domínio do problema, aumenta-se o total de indivíduos a serem avaliados pelo AG, requerendo um maior esforço computacional.

Por sua vez, uma taxa de cruzamento muito alta implica na substituição da maior parte da população e na possibilidade de perderem-se indivíduos com alta aptidão. Entretanto, uma taxa pequena, faz com que novos indivíduos sejam introduzidos mais lentamente na população, podendo tornar o algoritmo mais lento na determinação da solução global.

Já, uma taxa de mutação muito alta, torna a busca pela melhor solução essencialmente aleatória, além de possibilitar que uma boa solução seja destruída em função da troca do conteúdo de uma dada posição do cromossoma. A melhor taxa de mutação é dependente da aplicação, mas, na maioria dos casos, está entre 0,001 e 0,1.

Em geral, os parâmetros empregados como critério de parada de um AG são número de gerações e total de indivíduos (Pacheco, 1999).

3

Modelo Computacional para Otimização da Sensibilidade de Amostras GMI

Neste trabalho, foi desenvolvido um modelo computacional baseado em Redes Neurais MLP e Algoritmos Genéticos para determinar o condicionamento ótimo de amostras GMI de modo a maximizar sua sensibilidade e permitir o desenvolvimento de magnetômetros GMI de elevada sensibilidade.

Os magnetômetros GMI até então desenvolvidos por pesquisadores de todo o mundo eram baseados nas características de módulo da impedância do efeito GMI. No entanto, pesquisas recentes verificaram que transdutores magnéticos baseados nas características de fase da impedância do efeito GMI têm o potencial de elevar os valores de sensibilidade em pelo menos 100 vezes, quando comparados àqueles baseados em módulo. Assim, determinar o condicionamento ótimo da amostra que leve à maximização de sua sensibilidade, permite vislumbrar a aplicação deste tipo de transdutor na medição de campos magnéticos ultra-fracos. A sensibilidade, por sua vez, é afetada por diversos parâmetros, sendo que, no caso das fitas GMI analisadas, por meio de avaliações empíricas determinou-se o conjunto de variáveis que mais afetam sua impedância: comprimento das amostras, nível CC e frequência da corrente de excitação, além do campo magnético externo.

As Redes Neurais MLP modelam a fase da impedância do efeito GMI (saída das redes) em função destas quatro variáveis de interesse.

O Algoritmo Genético é responsável pela otimização da sensibilidade de fase da amostra e determinação do seu condicionamento ótimo, usando as RNAs como simuladores das fitas GMI.

3.1

Dados Experimentais

Os dados experimentais de fase da impedância do efeito GMI em função do campo magnético externo, aplicado longitudinalmente ao comprimento das amostras, foram medidos pelo Laboratório de Biometrologia (LaBioMet) da PUC-Rio a partir de amostras GMI em forma de fita com composição

$\text{Co}_{70}\text{Fe}_5\text{Si}_{15}\text{B}_{10}$, espessura média de 60 μm , largura de 1,5 mm e comprimentos de 1 cm, 3 cm, 5 cm e 15 cm. As análises foram realizadas para correntes CC variando entre 0 mA e 100 mA, frequências de 75 kHz a 30 MHz e campo magnético externo entre -5,0 Oe e 5,0 Oe.

O total de dados experimentais obtido foi de 49475 pontos. A Tabela 3.1 apresenta o total de dados experimentais por comprimento de fita GMI.

Tabela 3.1 – Total de dados experimentais por comprimento de fita GMI.

<i>Comprimento de fita (cm)</i>	<i>Dados</i>
<i>1</i>	<i>492</i>
<i>3</i>	<i>9660</i>
<i>5</i>	<i>38696</i>
<i>15</i>	<i>627</i>

Os dados experimentais utilizados na presente dissertação são provenientes de medições realizadas por Costa Silva (2010) durante os estudos do seu mestrado. Como pode-se observar, os dados fornecidos não apresentam uma homogeneidade, em termos quantitativos, por comprimento de fita (78% dos dados experimentais são de medições com fitas GMI de comprimento 5 cm enquanto que apenas 2% são de medições com fitas de comprimentos 1 cm e 15 cm). Essa não uniformidade, em termos quantitativos, pode, de certa forma, interferir no processo de aprendizado da rede neural (no caso da rede MLP que tem o comprimento da fita como parâmetro de entrada), pois o número reduzido de padrões de 1 cm e 15 cm em relação ao de 5 cm pode levar a rede a não conseguir extrair o conhecimento necessário para modelar o comportamento da fase da impedância de fitas de comprimentos 1 cm e 15 cm (os dados podem não ser suficientes e representativos para que o conhecimento seja extraído e o aprendizado da RNA aconteça com sucesso). É importante frisar que a coleta de dados feita por Costa Silva (2010) não foi para esta finalidade e portanto, não se tinha a necessidade da quantidade de dados ser a mesma para cada comprimento de fita.

Os dados fornecidos pelo Laboratório de Biometrologia (LaBioMet) da PUC-Rio foram obtidos a partir de medições cujo procedimento experimental é detalhado a seguir (Costa Silva, 2010).

A fita GMI é colocada no centro de uma Bobina de Helmholtz (Figura 3.1), de forma que o campo gerado pela bobina seja longitudinal ao comprimento da fita. O conjunto fita-bobina é posicionado de forma a garantir que a direção do campo magnético da Terra seja perpendicular ao comprimento da fita. Desta forma, minimiza-se a influência deste nas medições (as fitas GMI utilizadas são do tipo LMI, ou seja, a sensibilidade a campos perpendiculares às mesmas é muito baixa) (Phan & Peng, 2008; Costa Silva, 2009d, 2011a, b).

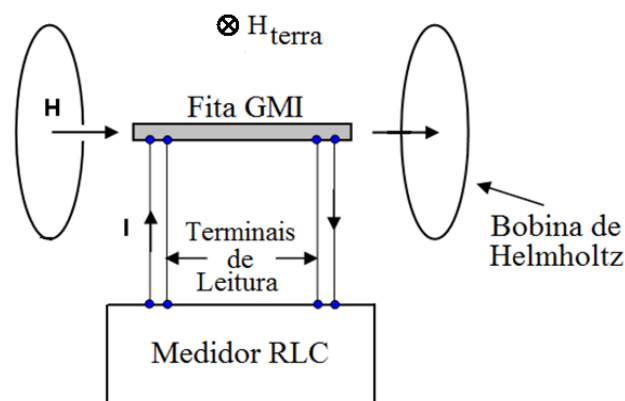


Figura 3.1 – Diagrama de blocos do sistema utilizado na obtenção dos dados experimentais (Costa Silva, 2010).

A técnica de soldagem empregada objetivando a conexão das extremidades da fita GMI aos terminais elétricos foi a solda de ponto. Por sua vez, os fios condutores são soldados aos terminais elétricos por solda de Estanho-Chumbo.

A corrente de condicionamento (ou excitação) i_c , utilizada para condicionar as amostras GMI, é definida por

$$i_c = I_{cc} + I_{ca} \text{sen}(2\pi ft) \quad (3.1)$$

onde I_{cc} é o nível CC da corrente i_c , I_{ca} é a amplitude e f é a frequência da componente alternada (CA) de i_c . A amplitude da corrente CA de excitação foi mantida fixa em 15 mA em todas as medições, em virtude de ter se verificado que sua variação pouco afeta o comportamento da fase da impedância.

As medições da fase da impedância foram realizadas com auxílio de um Medidor RLC (4285A, Agilent), o qual também foi o responsável pelo condicionamento (CC e CA) das fitas.

As variações do campo magnético gerado pela bobina de Helmholtz foram controladas por uma fonte de corrente CC, de acordo com,

$$H = \frac{8NI}{5\sqrt{5}R} \quad (3.2)$$

onde H é a magnitude do campo magnético no centro das bobinas, I é a corrente CC que percorre as espiras, N é o número total de espiras em cada bobina e R é o raio das bobinas.

A bobina de Helmholtz disponível no LaBioMet (PUC-Rio) possui 48 espiras em cada bobina e um raio de 15 cm. Logo, o campo magnético em oersteds, $H[\text{Oe}]$, no centro da bobina de Helmholtz, em função da corrente em amperes, $I[\text{A}]$, que a atravessa, é dado por

$$H[\text{Oe}] = 2,87 \cdot I[\text{A}] \quad (3.3)$$

A Figura 3.2 apresenta a bobina de Helmholtz utilizada no processo de medição, com uma fita GMI em seu centro.




Figura 3.2 – Bobina de Helmholtz com a fita GMI posicionada em seu centro (Costa Silva, 2010).

Outro ponto a considerar é o fato das variáveis de interesse terem uma distribuição não uniforme. Isto é evidenciado pelos respectivos histogramas. Nas

Figuras 3.3 até 3.14 são apresentados os histogramas de cada uma das variáveis de interesse por comprimento de fita.

Os histogramas destas variáveis para o comprimento de fita 1 cm constam das Figuras 3.3 até 3.5.

A Figura 3.3 apresenta o histograma do nível CC da corrente de condicionamento. Medições com nível CC de 80 mA correspondem a 42% do total, enquanto que com 0 mA, 25%. Os demais valores contabilizam 8% cada um.




Figura 3.3 – Histograma do nível CC da corrente de condicionamento (comprimento de fita 1 cm).

A Figura 3.4 apresenta o histograma da frequência da corrente de condicionamento. Medições com frequência de 100 kHz correspondem a 50% do total, enquanto que com 1 MHz, 17%.

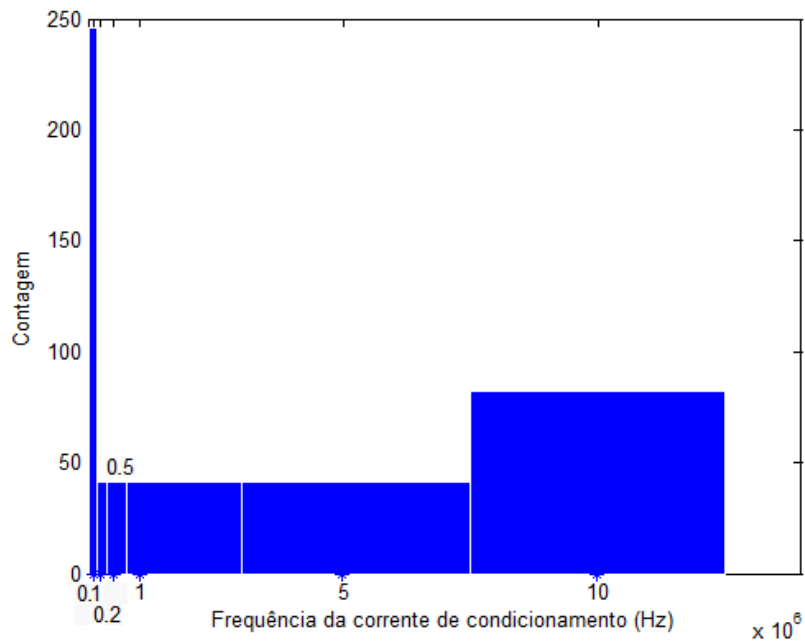


Figura 3.4 – Histograma da frequência da corrente de condicionamento (comprimento de fita 1 cm).

A Figura 3.5 exibe o histograma do campo magnético externo. Diferentemente das duas variáveis anteriores, observa-se que esta variável está uniformemente distribuída no intervalo entre -5,0 Oe e 5,0 Oe. Isto é facilmente explicado pelo processo de caracterização empregado, que varia sistematicamente o campo magnético aplicado pela bobina de Helmholtz.

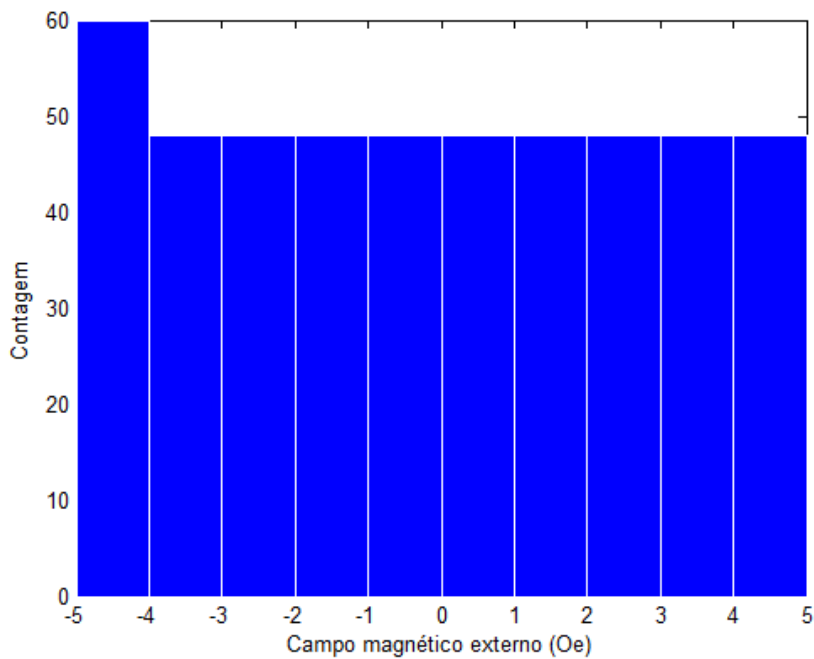


Figura 3.5 – Histograma do campo magnético externo (comprimento de fita 1 cm).

As Figuras 3.6 até 3.8 apresentam o histograma destas mesmas variáveis para o comprimento de fita 3 cm.

A Figura 3.6 apresenta o histograma do nível CC da corrente de condicionamento. Medições com nível CC de 80 mA representam 98% do total.

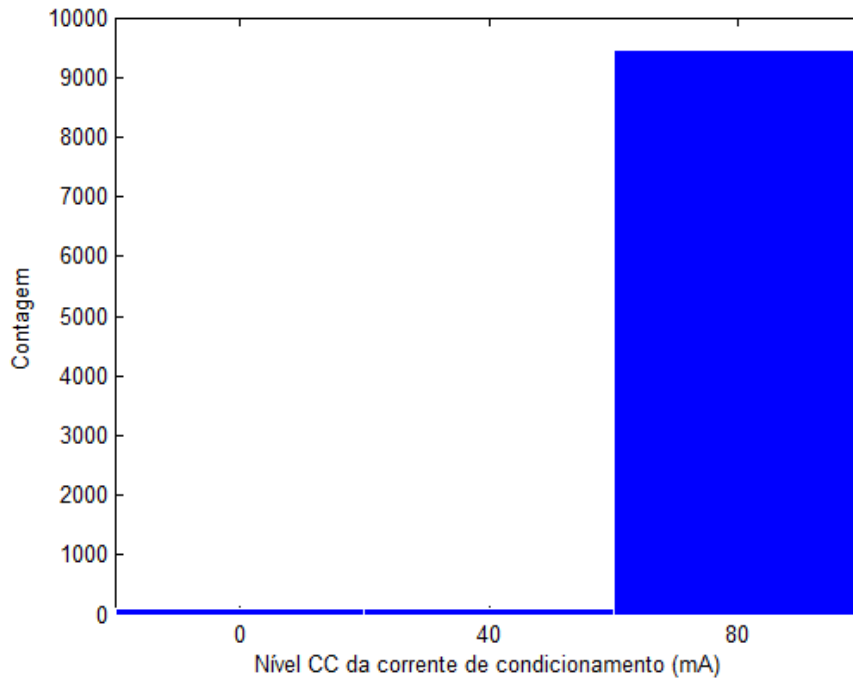


Figura 3.6 – Histograma do nível CC da corrente de condicionamento (comprimento de fita 3 cm).

A Figura 3.7 apresenta o histograma da frequência da corrente de condicionamento. Medições com frequência entre 75 kHz e 1 MHz representam 80% do total.

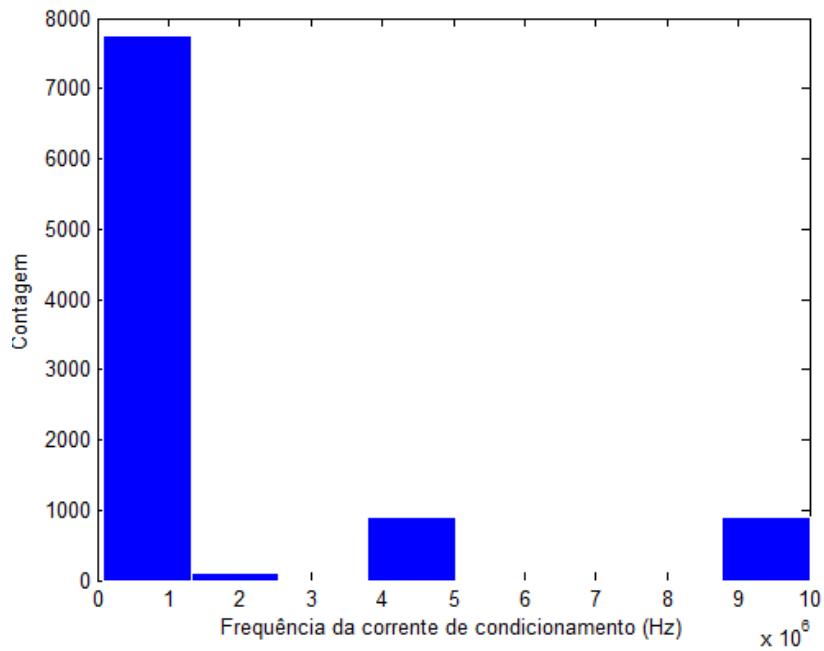


Figura 3.7 – Histograma da frequência da corrente de condicionamento (comprimento de fita 3 cm).

A Figura 3.8 apresenta o histograma do campo magnético externo. Medições com campo magnético externo entre -2,0 Oe e 2,0 Oe correspondem a 77% do total.




Figura 3.8 – Histograma do campo magnético externo (comprimento de fita 3 cm).

As Figuras 3.9 até 3.11 apresentam o histograma das variáveis em referência para o comprimento de fita 5 cm.

A Figura 3.9 apresenta o histograma do nível CC da corrente de condicionamento. Medições com nível CC de 80 mA representam cerca de 99% do total.

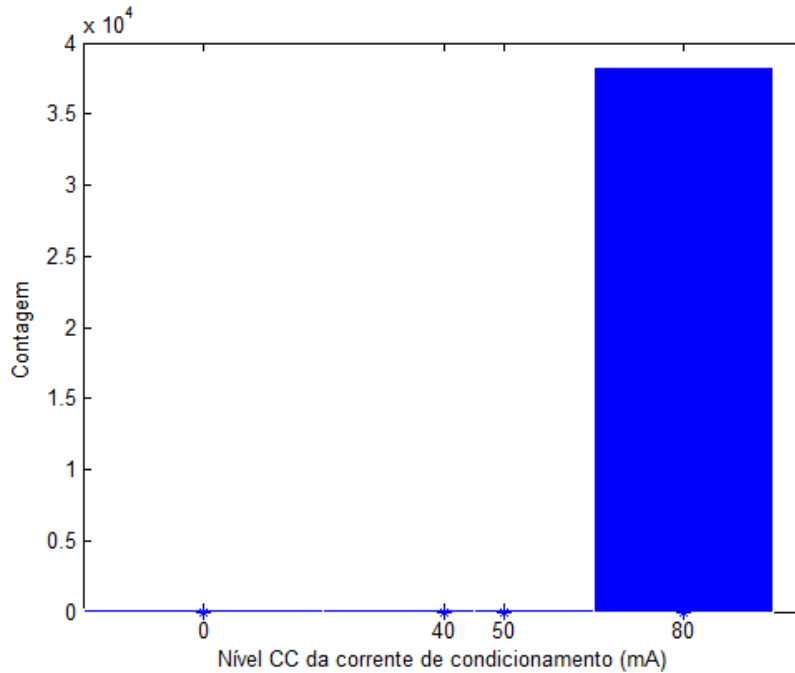


Figura 3.9 – Histograma do nível CC da corrente de condicionamento (comprimento de fita 5 cm).

A Figura 3.10 apresenta o histograma da frequência da corrente de condicionamento. Medições com frequência entre 90 kHz e 1,0 MHz correspondem a 56% do total e entre 1,0 MHz e 2,0 MHz, 43%.

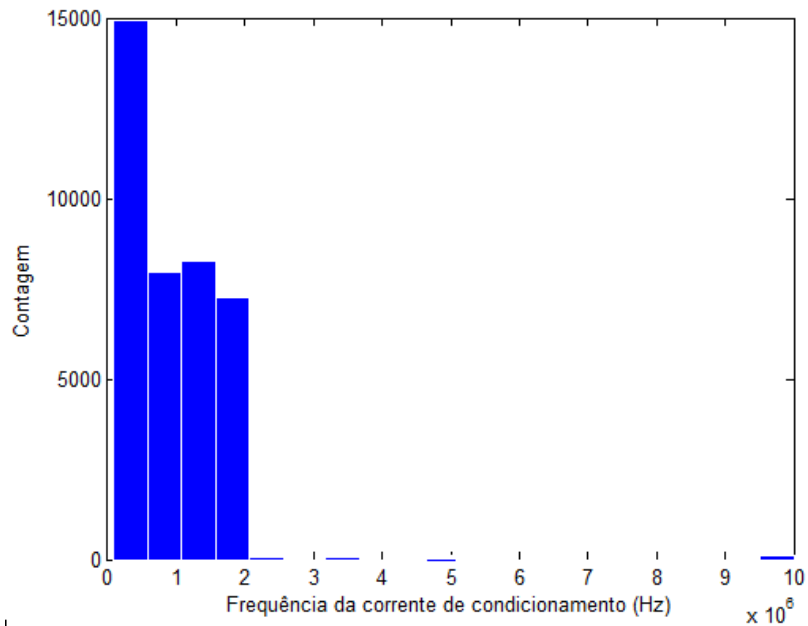


Figura 3.10 – Histograma da frequência da corrente de condicionamento (comprimento de fita 5 cm).

A Figura 3.11 exibe o histograma do campo magnético externo. Como no caso da fita de 1 cm, observa-se que esta variável apresenta uma distribuição uniforme.




Figura 3.11 – Histograma do campo magnético externo (comprimento de fita 5 cm).

As Figuras 3.12 até 3.14 ilustram o histograma das variáveis em referência para o comprimento de fita 15 cm.

A Figura 3.12 apresenta o histograma do nível CC da corrente de condicionamento. Medições com nível CC de 0 mA representam cerca de 32% do total, 80 mA, 26%, 40 mA e 100 mA, 16% cada.




Figura 3.12 – Histograma do nível CC da corrente de condicionamento (comprimento de fita 15 cm).

A Figura 3.13 apresenta o histograma da frequência da corrente de condicionamento. Medições com frequência entre 100 kHz e 2 MHz correspondem a 47% do total, 5 MHz, 16%, e 10 MHz, 21%.

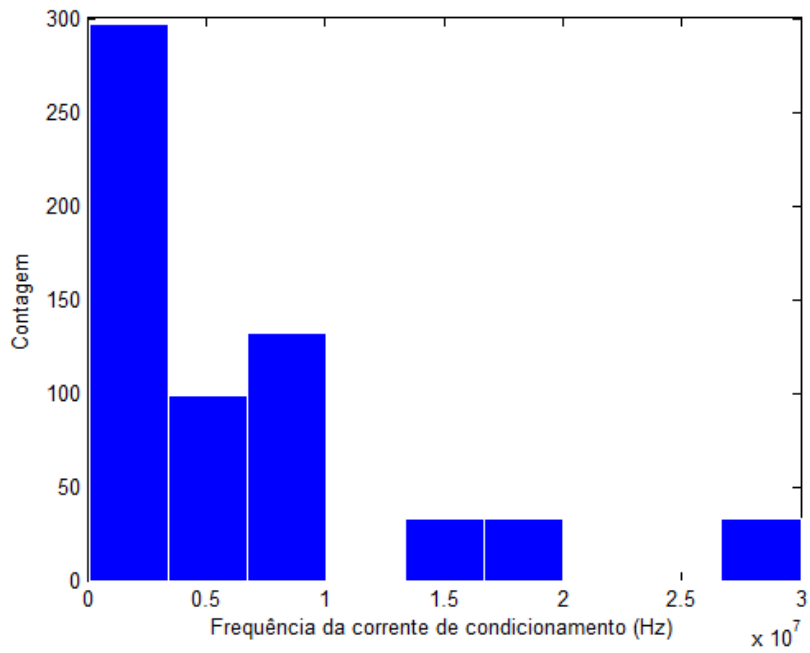


Figura 3.13 – Histograma da frequência da corrente de condicionamento (comprimento de fita 15 cm).

A Figura 3.14 exhibe o histograma do campo magnético externo. Como nos casos anteriores de 1 cm e 3 cm, observa-se que esta variável está uniformemente distribuída no intervalo entre -1,5 Oe e 1,5 Oe.

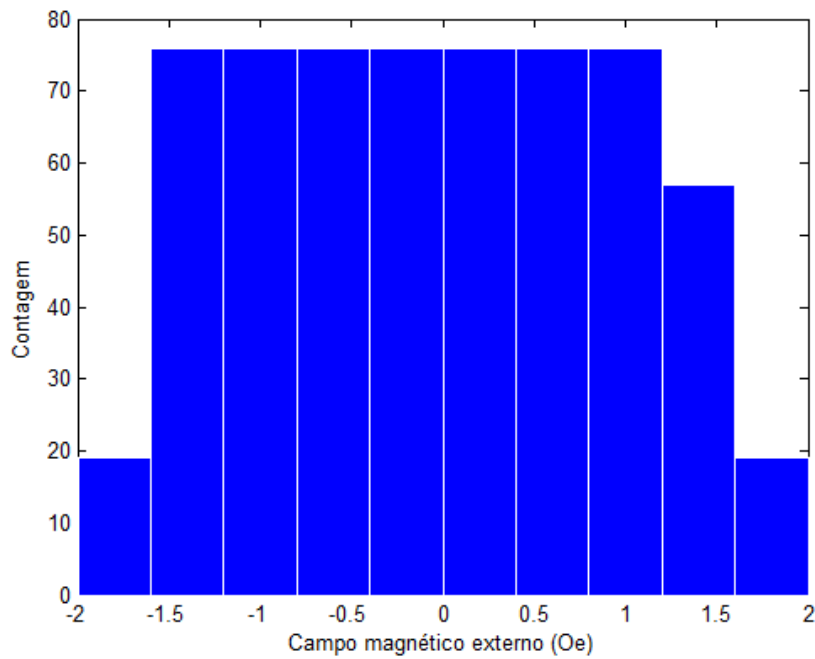


Figura 3.14 – Histograma do campo magnético externo (comprimento de fita 15 cm).

As Figuras 3.15 até 3.17 exibem os histogramas destas mesmas variáveis, independentemente do comprimento de fita. Observa-se que todas as variáveis apresentam uma distribuição não uniforme.

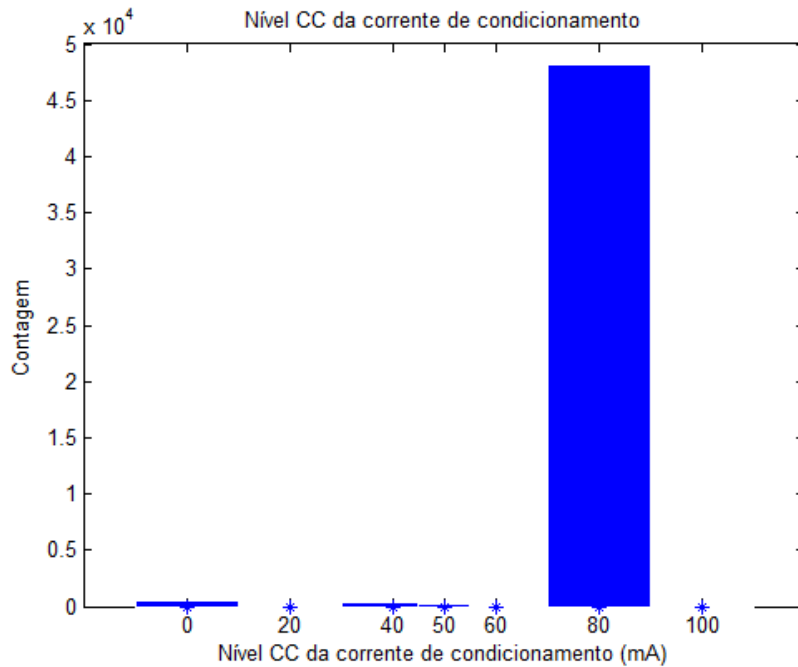


Figura 3.15 – Histograma do nível CC da corrente de condicionamento.

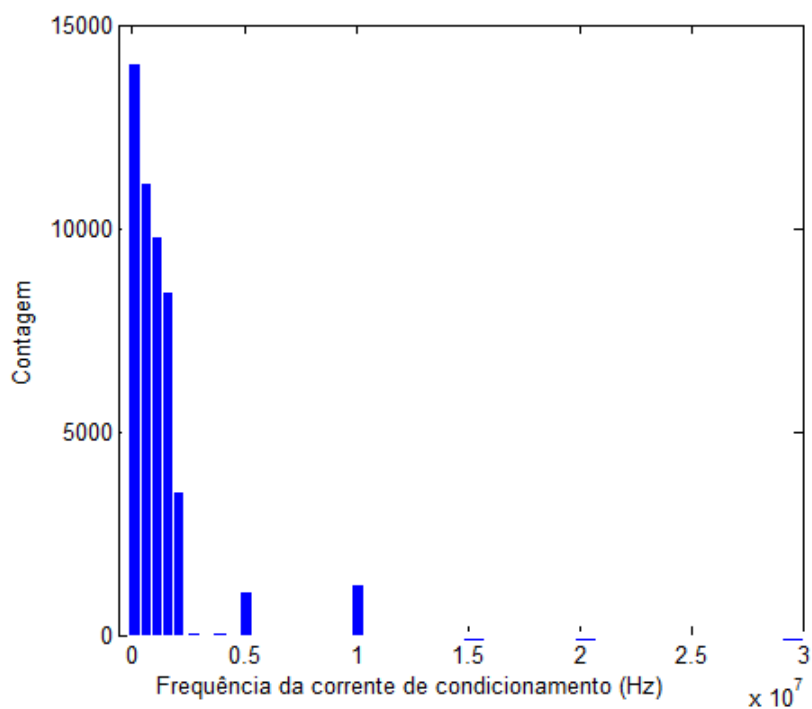


Figura 3.16 – Histograma da frequência da corrente de condicionamento.




Figura 3.17 – Histograma do campo magnético externo.

Conforme Costa Silva (2010), as curvas experimentais de caracterização da fase da impedância das amostras GMI em função do campo magnético externo foram levantadas considerando-se a histerese. As medições começam na situação em que a componente do campo magnético paralela à fita é nula ($H_{início} = 0$). Em seguida, aumenta-se o campo até um valor máximo ($H_{máx}$) e, na sequência, reduz-se o campo, passando por $H_{início} = 0$, até um valor mínimo $H_{min} = -H_{máx}$. Finalmente, a fim de completar o ciclo de histerese, percorre-se o trajeto de H_{min} a $H_{início}$. Dessa forma, para cada valor do campo magnético tem-se dois valores de fase, exceto para os extremos da curva $H_{máx}$ e H_{min} , para os quais tem-se apenas um valor de fase, e para $H_{início}$, onde se obtêm 3 valores de fase. A Figura 3.18 exemplifica a curva de histerese.

Assim, as curvas de caracterização apresentadas nesse capítulo são a “curva média de histerese” conforme indicado na Figura 3.18. Esta curva é obtida ponto-a-ponto fazendo-se as médias aritméticas dos valores de fase, obtidos experimentalmente para um mesmo valor do campo magnético externo.

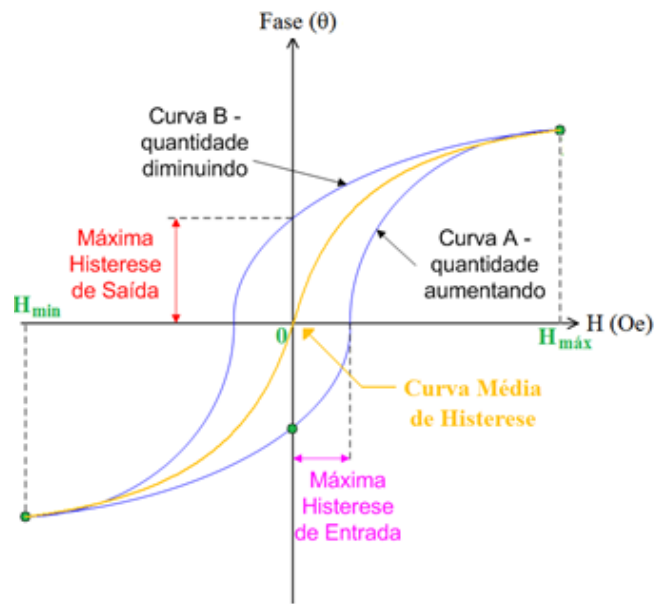


Figura 3.18 – Curva de Histerese (Costa Silva, 2010).

As Figuras 3.19 a 3.26 apresentam as curvas de caracterização da fase da impedância (θ) em função do campo magnético externo (H) aplicado longitudinalmente ao comprimento da amostra GMI (“curvas média de histerese”). Estas figuras representam casos particulares, dentre as diversas combinações possíveis de parâmetros analisadas experimentalmente.

A Figura 3.19 exibe a curva de caracterização da fase da impedância (θ) em função do campo magnético externo (H) para uma fita GMI de comprimento 1 cm condicionada por uma corrente de nível CC de 80 mA, frequência de 500 kHz e campo magnético variando entre -5,0 Oe e 5,0 Oe, em incrementos de 0,25 Oe.




Figura 3.19 – Fase da impedância em função do campo magnético externo para uma fita GMI de comprimento 1 cm submetida a uma corrente de nível CC de 80 mA e frequência de 500 kHz.

A Figura 3.20, por sua vez, apresenta a curva de caracterização da fase da impedância (θ) em função do campo magnético externo (H) para uma fita GMI de comprimento 1 cm condicionada por uma corrente de nível CC de 40 mA, frequência de 100 kHz e campo magnético variando entre -5,0 Oe e 5,0 Oe, em incrementos de 0,25 Oe.




Figura 3.20 – Fase da impedância em função do campo magnético externo para uma fita GMI de comprimento 1 cm submetida a uma corrente de nível CC de 40 mA e frequência de 100 kHz.

A Figura 3.21 exibe a curva de caracterização da fase da impedância (θ) em função do campo magnético externo (H) para uma fita GMI de comprimento 3 cm

condicionada por uma corrente de nível CC de 80 mA, frequência de 300 kHz e campo magnético variando entre -5,0 Oe e 5,0 Oe, em incrementos de 0,1 Oe.




Figura 3.21 – Fase da impedância em função do campo magnético externo para uma fita GMI de comprimento 3 cm submetida a uma corrente de nível CC de 80 mA e frequência de 300 kHz.

A Figura 3.22, por sua vez, apresenta a curva de caracterização da fase da impedância (θ) em função do campo magnético externo (H) para uma fita GMI de comprimento 3 cm condicionada por uma corrente de nível CC de 40 mA, frequência de 2 MHz e campo magnético variando entre -2,0 Oe e 2,0 Oe, em incrementos de 0,1 Oe.




Figura 3.22 – Fase da impedância em função do campo magnético externo para uma fita GMI de comprimento 3 cm submetida a uma corrente de nível CC de 40 mA e frequência de 2 MHz.

A Figura 3.23 exibe a curva de caracterização da fase da impedância (θ) em função do campo magnético externo (H) para uma fita GMI de comprimento 5 cm condicionada por uma corrente de nível CC de 80 mA, frequência de 3,5 MHz e campo magnético variando entre -2,0 Oe e 2,0 Oe, em incrementos de 0,1 Oe.




Figura 3.23 – Fase da impedância em função do campo magnético externo para uma fita GMI de comprimento 5 cm submetida a uma corrente de nível CC de 80 mA e frequência de 3,5 MHz.

A Figura 3.24, por sua vez, apresenta a curva de caracterização da fase da impedância (θ) em função do campo magnético externo (H) para uma fita GMI de comprimento 5 cm condicionada por uma corrente de nível CC de 50 mA, frequência de 99 kHz e campo magnético variando entre -2,0 Oe e 2,0 Oe, em incrementos de 0,05 Oe. O comportamento desta curva de caracterização é devido ao fato de haver mais de uma medida de fase para uma mesmo valor de campo magnético. É importante frisar que nenhum padrão foi descartado para fins de treinamento das redes neurais.




Figura 3.24 – Fase da impedância em função do campo magnético externo para uma fita GMI de comprimento 5 cm submetida a uma corrente de nível CC de 50 mA e frequência de 99 kHz.

A Figura 3.25 exibe a curva de caracterização da fase da impedância (θ) em função do campo magnético externo (H) para uma fita GMI de comprimento 15 cm condicionada por uma corrente de nível CC de 100 mA, frequência de 10 MHz e campo magnético variando entre -2,0 Oe e 2,0 Oe, em incrementos de 0,1 Oe.




Figura 3.25 – Fase da impedância em função do campo magnético externo para uma fita GMI de comprimento 15 cm submetida a uma corrente de nível CC de 100 mA e frequência de 10 MHz.

A Figura 3.26, por sua vez, apresenta a curva de caracterização da fase da impedância (θ) em função do campo magnético externo (H) para uma fita GMI de

comprimento 15 cm condicionada por uma corrente de nível CC de 0 mA, frequência de 500 kHz e campo magnético variando entre -2,0 Oe e 2,0 Oe, em incrementos de 0,1 Oe.




Figura 3.26 – Fase da impedância em função do campo magnético externo para uma fita GMI de comprimento 15 cm submetida a uma corrente de nível CC de 0 mA e frequência de 500 kHz.

Observa-se pelos gráficos que, ao se variarem os parâmetros de condicionamento das amostras GMI, o comportamento da curva da fase da impedância em função do campo magnético é drasticamente alterado.

A sensibilidade de fase, S_{fas} , definida pela Equação (3.4), é função da fase da impedância e, portanto, a variação dos parâmetros de condicionamento implica na variação da sensibilidade.

$$S_{fas} = \frac{d\theta(H)}{dH} \quad (3.4)$$

Com o objetivo de se otimizar a sensibilidade de amostras GMI em função dos parâmetros que a influenciam foram desenvolvidos dois modelos computacionais baseados em Redes Neurais Artificiais *Multilayer Perceptron* e Algoritmo Genético.

A Rede Neural é responsável pela modelagem da fase da impedância do efeito GMI em função dos seguintes parâmetros de interesse: comprimento das amostras, nível CC e frequência da corrente de excitação, além do campo magnético externo.

O Algoritmo Genético, responsável pela otimização da sensibilidade de fase da amostra GMI, determina o condicionamento ótimo da amostra de modo que sua sensibilidade seja máxima. A função de avaliação do AG foi definida como sendo a maximização da derivada da fase da impedância do efeito GMI em relação ao campo magnético externo. O cálculo da derivada é realizado por diferenciação numérica, utilizando aproximação por diferenças centrais.

O primeiro modelo é constituído por quatro redes neurais, uma para cada comprimento de fita GMI, a saber, 1 cm, 3 cm, 5 cm e 15 cm, que são referenciadas pelo AG. Este modelo é retratado na Figura 3.27. Cada uma destas redes neurais tem como variáveis de entrada: frequência e nível CC da corrente de excitação, além do campo magnético externo aplicado. Este modelo restringe a otimização da sensibilidade de fase a amostras GMI, em forma de fita, cujos comprimentos sejam um dos acima especificados. A Figura 3.28 apresenta, em detalhes, cada uma das redes neurais MLP utilizadas para modelar o comportamento da fase da impedância do efeito GMI de fitas de comprimentos 1 cm, 3 cm, 5 cm e 15 cm.

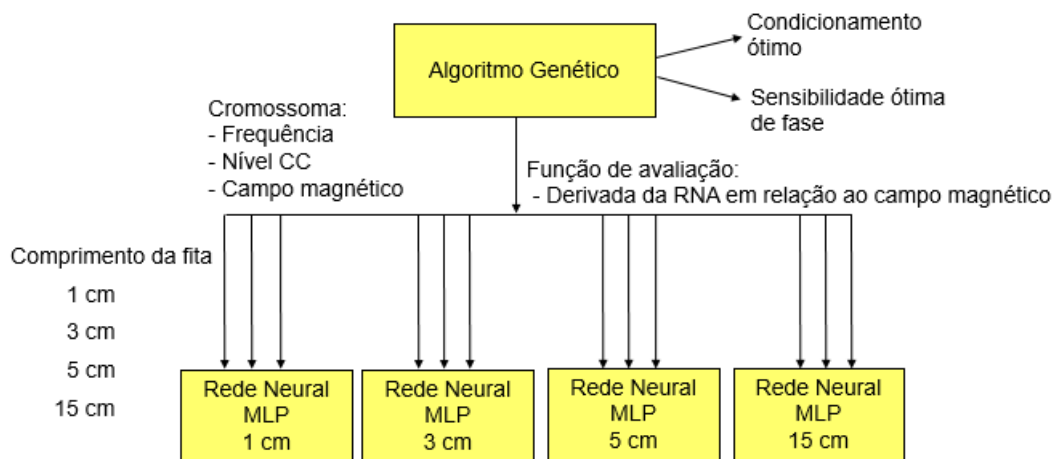


Figura 3.27 – Representação do modelo computacional baseado em quatro redes neurais MLP.

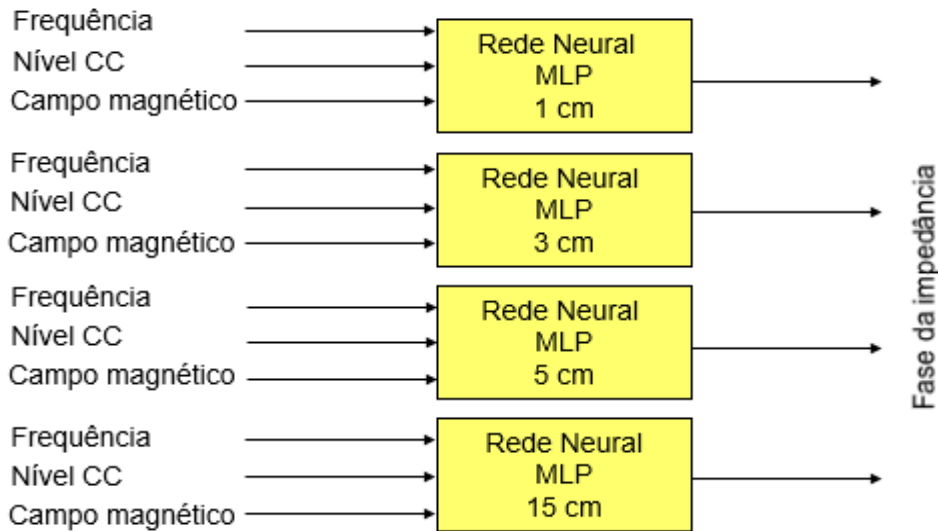


Figura 3.28 – Representação das redes neurais MLP utilizadas para modelar o comportamento da fase da impedância de amostras GMI, em forma de fita, de comprimentos 1 cm, 3 cm, 5 cm e 15 cm.

O segundo modelo, por sua vez, é constituído por uma única rede neural, com as seguintes variáveis de interesse (entradas da rede): comprimento da fita, nível CC e frequência da corrente de excitação, além do campo magnético externo aplicado. Esta rede é referenciada pelo AG durante o processo de otimização. Este modelo é retratado na Figura 3.29. Esta abordagem, diferentemente da anterior, não está restrita a comprimentos específicos de fitas GMI, devido ao fato do comprimento da fita ser uma das entradas da rede. A Figura 3.30 ilustra a rede neural MLP utilizada para modelar o comportamento da fase da impedância de amostras GMI em forma de fita.

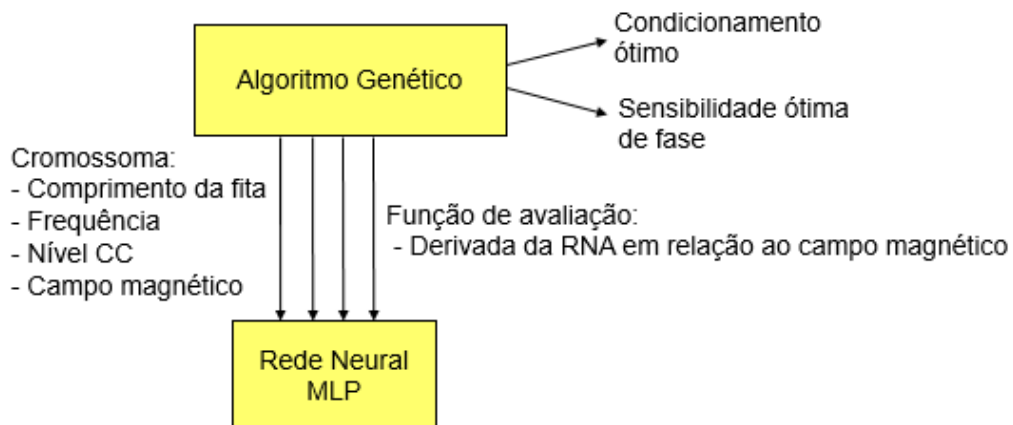


Figura 3.29 – Representação do modelo computacional baseado em uma única rede neural MLP.




Figura 3.30 – Representação da rede neural MLP utilizada para modelar o comportamento da fase da impedância de amostras GMI em forma de fita.

3.2 Desenvolvimento das Redes Neurais

Conforme descrito na seção anterior, foram implementados dois modelos computacionais neurogenéticos. O primeiro modelo é constituído por quatro redes neurais MLP. Cada rede modela o comportamento da fase da impedância do efeito GMI de uma amostra de comprimento específico a saber: 1 cm, 3 cm, 5 cm e 15 cm. Estas redes têm como variáveis de entrada: nível CC e frequência da corrente de excitação além do campo magnético externo aplicado. O segundo modelo, por sua vez, é constituído por uma única rede neural com as seguintes variáveis de interesse: comprimento das amostras, nível CC e frequência da corrente de excitação além do campo magnético externo aplicado. Em ambos os modelos, a variável de saída das redes neurais é a fase da impedância do efeito GMI. Diversas topologias foram analisadas para determinação da rede com melhor capacidade de generalização.

3.2.1 Normalização

Em redes neurais artificiais, a normalização das variáveis de entrada e saída da rede neural é um aspecto importante a ser considerado. O propósito da normalização é minimizar os problemas oriundos de dispersões distintas entre as variáveis de interesse e ajustar as escalas de valores dos atributos para um mesmo intervalo. Nas regras de normalização definidas pelas Equações 3.5, 3.6 e 3.7, a seguir, x é o valor do dado analisado, x_{max} e x_{min} são os valores máximo e mínimo

do conjunto amostral referente à variável x , respectivamente, e y é o dado normalizado.

As variáveis comprimento das amostras GMI, nível CC e frequência da corrente de excitação, por assumirem sempre valores positivos, foram submetidas a uma normalização linear no intervalo $[0,1]$. Esta normalização é definida pela Equação (3.5).

$$y = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (3.5)$$

Devido ao fato das variáveis nível CC e frequência da corrente de excitação apresentarem uma distribuição não uniforme, avaliou-se também o emprego de uma normalização linear por partes. No entanto, durante o processo de modelagem das redes neurais verificou-se que não houve diferença nos resultados obtidos ao se utilizar este tipo de normalização. Por esta razão, manteve-se para estas variáveis a normalização linear no intervalo $[0,1]$.

A variável campo magnético externo aplicado, em virtude de assumir valores negativos e/ou positivos, dependendo do sentido do campo, foi submetida a uma normalização linear no intervalo $[-1,1]$. Tal normalização é definida pela Equação (3.6).

$$y = 2 \left(\frac{x - x_{\min}}{x_{\max} - x_{\min}} \right) - 1 \quad (3.6)$$

Já a variável de saída fase da impedância foi submetida a uma normalização pelo valor máximo. Esta normalização é definida pela Equação (3.7). Em virtude das fases máximas obtidas experimentalmente não serem necessariamente as máximas fases possíveis, o valor máximo considerado para fins de normalização foi a fase máxima do conjunto experimental acrescido de um fator correspondente a 10% do seu valor.

$$y = \frac{x}{x_{\max}} \quad (3.7)$$

A Tabela 3.2 apresenta os limites experimentais, para fins de normalização, dos parâmetros de interesse das redes neurais MLP específicas por comprimento

de fita 1 cm, 3 cm, 5 cm e 15 cm. Tais limites experimentais foram utilizados no processo de normalização linear das entradas e saída das redes neurais. O limite máximo da fase da impedância constante da Tabela 3.2 já contempla o fator de ajuste de 10%.

Tabela 3.2 – Limites experimentais, para fins de normalização, dos parâmetros de interesse das redes neurais MLP específicas por comprimento de fita 1 cm, 3 cm, 5 cm e 15 cm.

Comprimento (cm)	Parâmetros de Entrada						Parâmetro de Saída
	Nível CC (mA)		Frequência (kHz)		Campo Magnético (Oe)		Fase da Impedância (graus)
	<i>Mín.</i>	<i>Máx.</i>	<i>Mín.</i>	<i>Máx.</i>	<i>Mín.</i>	<i>Máx.</i>	<i>Máx.</i>
1	0	100	100	1000	-5	5	91,86
3	0	80	75	10000	-5	5	86,25
5	0	80	90	10000	-2	2	80,97
15	0	100	100	30000	-2	2	60,78

A Tabela 3.3, por sua vez, exhibe os limites experimentais, para fins de normalização, dos parâmetros de interesse da rede neural MLP única.

Tabela 3.3 – Limites experimentais, para fins de normalização, dos parâmetros de interesse da rede neural MLP única.

Comprimento (cm)	Parâmetros de Entrada						Parâmetro de Saída	
	Nível CC (mA)		Frequência (kHz)		Campo Magnético (Oe)		Fase da Impedância (graus)	
	<i>Mín.</i>	<i>Máx.</i>	<i>Mín.</i>	<i>Máx.</i>	<i>Mín.</i>	<i>Máx.</i>	<i>Máx.</i>	
1	15	0	100	75	30000	-5	5	91,86

As topologias de rede *feedforward Multilayer Perceptron* avaliadas com o objetivo de determinar aquela que melhor modelasse o comportamento da fase da impedância do efeito GMI são descritas na próxima seção.

3.2.2 Topologia

Com o intuito de se determinar a rede neural MLP que melhor modelasse o comportamento da fase da impedância do efeito GMI, foram analisadas topologias com uma e duas camadas escondidas e número de neurônios variando entre 10 e 30 neurônios, no caso de uma camada escondida, e entre 10 e 20 neurônios, no caso de duas camadas escondidas.

A função de ativação escolhida para os neurônios da(s) camada(s) escondida(s) foi a tangente hiperbólica (*tansig* no *Matlab*®), pois a saída prevista pela rede pode assumir valores positivos e negativos, enquanto que, para o neurônio da camada de saída escolheu-se a função linear (*purelin* no *Matlab*®), uma vez que esta função não satura, permitindo que a rede possa ter saídas normalizadas acima de 1 e abaixo de -1.

O algoritmo de treinamento utilizado foi o *Levenberg-Marquardt Backpropagation*, função de treinamento padrão do *Matlab*® (*trainlm*) para redes neurais *feedforward*.

O conjunto de dados experimentais foi dividido em três subconjuntos: Treinamento, Validação e Teste.

Primeiramente, definiu-se o conjunto de teste, selecionando, de forma aleatória, 10% do total dos padrões experimentais.

Os conjuntos de treinamento e validação foram gerados a partir do conjunto de padrões remanescentes. O conjunto de validação foi definido selecionando-se, de forma aleatória, 20% do total dos padrões experimentais remanescentes. O conjunto de treinamento, por sua vez, foi composto pelos padrões restantes. Este procedimento foi repetido cinco vezes, gerando-se cinco conjuntos de treinamento e cinco conjuntos de validação.

Em função da implementação de dois modelos computacionais, um com quatro redes neurais e outro com uma única rede, foram gerados conjuntos de treinamento, validação e teste específicos para cada uma das redes.

A Tabela 3.4 apresenta o total de padrões, por comprimento de fita, dos conjuntos de treinamento, validação e teste utilizados na determinação das redes neurais MLP que melhor modelassem o comportamento da fase da impedância do efeito GMI de amostras de comprimentos 1 cm, 3 cm, 5 cm e 15 cm.

Tabela 3.4 – Total de padrões, por comprimento de fita, dos conjuntos de treinamento, validação e teste (rede neural MLP por comprimento de fita).

Comprimento (cm)	Total de Padrões			
	Treinamento	Validação	Teste	Total
1	354	89	49	492
3	6955	1739	966	9660
5	27861	6965	3870	38696
15	451	113	63	627
Total	35621	8906	4948	49475

A Tabela 3.5, a seguir, apresenta o total de padrões dos conjuntos de treinamento, validação e teste utilizados na determinação da rede neural MLP que melhor modelasse o comportamento da fase da impedância do efeito GMI, tendo o comprimento da amostra como parâmetro de interesse (rede MLP única). Note que, o total de padrões de cada conjunto da Tabela 3.5 é igual aos respectivos valores apresentados na última linha da Tabela 3.4, que representam o total de padrões disponíveis.

Tabela 3.5 – Total de padrões dos conjuntos de treinamento, validação e teste (rede MLP única).

Conjunto	Total de Padrões
Treinamento	35621
Validação	8906
Teste	4948
Total	49475

Na fase de treinamento das redes MLP utilizou-se a técnica de “validação cruzada” com parada antecipada (*early stopping*) baseada no erro médio quadrático (MSE – *Mean Squared Error*).

Em relação às taxas de aprendizado e momentum, optou-se por utilizar o padrão do *Matlab*® que automaticamente altera e adapta a taxa de aprendizado e os valores do momentum à medida que o erro médio quadrático diminui.

O número máximo de épocas de treinamento foi primeiramente definido em 1000. No entanto, em todos os casos, verificou-se que a rede apresentava uma boa

convergência com 500 épocas. Por esta razão, adotou-se este valor para todas as topologias avaliadas.

Com o objetivo de evitar o problema do *overfitting* (especialização da rede nos dados de treinamento e perda da capacidade de generalização) utilizou-se o mecanismo de *early stopping*. Por meio de avaliações empíricas, definiu-se em 50 o maior número de falhas sucessivas na validação. Assim, durante o treinamento, é verificado se a exatidão alcançada na previsão dos dados de validação também continua melhorando. Caso isto deixe de acontecer se, em até 50 épocas, a exatidão alcançada na previsão dos dados de validação não torne a melhorar, o treinamento é interrompido e considera-se ter encontrado o ponto “ótimo”.

Na fase de modelagem foram avaliadas topologias de redes MLP com uma e duas camadas escondidas e número de neurônios variando de 10 a 20 em cada camada. Cada uma destas configurações foi simulada 50 vezes e a cada simulação os pesos foram reinicializados com valores aleatórios. O processo foi repetido para cada um dos cinco conjuntos de treinamento gerados aleatoriamente.

O total de treinamentos realizados para determinação da melhor configuração de rede neural MLP de uma e duas camadas escondidas foi, respectivamente, 2750 e 30250 treinamentos. No presente trabalho foram implementadas 5 redes neurais MLP com uma camada e 5 redes neurais MLP com duas camadas, uma tendo o comprimento da amostra GMI como variável de entrada da rede, e as demais, específicas por comprimento de amostra, totalizando 165000 treinamentos. A Tabela 3.6, abaixo, apresenta um resumo do exposto.

Tabela 3.6 – Total de simulações realizadas por topologia de rede MLP.

<i>Topologia (Número de Camadas)</i>	<i>Número de Configurações</i>	<i>Número de Simulações por Configuração</i>	<i>Número de Conjuntos Treinamento</i>	<i>Número de Redes Avaliadas</i>	<i>Total de Treinam.</i>
<i>1</i>	<i>11</i>	<i>50</i>	<i>5</i>	<i>5</i>	<i>13750</i>
<i>2</i>	<i>121</i>	<i>50</i>	<i>5</i>	<i>5</i>	<i>151250</i>
				<i>Total</i>	<i>165000</i>

Particularmente, no caso das redes MLP com uma camada, avaliaram-se topologias de rede com até 30 neurônios na camada escondida, aumentando para 170000 o número de treinamentos realizados. O aumento do número de topologias avaliadas, para o caso de redes MLP com uma camada, foi uma tentativa de se

obter uma rede MLP, com uma única camada, que melhor modelasse o comportamento da fase da impedância do efeito GMI, uma vez que nenhuma das topologias avaliadas, com até 20 neurônios, conseguiu modelar satisfatoriamente o seu comportamento. A escolha do número 30 não foi embasada por nenhum fundamento teórico. Basicamente, o que pesou na escolha deste novo limite, foi o tempo computacional necessário para realizar a avaliação de 10 novas topologias de rede para cada uma das 6 redes MLP com uma única camada.

Como medidas de comparação do desempenho das redes, foram utilizadas as métricas de avaliação *RMSE* (*Root Mean Squared Error*) e *MAPE* (*Mean Absolute Percent Error*). O *RMSE* é definido pela Equação (3.8), onde t_j e y_j são, respectivamente, o valor experimental e o valor de saída da rede para o padrão de entrada j , e N é total de padrões.

$$RMSE = \sqrt{\frac{1}{N} \sum_{j=1}^N (t_j - y_j)^2} \quad (3.8)$$

O *MAPE*, por sua vez, é definido pela Equação (3.9), a seguir, e representa a distância percentual entre o valor de saída da rede e o valor alvo.

$$MAPE (\%) = \frac{1}{N} \sum_{j=1}^N \left| \frac{t_j - y_j}{t_j} \right| \quad (3.9)$$

A melhor rede, em cada caso, é aquela que obteve o menor erro *RMSE* no conjunto de validação. A escolha do *RMSE* como métrica principal de avaliação de desempenho da rede é pelo fato de ser uma medida de exatidão, pois como eleva ao quadrado a diferença entre os valores previstos e observados, é mais sensível a um aumento da diferença entre os valores de previsão e observação, além de apresentar os valores do erro nas mesmas dimensões da variável analisada.

3.3 Cálculo da Sensibilidade de Fase

A sensibilidade de fase do efeito GMI é calculada pela derivação da fase da impedância em relação ao campo magnético externo aplicado. Nesta dissertação, a derivada foi calculada por diferenciação numérica, utilizando aproximação por diferenças centrais. Esta seção apresenta, em detalhes, o processo de diferenciação por diferenças centrais.

3.3.1 Diferenciação por Diferenças Centrais

A sensibilidade de fase do efeito GMI é calculada pela derivação da fase da impedância em relação ao campo magnético externo aplicado. A derivada de uma função em um ponto é, por definição, a inclinação da reta tangente à função no ponto e sua determinação pode ser aproximada pelo método das diferenças. Neste caso, estima-se a derivada de uma função $f(x)$ em um ponto x_k , $f'(x_k)$, por meio da aproximação da inclinação da reta tangente em x_k , utilizando-se valores da função próximos a x_k . Esta aproximação pode ser feita por diferenças regressivas, diferenças progressivas ou diferenças centrais.

A aproximação por diferenças regressivas é definida pela Equação (3.10), que corresponde à inclinação da reta definida pelos pontos $(x_{k-1}, f(x_{k-1}))$ e $(x_k, f(x_k))$.

$$f'(x_k) = \frac{f(x_k) - f(x_{k-1})}{x_k - x_{k-1}} \quad (3.10)$$

A aproximação por diferenças progressivas, por sua vez, é definida pela Equação (3.11), que corresponde à inclinação da reta definida pelos pontos $(x_k, f(x_k))$ e $(x_{k+1}, f(x_{k+1}))$.

$$f'(x_k) = \frac{f(x_{k+1}) - f(x_k)}{x_{k+1} - x_k} \quad (3.11)$$

A aproximação por diferenças centrais é a média entre as diferenças regressivas e as diferenças progressivas. É definida pela Equação (3.12),

$$f'(x_k) = \frac{f(x_{k+1}) - f(x_{k-1})}{2\Delta x} \quad (3.12)$$

onde

$$\Delta x = x_{k+1} - x_k = x_k - x_{k-1} \quad (3.13)$$

Neste trabalho, para determinação do valor aproximado da primeira derivada da fase da impedância em função do campo magnético externo (diferenciação numérica), utilizaram-se diferenças centrais em virtude de, em geral, estas levarem a uma melhor aproximação. O intervalo entre pontos é um parâmetro do modelo computacional. Todos os resultados baseados no procedimento de diferenciação numérica foram calculados considerando um intervalo entre pontos de 0,01 Oe.

3.4 Desenvolvimento do Algoritmo Genético

O Algoritmo Genético (AG) determina o condicionamento ótimo de amostras GMI em forma de fita em função dos seguintes parâmetros de interesse: comprimento das amostras, nível CC e frequência da corrente de excitação além do campo magnético externo aplicado. O AG foi implementado por meio da função *ga* do *Matlab*®, que possui como parâmetros de entrada o número de variáveis a serem otimizadas, os valores mínimo e máximo que cada variável pode assumir e a função de avaliação (*fitness*).

As variáveis a serem otimizadas, no caso do primeiro modelo neurogenético, são: nível CC e frequência da corrente de excitação, além do campo magnético externo. Já no segundo, são as mesmas do modelo anterior juntamente com o comprimento da amostra.

A função de avaliação (*fitness*), utilizada para medir a aptidão de cada indivíduo (solução) gerado pelo algoritmo, é a derivada da saída da rede neural MLP em relação ao campo magnético externo aplicado, calculada pelo método de aproximação por diferenças centrais, multiplicada por -1. A necessidade deste fator multiplicativo é devido ao fato das funções internas do *Matlab*® estarem escritas de modo a contemplar apenas problemas de minimização e um problema

de maximização de uma função ser equivalente a minimizar a mesma função multiplicada por -1 . Conforme mencionado anteriormente, o papel do AG é determinar a combinação ótima de parâmetros que leve à maximização da sensibilidade de fase da amostra.

O tamanho da população foi definido com 100 indivíduos e o total de gerações em 800. Outros valores foram avaliados para estes parâmetros e, em todos os casos, o algoritmo apresentou uma boa convergência e tempo de resposta com os valores acima.

Os operadores genéticos escolhidos foram *crossover* aritmético e mutação adaptável. As taxas de *crossover* e mutação adotadas foram, respectivamente, de 0,8 e 0,2.

O operador genético de seleção utilizado foi seleção por roleta. Neste método, os indivíduos de uma geração são escolhidos para fazer parte da próxima geração, através de um sorteio de roleta. Cada indivíduo da população é representado na roleta e a área da seção da roleta correspondente a um indivíduo é proporcional ao seu índice de aptidão (*fitness*). O AG usa um número aleatório para selecionar uma das seções da roleta com uma probabilidade igual a área da seção.

Como critério de substituição dos indivíduos de uma população para a próxima geração adotou-se o método de troca parcial da população, onde 10% da população corrente é preservada e o restante é substituído por novos indivíduos. Os indivíduos mais aptos, aqueles com maior valor de avaliação, são preservados para integrarem a nova população.

Nos experimentos realizados observou-se que o AG teve uma melhor convergência quando se utilizou o conceito de subpopulações. No *Matlab*®, para se utilizar o conceito de subpopulações deve-se definir o tamanho da população por meio de um vetor de comprimento maior do que 1. Ao se definir subpopulações, é necessário especificar as regras de migração dos indivíduos entre as subpopulações. A migração de indivíduos entre subpopulações implica na substituição dos indivíduos menos aptos de uma subpopulação pelos melhores indivíduos de outra. Os melhores indivíduos da subpopulação de origem são copiados para a subpopulação de destino. Estes indivíduos não são removidos da subpopulação de origem.

Nesta dissertação foram definidas 2 subpopulações de tamanho 100, podendo a migração ocorrer em ambos os sentidos. A fração de indivíduos que migram de uma subpopulação para outra é de 20% do tamanho da subpopulação e o intervalo de migração, ou seja, o número de gerações que são necessárias para ocorrer uma migração entre subpopulações, é 20. Ambos os valores escolhidos são os valores *default* do *Matlab*®.

O critério de parada adotado para o algoritmo foi o número máximo de gerações.

4

Resultados e Análises

Este capítulo apresenta, primeiramente, as configurações das redes MLP que melhor modelaram o comportamento da fase da impedância do efeito GMI (comparativo entre a saída fornecida pela rede e os dados experimentais). Em seguida, são apresentados os resultados de sensibilidade de fase, obtidos por diferenciação numérica das saídas das redes. Por fim, são descritos os resultados do AG e é avaliada sua capacidade de convergência.

4.1

Resultados das Redes Neurais MLP

Nesta seção são descritas as configurações de rede MLP que apresentaram melhor desempenho na modelagem dos dados experimentais da fase da impedância do efeito GMI (comparativo entre a saída fornecida pela rede e os dados alvos) em ambos os modelos computacionais desenvolvidos.

4.1.1

Redes MLP Específicas por Comprimento de Amostra

A Tabela 4.1 exibe a configuração das redes MLP, com uma camada escondida, que apresentaram melhor desempenho na modelagem dos dados experimentais da fase da impedância do efeito GMI de amostras de comprimentos 1 cm, 3 cm, 5 cm e 15 cm. As redes com melhor desempenho foram aquelas que apresentaram menor erro RMSE no conjunto de validação.

Tabela 4.1 – Parâmetros das redes MLP, com uma camada escondida, que apresentaram melhor desempenho na modelagem da fase da impedância do efeito GMI, para amostras de comprimentos 1 cm, 3 cm, 5 cm e 15 cm.

	<i>Comprimento de Fita (cm)</i>			
	<i>1</i>	<i>3</i>	<i>5</i>	<i>15</i>
<i>No. Neurônios Camada Escondida</i>	<i>19</i>	<i>30</i>	<i>28</i>	<i>18</i>
<i>RMSE Validação (°)</i>	<i>0,06</i>	<i>1,50</i>	<i>0,75</i>	<i>0,21</i>
<i>MAPE Validação (%)</i>	<i>0,13</i>	<i>2,91</i>	<i>1,09</i>	<i>0,47</i>
<i>RMSE Teste (°)</i>	<i>0,05</i>	<i>1,44</i>	<i>0,72</i>	<i>0,31</i>
<i>MAPE Teste (%)</i>	<i>0,10</i>	<i>2,39</i>	<i>0,98</i>	<i>0,50</i>

Os valores de RMSE obtidos no conjunto de validação (amostras com 1 cm e 15 cm de comprimento), por meio da comparação entre os dados estimados pela rede neural e os dados experimentais, são adequados, com magnitude do erro da ordem de $0,06^\circ$ e $0,21^\circ$, respectivamente, indicando que estas redes conseguiram modelar satisfatoriamente os dados. No caso de amostras de comprimentos 3 cm e 5 cm, o desempenho das redes foi pior, com magnitude do erro da ordem de $1,50^\circ$ e $0,75^\circ$, respectivamente. A magnitude do erro RMSE no conjunto de teste mostra que estas redes não conseguiram generalizar, adequadamente, padrões nunca vistos. Além disso, estas redes necessitaram de mais neurônios na camada escondida, pois a rede tinha que ter mais graus de liberdade para melhor aproximar a função, dado o grande número de pares entrada-saída de mapeamento (cerca de 98% dos padrões são de amostras de comprimentos 3 cm e 5 cm).

A seguir, são apresentados, para os condicionamentos definidos na seção 3.1, um comparativo entre a saída (fase da impedância) da rede neural MLP, com uma camada escondida, e os dados experimentais (alvos).

A Figura 4.1 apresenta um comparativo entre a saída da rede neural MLP, com uma camada escondida, que modela a fase da impedância do efeito GMI de amostras de comprimento 1 cm, e os valores alvos pertencentes ao conjunto de validação.




Figura 4.1 – Comparativo entre a saída (fase da impedância) da rede MLP, com uma camada escondida, e os dados experimentais (alvos) do conjunto de validação (amostras de comprimento 1 cm).

A Figura 4.2, por sua vez, apresenta um comparativo entre a saída desta rede e os valores alvos pertencentes ao conjunto de teste.




Figura 4.2 – Comparativo entre a saída (fase da impedância) da rede MLP, com uma camada escondida, e os dados experimentais (alvos) do conjunto de teste (amostras de comprimento 1 cm).

Com base na Figura 4.1, observa-se que a rede neural MLP modelou de forma satisfatória o comportamento da fase da impedância do efeito GMI, porque, para todos os padrões, verifica-se, visualmente, que há uma convergência entre os valores de saída da rede e os valores experimentais correspondentes (alvos),

pertencentes ao conjunto de validação. As Figuras 4.3 e 4.4, que apresentam um comparativo entre as curvas (fase da impedância em função do campo magnético externo) experimentais (alvos) e as de saída da rede neural MLP, com uma camada escondida, ilustram esse fato. A Figura 4.3 refere-se a uma fita GMI com 1 cm de comprimento submetida a uma corrente de nível CC de 80 mA e frequência de 500 kHz, enquanto que a Figura 4.4 refere-se ao caso em que esta amostra é submetida a uma corrente de nível CC de 40 mA e frequência de 100 kHz. Em ambos os casos, a curva experimental apresenta 41 pontos (campo magnético variando entre -5,0 Oe e 5,0 Oe em incrementos de 0,25 Oe), enquanto que a saída da rede neural apresenta 1001 pontos (campo magnético variando entre -5,0 Oe e 5,0 Oe em incrementos de 0,01 Oe).




Figura 4.3 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida, para uma fita GMI de 1 cm submetida a uma corrente de nível CC de 80 mA e frequência de 500 kHz.




Figura 4.4 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida, para uma fita GMI de 1 cm submetida a uma corrente de nível CC de 40 mA e frequência de 100 kHz.

A Figura 4.5 apresenta um comparativo entre a saída da rede neural MLP, com uma camada escondida, que modela a fase da impedância do efeito GMI de amostras de comprimento 3 cm, e os valores alvos pertencentes ao conjunto de validação (1000 primeiros pontos do conjunto de referência).




Figura 4.5 – Comparativo entre a saída (fase da impedância) da rede MLP, com uma camada escondida, e os dados experimentais (alvos) do conjunto de validação (amostras de comprimento 3 cm).

A Figura 4.6, por sua vez, apresenta um comparativo entre a saída desta rede e os valores alvos pertencentes ao conjunto de teste.




Figura 4.6 – Comparativo entre a saída (fase da impedância) da rede MLP, com uma camada escondida, e os dados experimentais (alvos) do conjunto de teste (amostras de comprimento 3 cm).

Com base na Figura 4.5, observa-se que a rede neural MLP não modelou satisfatoriamente o comportamento da fase da impedância do efeito GMI, porque, para muitos padrões, verifica-se, visualmente, que não há uma convergência entre os valores de saída da rede e os valores experimentais correspondentes (alvos), pertencentes ao conjunto de validação. As Figuras 4.7 e 4.8, que apresentam um comparativo entre as curvas (fase da impedância em função do campo magnético externo) experimentais (alvos) e as de saída da rede neural MLP, com uma camada escondida, ilustram este fato. Percebe-se que a rede não conseguiu modelar, adequadamente, valores de fase da impedância entre 10° e 35° . A Figura 4.7 refere-se a uma fita GMI com 3 cm de comprimento submetida a uma corrente de nível CC de 80 mA e frequência de 300 kHz, enquanto que a Figura 4.8 refere-se ao caso em que esta amostra é submetida a uma corrente de nível CC de 40 mA e frequência de 2 MHz. No primeiro caso, a curva experimental apresenta 201 pontos (campo magnético variando entre -5,0 Oe e 5,0 Oe em incrementos de 0,1 Oe) e no segundo, 33 pontos (campo magnético variando entre -2,0 Oe e 2,0 Oe em incrementos de 0,1 Oe, excetuando-se os intervalos -1,9 Oe até -1,6 Oe e 1,6 Oe até 1,9 Oe), enquanto que a saída da rede neural apresenta, no primeiro caso, 1001 pontos (campo magnético entre -5,0 Oe e 5,0 Oe em incrementos de 0,01 Oe) e no segundo, 401 pontos (campo magnético entre -2,0 Oe e 2,0 Oe em incrementos de 0,01 Oe).




Figura 4.7 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida, para uma fita GMI de 3 cm submetida a uma corrente de nível CC de 80 mA e frequência de 300 kHz.




Figura 4.8 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida, para uma fita GMI de 3 cm submetida a uma corrente de nível CC de 40 mA e frequência de 2 MHz.

A Figura 4.9 apresenta um comparativo entre a saída da rede neural MLP, com uma camada escondida, que modela a fase da impedância do efeito GMI de amostras de comprimento 5 cm, e os valores alvos pertencentes ao conjunto de validação (1000 primeiros pontos do conjunto de referência).




Figura 4.9 – Comparativo entre a saída (fase da impedância) da rede MLP, com uma camada escondida, e os dados experimentais (alvos) do conjunto de validação (amostras de comprimento 5 cm).

A Figura 4.10, por sua vez, apresenta um comparativo entre a saída desta rede e os valores alvos pertencentes ao conjunto de teste (1000 primeiros pontos do conjunto de referência).




Figura 4.10 – Comparativo entre a saída (fase da impedância) da rede MLP, com uma camada escondida, e os dados experimentais (alvos) do conjunto de teste (amostras de comprimento 5 cm).

Com base na Figura 4.9, observa-se que a rede neural MLP não modelou satisfatoriamente o comportamento da fase da impedância do efeito GMI, porque, para muitos padrões, verifica-se, visualmente, que não há uma convergência entre os valores de saída da rede e os valores experimentais correspondentes (alvos),

pertencentes ao conjunto de validação. As Figuras 4.11 e 4.12, que apresentam um comparativo entre as curvas (fase da impedância em função do campo magnético externo) experimentais (alvos) e as de saída da rede neural MLP, com uma camada escondida, ilustram esse fato. Percebe-se que a rede não conseguiu modelar, adequadamente, valores de fase da impedância entre 10° . A Figura 4.11 refere-se a uma fita GMI com 5 cm de comprimento submetida a uma corrente de nível CC de 80 mA e frequência de 3,5 MHz, enquanto que a Figura 4.12 refere-se ao caso em que esta amostra é submetida a uma corrente de nível CC de 50 mA e frequência de 99 kHz. No primeiro caso, a curva experimental apresenta 41 pontos (campo magnético variando entre -2,0 Oe e 2,0 Oe em incrementos de 0,1 Oe), enquanto que no segundo, a curva experimental apresenta 161 pontos (campo magnético variando entre -2,0 Oe e 2,0 Oe em incrementos de 0,05 Oe). A saída da rede neural apresenta 401 pontos (campo magnético variando entre -2,0 Oe e 2,0 Oe em incrementos de 0,01 Oe).




Figura 4.11 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida, para uma fita GMI de 5 cm submetida a uma corrente de nível CC de 80 mA e frequência de 3,5 MHz.




Figura 4.12 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida, para uma fita GMI de 5 cm submetida a uma corrente de nível CC de 50 mA e frequência de 99 kHz.

A Figura 4.13 apresenta um comparativo entre a saída da rede neural MLP, com uma camada escondida, que modela a fase da impedância do efeito GMI de amostras de comprimento 15 cm, e os valores alvos pertencentes ao conjunto de validação.

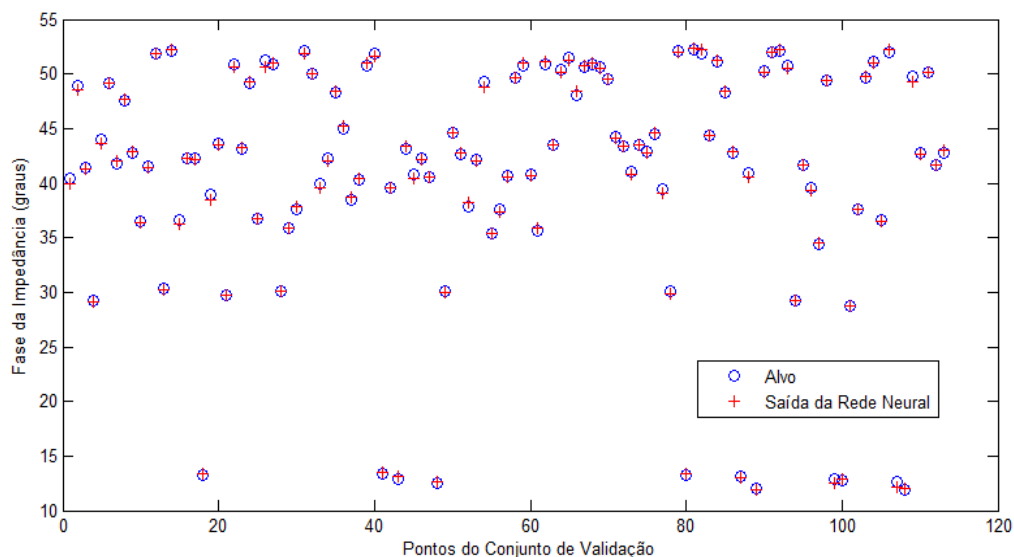


Figura 4.13 – Comparativo entre a saída (fase da impedância) da rede MLP, com uma camada escondida, e os dados experimentais (alvos) do conjunto de validação (amostras de comprimento 15 cm).

A Figura 4.14, por sua vez, apresenta um comparativo entre a saída desta rede e os valores alvos pertencentes ao conjunto de teste.




Figura 4.14 – Comparativo entre a saída (fase da impedância) da rede MLP, com uma camada escondida, e os dados experimentais (alvos) do conjunto de teste (amostras de comprimento 15 cm).

Com base na Figura 4.13, observa-se que a rede neural MLP modelou de forma satisfatória o comportamento da fase da impedância do efeito GMI, porque, para todos os padrões, verifica-se, visualmente, que há uma convergência entre os valores de saída da rede e os valores experimentais correspondentes (alvos), pertencentes ao conjunto de validação. As Figuras 4.15 e 4.16, que apresentam um comparativo entre as curvas (fase da impedância em função do campo magnético externo) experimentais (alvos) e as de saída da rede neural MLP, com uma camada escondida, ilustram esse fato. A Figura 4.15 refere-se a uma fita GMI com 15 cm de comprimento submetida a uma corrente de nível CC de 100 mA e frequência de 10 MHz, enquanto que a Figura 4.16 refere-se ao caso em que esta amostra é submetida a uma corrente de nível CC de 0 mA e frequência de 500 kHz. Em ambos os casos, a curva experimental apresenta 33 pontos (campo magnético variando entre -2,0 Oe e 2,0 Oe em incrementos de 0,1 Oe, excetuando-se os intervalos de -1,9 Oe até -1,6 Oe e 1,6 Oe até 1,9 Oe, em que não há medição experimental), enquanto que a saída da rede neural apresenta 401 pontos (campo magnético variando entre -2,0 Oe e 2,0 Oe em incrementos de 0,01 Oe).




Figura 4.15 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida, para uma fita GMI de 15 cm submetida a uma corrente de nível CC de 100 mA e frequência de 10 MHz.




Figura 4.16 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida, para uma fita GMI de 15 cm submetida a uma corrente de nível CC de 0 mA e frequência de 500 kHz.

A Tabela 4.2 exibe a configuração das redes MLP, com duas camadas escondidas, que apresentaram melhor desempenho na modelagem dos dados experimentais da fase da impedância do efeito GMI de amostras de comprimentos

1 cm, 3 cm, 5 cm e 15 cm. As redes com melhor desempenho foram aquelas que apresentaram menor erro RMSE no conjunto de validação.

Tabela 4.2 – Parâmetros das redes MLP, com duas camadas escondidas, que apresentaram melhor desempenho na modelagem da fase da impedância do efeito GMI, para amostras de comprimentos 1 cm, 3 cm, 5 cm e 15 cm.

	<i>Comprimento de Fita (cm)</i>			
	<i>1</i>	<i>3</i>	<i>5</i>	<i>15</i>
<i>No. Neurônios Primeira Camada</i>	<i>20</i>	<i>11</i>	<i>18</i>	<i>10</i>
<i>No. Neurônios Segunda Camada</i>	<i>19</i>	<i>20</i>	<i>18</i>	<i>20</i>
<i>RMSE Validação (°)</i>	<i>0,02</i>	<i>1,31</i>	<i>0,67</i>	<i>0,11</i>
<i>MAPE Validação (%)</i>	<i>0,05</i>	<i>2,22</i>	<i>0,80</i>	<i>0,19</i>
<i>RMSE Teste (°)</i>	<i>0,02</i>	<i>1,39</i>	<i>0,65</i>	<i>0,25</i>
<i>MAPE Teste (%)</i>	<i>0,04</i>	<i>1,92</i>	<i>0,70</i>	<i>0,23</i>

Os valores de RMSE obtidos no conjunto de validação (amostras com 1 cm e 15 cm de comprimento), por meio da comparação entre os dados estimados pela rede neural e os dados experimentais, são adequados, com magnitude do erro da ordem de $0,02^\circ$ e $0,11^\circ$, respectivamente, indicando que estas redes conseguiram modelar satisfatoriamente os dados. No caso de amostras de comprimentos 3 cm e 5 cm, o desempenho das redes foi pior, com magnitude do erro da ordem de $1,31^\circ$ e $0,67^\circ$, respectivamente. No entanto, estes valores de RMSE podem ser considerados adequados.

A seguir, são apresentados, para os condicionamentos definidos na seção 3.1, um comparativo entre a saída (fase da impedância) da rede neural MLP, com duas camadas escondidas, e os dados experimentais (alvos).

A Figura 4.17 apresenta um comparativo entre a saída da rede neural MLP, com duas camadas escondidas, que modela a fase da impedância do efeito GMI de amostras de comprimento 1 cm, e os valores alvos pertencentes ao conjunto de validação.




Figura 4.17 – Comparativo entre a saída (fase da impedância) da rede MLP com duas camadas escondidas e os dados experimentais (alvos) do conjunto de validação (amostras de comprimento 1 cm).

A Figura 4.18, por sua vez, apresenta um comparativo entre a saída desta rede e os valores alvos pertencentes ao conjunto de teste.




Figura 4.18 – Comparativo entre a saída (fase da impedância) da rede MLP com duas camadas escondidas e os dados experimentais (alvos) do conjunto de teste (amostras de comprimento 1 cm).

Com base na Figura 4.17, observa-se que a rede neural MLP modelou de forma satisfatória o comportamento da fase da impedância do efeito GMI, porque, para todos os padrões, verifica-se, visualmente, que há uma convergência entre os valores de saída da rede e os valores experimentais correspondentes (alvos), pertencentes ao conjunto de validação. As Figuras 4.19 e 4.20, que apresentam um

comparativo entre as curvas (fase da impedância em função do campo magnético externo) experimentais (alvos) e as de saída da rede neural MLP, com duas camadas escondidas, ilustram esse fato. A Figura 4.19 refere-se a uma fita GMI com 1 cm de comprimento submetida a uma corrente de nível CC de 80 mA e frequência de 500 kHz, enquanto que a Figura 4.20 refere-se ao caso em que esta amostra é submetida a uma corrente de nível CC de 40 mA e frequência de 100 kHz. Em ambos os casos, a curva experimental apresenta 41 pontos (campo magnético variando entre -5,0 Oe e 5,0 Oe em incrementos de 0,25 Oe), enquanto que a saída da rede neural apresenta 1001 pontos (campo magnético variando entre -5,0 Oe e 5,0 Oe em incrementos de 0,01 Oe).

Os valores de RMSE e MAPE obtidos no conjunto de validação (amostras com 1 cm de comprimento) da ordem de $0,02^\circ$ e $0,05\%$, respectivamente, são inferiores ao da topologia com uma camada, $0,06^\circ$ e $0,13\%$ (Tabela 4.3). Percebe-se que a topologia com duas camadas apresenta um desempenho superior a de uma camada, tendo-se uma redução no valor do RMSE de cerca de 61,4%.




Figura 4.19 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas, para uma fita GMI de 1 cm submetida a uma corrente de nível CC de 80 mA e frequência de 500 kHz.




Figura 4.20 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas, para uma fita GMI de 1 cm submetida a uma corrente de nível CC 40 mA e frequência de 100 kHz.

A Figura 4.21 apresenta um comparativo entre a saída da rede neural MLP, com duas camadas escondidas, que modela a fase da impedância do efeito GMI de amostras de comprimento 3 cm, e os valores alvos pertencentes ao conjunto de validação (1000 primeiros pontos do conjunto de referência).




Figura 4.21 – Comparativo entre a saída (fase da impedância) da rede MLP com duas camadas escondidas e os dados experimentais (alvos) do conjunto de validação (amostras de comprimento 3 cm).

A Figura 4.22, por sua vez, apresenta um comparativo entre a saída desta rede e os valores alvos pertencentes ao conjunto de teste.




Figura 4.22 – Comparativo entre a saída (fase da impedância) da rede MLP com duas camadas escondidas e os dados experimentais (alvos) do conjunto de teste (amostras de comprimento 3 cm).

Comparando-se as Figuras 4.5 e 4.21, observa-se que, para a maioria dos pontos do conjunto de validação, o valor previsto pela rede com duas camadas escondidas está mais próximo do valor alvo correspondente que no caso da rede com uma única camada. Percebe-se que a rede não conseguiu modelar, adequadamente, valores de fase da impedância entre 10° e 30° , embora haja uma maior convergência entre os valores de saída da rede e os valores experimentais correspondentes (alvos), pertencentes ao conjunto de validação. As Figuras 4.23 e 4.24, que apresentam um comparativo entre as curvas (fase da impedância em função do campo magnético externo) experimentais (alvos) e as de saída da rede neural MLP, com duas camadas escondidas, ilustram este fato. A Figura 4.23 refere-se a uma fita GMI com 3 cm de comprimento submetida a uma corrente de nível CC de 80 mA e frequência de 300 kHz enquanto que a Figura 4.24 refere-se ao caso em que esta amostra é submetida a uma corrente de nível CC de 40 mA e frequência de 2 MHz. No primeiro caso, a curva experimental apresenta 201 pontos (campo magnético variando entre -5,0 Oe e 5,0 Oe em incrementos de 0,1 Oe), enquanto que no segundo caso, a curva experimental apresenta 33 pontos (campo magnético variando entre -2,0 Oe e 2,0 Oe em incrementos de 0,1 Oe, excetuando-se os intervalos de -1,9 Oe até -1,6 Oe e 1,6 Oe até 1,9 Oe, em que não há medição experimental). A saída da rede neural apresenta 1001 pontos no primeiro caso (campo magnético variando entre -5,0 Oe e 5,0 Oe em incrementos

de 0,01 Oe) e 401 pontos no segundo (campo magnético variando entre -2,0 Oe e 2,0 Oe em incrementos de 0,01 Oe).

Os valores de RMSE e MAPE obtidos no conjunto de validação (amostras com 3 cm de comprimento) da ordem de $1,31^\circ$ e 2,22%, respectivamente, são inferiores ao da topologia com uma camada, $1,50^\circ$ e 2,91% (Tabela 4.3). Percebe-se que a topologia com duas camadas apresenta um desempenho superior a de uma camada, tendo-se uma redução no valor do RMSE de cerca de 23,8%, embora haja pontos em que a rede não apresentou uma boa convergência.




Figura 4.23 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas, para uma fita GMI de 3 cm submetida a uma corrente de nível CC de 80 mA e frequência de 300 kHz.




Figura 4.24 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas, para uma fita GMI de 3 cm submetida a uma corrente de nível CC de 40 mA e frequência de 2 MHz.

A Figura 4.25 apresenta um comparativo entre a saída da rede neural MLP, com duas camadas escondidas, que modela a fase da impedância do efeito GMI de amostras de comprimento 5 cm, e os valores alvos pertencentes ao conjunto de validação (1000 primeiros pontos do conjunto de referência).




Figura 4.25 – Comparativo entre a saída (fase da impedância) da rede MLP com duas camadas escondidas e os dados experimentais (alvos) do conjunto de validação (amostras de comprimento 5 cm).

A Figura 4.26, por sua vez, apresenta um comparativo entre a saída desta mesma rede e os valores alvos pertencentes ao conjunto de teste (1000 primeiros pontos do conjunto de referência).




Figura 4.26 – Comparativo entre a saída (fase da impedância) da rede MLP com duas camadas escondidas e os dados experimentais (alvos) do conjunto de teste (amostras de comprimento 5 cm).

Comparando-se as Figuras 4.9 e 4.25, observa-se que, para a maioria dos pontos do conjunto de validação, o valor previsto pela rede com duas camadas escondidas está mais próximo do valor alvo correspondente que no caso da rede com uma única camada. Percebe-se que a rede modelou melhor os valores de fase da impedância entre 10° e 30° . As Figuras 4.27 e 4.28, que apresentam um comparativo entre as curvas (fase da impedância em função do campo magnético externo) experimentais (alvos) e as de saída da rede neural MLP, com duas camadas escondidas, ilustram este fato. A Figura 4.27 refere-se a uma fita GMI com 5 cm de comprimento submetida a uma corrente de nível CC de 80 mA e frequência de 3,5 MHz enquanto que a Figura 4.28 refere-se ao caso em que esta amostra é submetida a uma corrente de nível CC de 50 mA e frequência de 99 kHz. No primeiro caso, a curva experimental apresenta 41 pontos (campo magnético variando entre -2,0 Oe e 2,0 Oe em incrementos de 0,1 Oe), enquanto que no segundo caso, a curva experimental apresenta 161 pontos (campo magnético variando entre -2,0 Oe e 2,0 Oe em incrementos de 0,05 Oe). A saída da rede neural apresenta 401 pontos (campo magnético variando entre -2,0 Oe e 2,0 Oe em incrementos de 0,01 Oe).

Os valores de RMSE e MAPE obtidos no conjunto de validação (amostras com 5 cm de comprimento) da ordem de 0,67° e 0,80%, respectivamente, são inferiores ao da topologia com uma camada, 0,75° e 1,09% (Tabela 4.3). Percebe-se que a topologia com duas camadas apresenta um desempenho superior a de uma camada, tendo-se uma redução no valor do RMSE de cerca de 9,8%.




Figura 4.27 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas, para uma fita GMI de 5 cm submetida a uma corrente de nível CC de 80 mA e frequência de 3,5 MHz.




Figura 4.28 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas, para uma fita GMI de 5 cm submetida a uma corrente de nível CC de 50 mA e frequência de 99 kHz.

A Figura 4.29 apresenta um comparativo entre a saída da rede neural MLP, com duas camadas escondidas, que modela a fase da impedância do efeito GMI de amostras de comprimento 15 cm, e os valores alvos pertencentes ao conjunto de validação.




Figura 4.29 – Comparativo entre a saída (fase da impedância) da rede MLP com duas camadas escondidas e os dados experimentais (alvos) do conjunto de validação (amostras de comprimento 15 cm).

A Figura 4.30, por sua vez, apresenta um comparativo entre a saída desta mesma rede e os valores alvos pertencentes ao conjunto de teste.




Figura 4.30 – Comparativo entre a saída (fase da impedância) da rede MLP com duas camadas escondidas e os dados experimentais (alvos) do conjunto de teste (amostras de comprimento 15 cm).

Com base na Figura 4.29, observa-se que a rede neural MLP modelou de forma satisfatória o comportamento da fase da impedância do efeito GMI, porque, para todos os padrões do conjunto de validação, verifica-se, visualmente, que há uma convergência entre os valores de saída da rede e os valores experimentais correspondentes (alvos). As Figuras 4.31 e 4.32, que apresentam um comparativo

entre as curvas (fase da impedância em função do campo magnético externo) experimentais (alvos) e as de saída da rede neural MLP, com duas camadas escondidas, ilustram este fato. A Figura 4.31 refere-se a uma fita GMI com 15 cm de comprimento submetida a uma corrente de nível CC de 100 mA e frequência de 10 MHz, enquanto que a Figura 4.32 refere-se ao caso em que esta amostra é submetida a uma corrente de nível CC de 0 mA e frequência de 500 kHz. Em ambos os casos, a curva experimental apresenta 33 pontos (campo magnético variando entre -2,0 Oe e 2,0 Oe em incrementos de 0,1 Oe, excetuando-se os intervalos de -1,9 Oe até -1,6 Oe e 1,6 Oe até 1,9 Oe, em que não há medição experimental), enquanto que a saída da rede neural apresenta 401 pontos (campo magnético variando entre -2,0 Oe e 2,0 Oe em incrementos de 0,01 Oe).

Os valores de RMSE e MAPE obtidos no conjunto de validação (amostras com 15 cm de comprimento) da ordem de $0,11^\circ$ e $0,19\%$, respectivamente, são inferiores ao da topologia com uma camada, $0,21^\circ$ e $0,47\%$ (Tabela 4.3). Percebe-se que a topologia com duas camadas apresenta um desempenho superior a de uma camada, tendo-se uma redução no valor do RMSE de cerca de $49,3\%$.




Figura 4.31 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas, para uma fita GMI de 15 cm submetida a uma corrente de nível CC de 100 mA e frequência de 10 MHz.




Figura 4.32 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas, para uma fita GMI de 15 cm submetida a uma corrente de nível CC de 0 mA e frequência de 500 kHz.

A Tabela 4.3, a seguir, apresenta os valores de RMSE e MAPE das Tabelas 4.1 e 4.2 para fins de comparação. Percebe-se que a topologia de rede com duas camadas escondidas apresenta um desempenho, quanto ao RMSE e MAPE, superior a de uma camada, para todos os comprimentos de fita analisados. Porém, tanto a rede de uma camada quanto a de duas camadas apresentaram seus piores desempenhos para as amostras de comprimentos 3 cm e 5 cm. Apesar disso, os valores de RMSE obtidos para a rede com duas camadas são considerados satisfatórios para todos os comprimentos analisados. Por esta razão, no caso do modelo computacional composto por quatro redes neurais MLP, a topologia de rede escolhida é a com duas camadas escondidas para todos os comprimentos de fita, a saber, 1 cm, 3 cm, 5 cm e 15 cm.

Tabela 4.3 – Comparativo entre os valores de RMSE e MAPE das redes neurais MLP, com uma e duas camadas escondidas, para os comprimentos de amostra 1 cm, 3 cm, 5 cm e 15 cm.

	<i>Comprimento de Fita (cm)</i>							
	<i>1</i>		<i>3</i>		<i>5</i>		<i>15</i>	
<i>Número de Camadas Escondidas</i>	<i>1</i>	<i>2</i>	<i>1</i>	<i>2</i>	<i>1</i>	<i>2</i>	<i>1</i>	<i>2</i>
<i>RMSE Validação (°)</i>	0,057	0,02	1,50	1,31	0,75	0,67	0,21	0,11
<i>MAPE Validação (%)</i>	0,13	0,05	2,91	2,22	1,09	0,80	0,47	0,19
<i>RMSE Teste (°)</i>	0,05	0,02	1,44	1,39	0,72	0,65	0,31	0,25
<i>MAPE Teste (%)</i>	0,10	0,04	2,39	1,92	0,98	0,70	0,50	0,23

4.1.2 Rede MLP Única

A Tabela 4.4 exibe a configuração da rede neural MLP, com uma camada escondida (rede MLP única), que apresentou melhor desempenho na modelagem dos dados experimentais da fase da impedância do efeito GMI e cujos parâmetros de entrada são: comprimento da amostra, nível CC e frequência da corrente de excitação além do campo magnético externo. A rede com melhor desempenho foi aquela que obteve o menor erro RMSE no conjunto de validação.

Tabela 4.4 – Parâmetros da rede MLP, com uma camada escondida, que apresentou melhor desempenho na modelagem da fase da impedância do efeito GMI (rede MLP única).

<i>No. Camadas Escondidas</i>	<i>No. Neurônios Camada Escondida</i>	<i>RMSE Validação (°)</i>	<i>MAPE Validação (%)</i>	<i>RMSE Teste (°)</i>	<i>MAPE Teste (%)</i>
<i>1</i>	<i>27</i>	<i>0,77</i>	<i>1,52</i>	<i>0,99</i>	<i>1,56</i>

Analisando a Figura 4.33, percebe-se que a rede não conseguiu modelar, adequadamente, valores de fase da impedância entre 10° e 30° e entre 65° e 85°. Verifica-se visualmente que, para muitos padrões, não há uma convergência entre os valores de saída da rede e os valores experimentais correspondentes (alvos), pertencentes ao conjunto de validação. As Figuras 4.35 até 4.42, que apresentam

um comparativo entre as curvas (fase da impedância em função do campo magnético externo) experimentais (alvos) e as de saída da rede neural MLP, com uma camada escondida (rede MLP única), ilustram este fato. Em nenhum dos casos a rede neural apresentou capacidade de generalização.

Comparando-se as Tabelas 4.1 e 4.4, observa-se que o RMSE obtido é melhor somente que o da rede neural com uma camada escondida, de amostras de comprimento 3 cm. No entanto, conforme ilustrado pelas Figuras 4.35 até 4.42, a magnitude do erro RMSE da ordem de $0,77^\circ$ mostra-se que não é adequada.

A Figura 4.33 apresenta um comparativo entre a saída (fase da impedância) da rede neural MLP, com uma camada escondida (rede MLP única), e os valores alvos pertencentes ao conjunto de validação (1000 primeiros pontos do conjunto de referência).




Figura 4.33 – Comparativo entre a saída (fase da impedância) da rede MLP, com uma camada escondida (rede MLP única), e os dados experimentais (alvos) do conjunto de validação.

A Figura 4.34, por sua vez, apresenta um comparativo entre a saída desta mesma rede e os valores alvos pertencentes ao conjunto de teste (1000 primeiros pontos do conjunto de referência).




Figura 4.34 – Comparativo entre a saída (fase da impedância) da rede MLP, com uma camada escondida (rede MLP única), e os dados experimentais (alvos) do conjunto de teste.

Conforme já mencionado, as Figuras 4.35 até 4.42 apresentam um comparativo entre as curvas (fase da impedância em função do campo magnético externo) experimentais (alvos) e as de saída da rede neural MLP, com uma camada escondida (rede MLP única), para os mesmos condicionamentos da subseção 4.1.1.




Figura 4.35 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida (rede MLP única), para uma fita GMI de comprimento 1 cm submetida a uma corrente de nível CC de 80 mA e frequência de 500 kHz.




Figura 4.36 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP com uma camada escondida (rede MLP única), para uma fita GMI de comprimento 1 cm submetida a uma corrente de nível CC de 40 mA e frequência de 100 kHz.




Figura 4.37 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida (rede MLP única), para uma fita GMI de comprimento 3 cm submetida a uma corrente de nível CC de 80 mA e frequência de 300 kHz.




Figura 4.38 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida (rede MLP única), para uma fita GMI de comprimento 3 cm submetida a uma corrente de nível CC de 40 mA e frequência de 2 MHz.




Figura 4.39 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida (rede MLP única), para uma fita GMI de comprimento 5 cm submetida a uma corrente de nível CC de 80 mA e frequência de 3,5 MHz.




Figura 4.40 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida (rede MLP única), para uma fita GMI de comprimento 5 cm submetida a uma corrente de nível CC de 50 mA e frequência de 99 kHz.




Figura 4.41 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida (rede MLP única), para uma fita GMI de comprimento 15 cm submetida a uma corrente de nível CC de 100 mA e frequência de 10 MHz.




Figura 4.42 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com uma camada escondida (rede MLP única), para uma fita GMI de comprimento 15 cm submetida a uma corrente de nível CC de 0 mA e frequência de 500 kHz.

Em nenhum dos condicionamentos avaliados, a rede neural MLP com uma camada escondida (rede MLP única), conseguiu modelar satisfatoriamente o comportamento da fase da impedância do efeito GMI. A rede não apresentou poder de generalização e, em nenhum dos casos, conseguiu aproximar, adequadamente, a função.

A Tabela 4.5 exibe a configuração da rede neural MLP, com duas camadas escondidas (rede MLP única), que apresentou melhor desempenho na modelagem dos dados experimentais da fase da impedância do efeito GMI. A rede com melhor desempenho foi aquela que obteve o menor erro RMSE no conjunto de validação.

Tabela 4.5 – Parâmetros da rede MLP, com duas camadas escondidas, que apresentou melhor desempenho na modelagem da fase da impedância do efeito GMI (rede MLP única).

<i>No. Neurônios Primeira Camada</i>	<i>No. Neurônios Segunda Camada</i>	<i>Conjunto de Validação</i>	<i>RMSE Validação (°)</i>	<i>MAPE Validação (%)</i>	<i>RMSE Teste (°)</i>	<i>MAPE Teste (%)</i>
20	17	2	0,59	0,94	0,84	0,97

Os valores de RMSE e MAPE obtidos no conjunto de validação da ordem de 0,59° e 0,94%, respectivamente, são inferiores ao da topologia com uma camada, 0,78° e 1,52% (vide Tabela 4.4). Percebe-se que a topologia com duas

camadas apresenta um desempenho superior a de uma camada, tendo-se uma redução no valor do RMSE de cerca de 37,6%, embora haja vários pontos em que a rede não apresentou uma boa convergência. Observa-se, comparando as Figuras 4.33 e 4.43, que, para a maioria dos pontos do conjunto de validação, o valor previsto pela rede com duas camadas escondidas está mais próximo do valor alvo correspondente que no caso da rede com uma única camada. No entanto, a magnitude do erro RMSE ainda não é adequado, conforme evidenciado pelas Figuras 4.45 até 4.52, que apresentam um comparativo entre as curvas (fase da impedância em função do campo magnético externo) experimentais (alvos) e as de saída da rede neural MLP, com duas camadas escondidas (rede MLP única) e ilustram o baixo poder de generalização desta rede.

A Figura 4.43 apresenta um comparativo entre a saída (fase da impedância) da rede neural MLP, com duas camadas escondidas (rede MLP única), e os valores alvos pertencentes ao conjunto de validação (1000 primeiros pontos do conjunto de referência).




Figura 4.43 – Comparativo entre a saída (fase da impedância) da rede MLP, com duas camadas escondidas (rede MLP única), e os dados experimentais (alvos) do conjunto de validação.

A Figura 4.44, por sua vez, apresenta um comparativo entre a saída desta mesma rede e os valores alvos pertencentes ao conjunto de teste (1000 primeiros pontos do conjunto de referência).




Figura 4.44 – Comparativo entre a saída (fase da impedância) da rede MLP, com duas camadas escondidas (rede MLP única), e os dados experimentais (alvos) do conjunto de teste.

Conforme já mencionado, as Figuras 4.45 até 4.52 apresentam um comparativo entre as curvas (fase da impedância em função do campo magnético externo) experimentais (alvos) e as de saída da rede neural MLP, com duas camadas escondidas (rede MLP única), para os mesmos condicionamentos analisados no caso de uma camada escondida.




Figura 4.45 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas (rede MLP única), para uma fita GMI de comprimento 1 cm submetida a uma corrente de nível CC de 80 mA e frequência de 500 kHz.




Figura 4.46 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas (rede MLP única), para uma fita GMI de comprimento 1 cm submetida a uma corrente de nível CC de 40 mA e frequência de 100 kHz.




Figura 4.47 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas (rede MLP única), para uma fita GMI de comprimento 3 cm submetida a uma corrente de nível CC de 80 mA e frequência de 300 kHz.




Figura 4.48 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas (rede MLP única), para uma fita GMI de comprimento 3 cm submetida a uma corrente de nível CC de 40 mA e frequência de 2 MHz.




Figura 4.49 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas (rede MLP única), para uma fita GMI de comprimento 5 cm submetida a uma corrente de nível CC de 80 mA e frequência de 3,5 MHz.




Figura 4.50 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas (rede MLP única), para uma fita GMI de comprimento 5 cm submetida a uma corrente de nível CC de 50 mA e frequência de 99 kHz.




Figura 4.51 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas (rede MLP única), para uma fita GMI de comprimento 15 cm submetida a uma corrente de nível CC de 100 mA e frequência de 10 MHz.




Figura 4.52 – Comparativo entre a curva (fase da impedância em função do campo magnético externo) experimental e a de saída da rede neural MLP, com duas camadas escondidas (rede MLP única), para uma fita GMI de comprimento 15 cm submetida a uma corrente de nível CC de 0 mA e frequência de 500 kHz.

A rede neural MLP única, com duas camadas escondidas, teve um desempenho melhor que a rede MLP única com uma camada. Observa-se que, dos 8 casos analisados, em 2 a rede modelou satisfatoriamente o comportamento da função. No entanto, as redes MLP específicas por comprimento de fita tiveram uma melhor capacidade de generalização e de aproximação da função. Devido a isto, o modelo neural escolhido para ser acoplado ao AG é composto por quatro redes neurais MLP, todas com duas camadas escondidas, uma rede para cada comprimento de amostra específico.

4.1.4.3 Resultados da Derivação das Redes Neurais MLP

O comportamento da fase da impedância do efeito GMI foi melhor modelado por uma rede neural MLP com duas camadas escondidas. O modelo neurogenético composto por quatro redes neurais MLP, uma rede para cada comprimento de amostra 1 cm, 3 cm, 5 cm e 15 cm, foi o que melhor modelou este comportamento a partir dos dados experimentais disponíveis. A sensibilidade de fase do efeito GMI é determinada diferenciando-se a saída destas redes em relação ao seu parâmetro de entrada campo magnético externo.

Esta seção apresenta, para cada caso de condicionamento analisado na seção 3.1, a curva de sensibilidade de fase em função do campo magnético externo

obtida a partir da diferenciação, pelo método de aproximação por diferenças centrais, da saída das redes MLP. A partir desta curva, determinou-se o campo magnético ótimo que levava à maximização da sensibilidade de fase. Em todos os casos, os demais parâmetros de entrada não variaram (nível CC e frequência da corrente de excitação). Para fins de análise, foram plotados em um mesmo gráfico, as curvas da fase da impedância (em azul) e da sensibilidade de fase (em vermelho) em função do campo magnético externo.

A Figura 4.53 exibe a curva de sensibilidade de fase em função do campo magnético externo (em vermelho), para uma fita GMI de comprimento 1 cm submetida a uma corrente de nível CC de 80 mA, frequência de 500 kHz e campo magnético variando entre -5,0 Oe e 5,0 Oe em incrementos de 0,01 Oe. O valor máximo da sensibilidade de fase foi de $1,13^{\circ}\cdot\text{Oe}^{-1}$, para um campo magnético de 4,99 Oe.




Figura 4.53 – Sensibilidade de fase em função do campo magnético externo para uma fita GMI de comprimento 1 cm submetida a uma corrente de nível CC de 80 mA e frequência de 500 kHz (campo magnético variando entre -5,0 Oe e 5,0 Oe).

A Figura 4.54 exibe a curva de sensibilidade de fase em função do campo magnético externo (em vermelho), para uma fita GMI de comprimento 1 cm submetida a uma corrente de nível CC de 40 mA, frequência de 100 kHz e campo magnético variando entre -5,0 Oe e 5,0 Oe em incrementos de 0,01 Oe. O valor máximo da sensibilidade de fase foi de $1,31^{\circ}\cdot\text{Oe}^{-1}$, para um campo magnético de 2,62 Oe.




Figura 4.54 – Sensibilidade de fase em função do campo magnético externo para uma fita GMI de comprimento 1 cm submetida a uma corrente de nível CC de 40 mA e frequência de 100 kHz (campo magnético variando entre -5,0 Oe e 5,0 Oe).

A Figura 4.55 exibe a curva de sensibilidade de fase em função do campo magnético externo (em vermelho), para uma fita GMI de comprimento 3 cm submetida a uma corrente de nível CC de 80 mA, frequência de 300 kHz e campo magnético variando entre -5,0 Oe e 5,0 Oe em incrementos de 0,01 Oe. O valor máximo da sensibilidade de fase foi de $3,10^\circ \cdot \text{Oe}^{-1}$, para um campo magnético de 1,09 Oe.




Figura 4.55 – Sensibilidade de fase em função do campo magnético externo para uma fita GMI de comprimento 3 cm submetida a uma corrente de nível CC de 80 mA e frequência de 300 kHz (campo magnético variando entre -5,0 Oe e 5,0 Oe).

A Figura 4.56 exibe a curva de sensibilidade de fase em função do campo magnético externo (em vermelho), para uma fita GMI de comprimento 3 cm

submetida a uma corrente de nível CC de 40 mA, frequência de 2 MHz e campo magnético variando entre -2,0 Oe e 2,0 Oe em incrementos de 0,01 Oe. O valor máximo da sensibilidade de fase foi de $5,54^{\circ}\cdot\text{Oe}^{-1}$, para um campo magnético de 1,73 Oe.




Figura 4.56 – Sensibilidade de fase em função do campo magnético externo para uma fita GMI de comprimento 3 cm submetida a uma corrente de nível CC de 40 mA e frequência de 2 MHz (campo magnético variando entre -2,0 Oe e 2,0 Oe).

A Figura 4.57 exibe a curva de sensibilidade de fase em função do campo magnético externo (em vermelho), para uma fita GMI de comprimento 5 cm submetida a uma corrente de nível CC de 80 mA, frequência de 3,5 MHz e campo magnético variando entre -2,0 Oe e 2,0 Oe em incrementos de 0,01 Oe. O valor máximo da sensibilidade de fase foi de $10,28^{\circ}\cdot\text{Oe}^{-1}$, para um campo magnético de -0,35 Oe.




Figura 4.57 – Sensibilidade de fase em função do campo magnético externo para uma fita GMI de comprimento 5 cm submetida a uma corrente de nível CC de 80 mA e frequência de 3,5 MHz (campo magnético variando entre -2,0 Oe e 2,0 Oe).

A Figura 4.58 exibe a curva de sensibilidade de fase em função do campo magnético externo (em vermelho), para uma fita GMI de comprimento 5 cm submetida a uma corrente de nível CC de 50 mA, frequência de 99 kHz e campo magnético variando entre -2,0 Oe e 2,0 Oe em incrementos de 0,01 Oe. O valor máximo da sensibilidade de fase foi de $-2,75^{\circ}\cdot\text{Oe}^{-1}$, para um campo magnético de 1,99 Oe.




Figura 4.58 – Sensibilidade de fase em função do campo magnético externo para uma fita GMI de comprimento 5 cm submetida a uma corrente de nível CC de 50 mA e frequência de 99 kHz (campo magnético variando entre -2,0 Oe e 2,0 Oe).

A Figura 4.59 exibe a curva de sensibilidade de fase em função do campo magnético externo (em vermelho), para uma fita GMI de comprimento 15 cm submetida a uma corrente de nível CC de 100 mA, frequência de 10 MHz e campo magnético variando entre -2,0 Oe e 2,0 Oe em incrementos de 0,01 Oe. O valor máximo da sensibilidade de fase foi de $18,72^{\circ}\cdot\text{Oe}^{-1}$, para um campo magnético de -0,18 Oe.




Figura 4.59 – Sensibilidade de fase em função do campo magnético externo para uma fita GMI de comprimento 15 cm submetida a uma corrente de nível CC de 100 mA e frequência de 10 MHz (campo magnético variando entre -2,0 Oe e 2,0 Oe).

A Figura 4.60 exibe a curva de sensibilidade de fase em função do campo magnético externo (em vermelho), para uma fita GMI de comprimento 15 cm submetida a uma corrente de nível CC de 0 mA, frequência de 500 kHz e campo magnético variando entre -2,0 Oe e 2,0 Oe em incrementos de 0,01 Oe. O valor máximo da sensibilidade de fase foi de $5,73^{\circ}\cdot\text{Oe}^{-1}$, para um campo magnético de 0,23 Oe.




Figura 4.60 – Sensibilidade de fase em função do campo magnético externo para uma fita GMI de comprimento 15 cm submetida a uma corrente de nível CC de 0 mA e frequência de 500 kHz (campo magnético variando entre -2,0 Oe e 2,0 Oe).

A Tabela 4.6 exibe os valores de campo magnético ótimo e de sensibilidade máxima de fase, calculada pelo método de aproximação por diferenças centrais.

Tabela 4.6 – Campo magnético ótimo e sensibilidade máxima de fase, calculada pelo método de aproximação por diferenças centrais.

<i>Comprimento de Fita (cm)</i>	<i>Nível CC (mA)</i>	<i>Frequência (kHz)</i>	<i>Sensibilidade Máxima de Fase ($^{\circ}\cdot\text{Oe}^{-1}$)</i>	<i>Campo Magnético (Oe)</i>
1	80	500	1,13	4,99
1	40	100	1,31	2,62
3	80	300	3,10	1,09
3	40	2000	5,54	1,73
5	80	3500	10,28	-0,35
5	50	99	-2,75	1,99
15	100	10000	18,72	-0,18
15	0	500	5,73	0,23

Os resultados constantes da Tabela 4.6 serão comparados, na próxima seção, aos valores de sensibilidade de fase e campo magnético ótimos determinados pelo AG, a fim de avaliar sua capacidade de convergência para um máximo global da função.

4.2.4.4 Resultados do Algoritmo Genético

Esta seção apresenta, para cada estudo de caso analisado na seção 4.1, a sensibilidade ótima de fase determinada pelo AG e a combinação dos parâmetros de condicionamento responsável por maximizar esta sensibilidade. Os componentes do cromossoma de cada indivíduo da população são frequência e nível CC da corrente de excitação além do campo magnético externo, nesta ordem.

Primeiramente, avaliou-se o desempenho do AG considerando os parâmetros de entrada nível CC e frequência da corrente de excitação fixos e campo magnético externo variável, dentro do espaço de busca. Os resultados fornecidos pelo AG são mostrados nas Figuras 4.61 até 4.68, que ilustram a evolução do AG em sua busca pelo valor ótimo de sensibilidade de fase. Estes resultados foram gerados considerando uma população de tamanho 100 e um total de 800 gerações. Cada uma destas figuras apresenta dois gráficos. O primeiro, na parte superior da figura, apresenta um comparativo entre o *fitness* médio (*Mean*) (média das avaliações de todos os indivíduos da população a cada geração) (sensibilidade de fase média) e o melhor *fitness* (*Best*) (melhor avaliação obtida pelo AG dentre todos os indivíduos da população) (sensibilidade ótima determinada pelo AG). Este gráfico permite avaliar a capacidade de convergência do AG na busca de uma solução ótima (convergência entre os valores de *fitness* médio e melhor *fitness* ao final do processo evolucionário). O segundo gráfico (histograma), na parte inferior, exibe o indivíduo com melhor *fitness* entre todos os indivíduos de todas as gerações (*current best individual*). Este indivíduo indica o condicionamento ótimo da amostra GMI. Cada barra do histograma representa um dos parâmetros de entrada do modelo. As duas primeiras barras, da esquerda para a direita, representam, respectivamente, a frequência (*variable 1*) e o nível CC (*variable 2*) da corrente de excitação enquanto que a última corresponde ao campo magnético externo (*variable 3*). Os valores destas variáveis no histograma estão normalizados, segundo as regras de normalização definidas na seção 3.2.1. Para obtenção dos valores reais, deve-se aplicar as regras de desnormalização correspondentes. Os gráficos das Figuras 4.71, 4.74, 4.77, 4.80, 4.81 e 4.82 também ilustram a evolução do AG em sua busca pelo valor ótimo de

sensibilidade de fase e portanto, a explicação dada acima (comparativo entre o *fitness* médio e o melhor *fitness* e indivíduo com melhor *fitness*) também se aplica às figuras em referência.

A Figura 4.61 apresenta um comparativo entre o *fitness* médio e o melhor *fitness* a cada geração, bem como o indivíduo com melhor *fitness* (condicionamento ótimo) para o caso de uma amostra GMI de comprimento 1 cm submetida a uma corrente de nível CC de 80 mA e frequência de 500 kHz. A sensibilidade ótima de fase determinada pelo AG foi de $1,13^\circ \cdot \text{Oe}^{-1}$ para um campo magnético de 5,0 Oe. O resultado obtido mostra que o AG convergiu para o máximo global da função. Estes resultados estão de acordo com os valores obtidos na seção 4.3 (Figura 4.53).




Figura 4.61 – *Fitness* médio e melhor *fitness* por geração e indivíduo com melhor *fitness* (condicionamento ótimo), para uma amostra GMI de comprimento 1 cm submetida a uma corrente de nível CC de 80 mA e frequência de 500 kHz.

A Figura 4.62 apresenta um comparativo entre o *fitness* médio e o melhor *fitness* a cada geração, bem como o indivíduo com melhor *fitness* (condicionamento ótimo) para o caso de uma amostra GMI de comprimento 1 cm submetida a uma corrente de nível CC de 40 mA e frequência de 100 kHz. A

sensibilidade ótima de fase determinada pelo AG foi $1,31^\circ \cdot \text{Oe}^{-1}$ para um campo magnético de 2,62 Oe. O resultado obtido mostra que o AG convergiu para o máximo global da função. Estes resultados estão de acordo com os valores obtidos na seção 4.3 (Figura 4.54).




Figura 4.62 – *Fitness* médio e melhor *fitness* por geração e indivíduo com melhor *fitness* (condicionamento ótimo), para uma amostra GMI de comprimento 1 cm submetida a uma corrente de nível CC de 40 mA e frequência de 100 kHz.

A Figura 4.63 apresenta um comparativo entre o *fitness* médio e o melhor *fitness* a cada geração, bem como o indivíduo com melhor *fitness* (condicionamento ótimo) para o caso de uma amostra GMI de comprimento 3 cm submetida a uma corrente de nível CC de 80 mA e frequência de 300 kHz. A sensibilidade ótima de fase determinada pelo AG foi $3,10^\circ \cdot \text{Oe}^{-1}$ para um campo magnético de 1,09 Oe. O resultado obtido mostra que o AG convergiu para o máximo global da função. Estes resultados estão de acordo com os valores obtidos na seção 4.3 (Figura 4.55).




Figura 4.63 – *Fitness* médio e melhor *fitness* por geração e indivíduo com melhor *fitness* (condicionamento ótimo), para uma amostra GMI de comprimento 3 cm submetida a uma corrente de nível CC de 80 mA e frequência de 300 kHz.

A Figura 4.64 apresenta um comparativo entre o *fitness* médio e o melhor *fitness* a cada geração, bem como o indivíduo com melhor *fitness* (condicionamento ótimo) para o caso de uma amostra GMI de comprimento 3 cm submetida a uma corrente de nível CC de 40 mA e frequência de 2 MHz. A sensibilidade ótima de fase determinada pelo AG foi $5,54^\circ \cdot \text{Oe}^{-1}$ para um campo magnético de 1,73 Oe. O resultado obtido mostra que o AG convergiu para o máximo global da função. Estes resultados estão de acordo com os valores obtidos na seção 4.3 (Figura 4.56).




Figura 4.64 – *Fitness* médio e melhor *fitness* por geração e indivíduo com melhor *fitness* (condicionamento ótimo), para uma amostra GMI de comprimento 3 cm submetida a uma corrente de nível CC de 40 mA e frequência de 2 MHz.

A Figura 4.65 apresenta um comparativo entre o *fitness* médio e o melhor *fitness* a cada geração, bem como o indivíduo com melhor *fitness* (condicionamento ótimo) para o caso de uma amostra GMI de comprimento 5 cm submetida a uma corrente de nível CC de 80 mA e frequência de 3,5 MHz. A sensibilidade ótima de fase determinada pelo AG foi $10,28^\circ \cdot \text{Oe}^{-1}$ para um campo magnético de $-0,35 \text{ Oe}$. O resultado obtido mostra que o AG convergiu para o máximo global da função. Estes resultados estão de acordo com os valores obtidos na seção 4.3 (Figura 4.57).




Figura 4.65 – *Fitness* médio e melhor *fitness* por geração e indivíduo com melhor *fitness* (condicionamento ótimo), para uma amostra GMI de comprimento 5 cm submetida a uma corrente de nível CC de 80 mA e frequência de 3,5 MHz.

A Figura 4.66 apresenta um comparativo entre o *fitness* médio e o melhor *fitness* a cada geração, bem como o indivíduo com melhor *fitness* (condicionamento ótimo) para o caso de uma amostra GMI de comprimento 5 cm submetida a uma corrente de nível CC de 50 mA e frequência de 99 kHz. A sensibilidade ótima de fase determinada pelo AG foi de $-2,78^\circ \cdot \text{Oe}^{-1}$ para um campo magnético de 2,0 Oe. O resultado obtido mostra que o AG convergiu para o máximo global da função. Estes resultados estão de acordo com os valores obtidos na seção 4.3 (Figura 4.58).




Figura 4.66 – *Fitness* médio e melhor *fitness* por geração e indivíduo com melhor *fitness* (condicionamento ótimo), para uma amostra GMI de comprimento 5 cm submetida a uma corrente de nível CC de 50 mA e frequência de 99 kHz.

A Figura 4.67 apresenta um comparativo entre o *fitness* médio e o melhor *fitness* a cada geração, bem como o indivíduo com melhor *fitness* (condicionamento ótimo) para o caso de uma amostra GMI de comprimento 15 cm submetida a uma corrente de nível CC de 100 mA e frequência de 10 MHz. A sensibilidade ótima de fase determinada pelo AG foi $18,75^\circ \cdot \text{Oe}^{-1}$ para um campo magnético de $-0,18 \text{ Oe}$. O resultado obtido mostra que o AG convergiu para o máximo global da função. Estes resultados estão de acordo com os valores obtidos na seção 4.3 (Figura 4.59).




Figura 4.67 – *Fitness* médio e melhor *fitness* por geração e indivíduo com melhor *fitness* (condicionamento ótimo), para uma amostra GMI de comprimento 15 cm submetida a uma corrente de nível CC de 100 mA e frequência de 10 MHz.

A Figura 4.68 apresenta um comparativo entre o *fitness* médio e o melhor *fitness* a cada geração, bem como o indivíduo com melhor *fitness* (condicionamento ótimo) para o caso de uma amostra GMI de comprimento 15 cm submetida a uma corrente de nível CC de 0 mA e frequência de 500 kHz. A sensibilidade ótima de fase determinada pelo AG foi $5,73^\circ \cdot \text{Oe}^{-1}$ para um campo magnético de 0,23 Oe. O resultado obtido mostra que o AG convergiu para o máximo global da função. Estes resultados estão de acordo com os valores obtidos na seção 4.3 (Figura 4.60).




Figura 4.68 – *Fitness* médio e melhor *fitness* por geração e indivíduo com melhor *fitness* (condicionamento ótimo), para uma amostra GMI de comprimento 15 cm submetida a uma corrente de nível CC de 0 mA e frequência de 500 kHz.

A Tabela 4.7, a seguir, exibe os valores de sensibilidade de fase e campo magnético ótimos determinados pelo AG.

Tabela 4.7 – Sensibilidade de fase e campo magnético ótimos determinados pelo AG.

<i>Comprimento de Fita (cm)</i>	<i>Nível CC (mA)</i>	<i>Frequência (kHz)</i>	<i>Sensibilidade de Fase Ótimo ($^{\circ}\cdot\text{Oe}^{-1}$)</i>	<i>Campo Magnético Ótimo (Oe)</i>
1	80	500	1,13	5,0
1	40	100	1,31	2,62
3	80	300	3,10	1,09
3	40	2000	5,54	1,73
5	80	3500	10,28	-0,35
5	50	99	-2,78	2,0
15	100	10000	18,75	-0,18
15	0	500	5,73	0,23

Comparando-se as Tabelas 4.6 e 4.7, percebe-se que, em todos os estudos de caso analisados, considerando nível CC e frequência da corrente de excitação fixos e campo magnético externo variável, dentro do espaço de busca, o AG convergiu para o máximo global da função.

A capacidade do AG em determinar o condicionamento ótimo de uma amostra GMI também foi avaliada considerando o caso em que a frequência da corrente de excitação e o campo magnético externo são variáveis e apenas o nível CC é fixo. Estes resultados são apresentados a seguir. As curvas de sensibilidade de fase (S_{fas}) em função da frequência da corrente de excitação (f) e do campo magnético externo (H), foram obtidas a partir do modelo neurogenético composto por quatro redes neurais MLP.

As Figuras 4.69 e 4.70 apresentam, respectivamente, a sensibilidade de fase e o módulo da sensibilidade de fase, em função da frequência da corrente de excitação (f) e do campo magnético externo aplicado (H), para o caso de uma fita GMI com 1 cm de comprimento, nível CC da corrente de excitação igual a 40 mA, frequência variando entre 100 kHz e 500 kHz, em incrementos de 10 kHz, e campo magnético variando entre -5,0 Oe e 5,0 Oe, em incrementos de 0,01 Oe. O valor máximo da sensibilidade de fase foi de $3,02^{\circ}\cdot\text{Oe}^{-1}$, para um campo magnético de 2,90 Oe e frequência de 500 kHz.




Figura 4.69 – $S_{fas} \times F \times H$, para uma fita GMI de comprimento 1 cm, submetida a uma corrente de nível CC de 40 mA (faixa de frequência entre 100 kHz e 500 kHz e campo magnético entre -5,0 Oe e 5,0 Oe).




Figura 4.70 – Mapa de cores $|S_{fas}| \times F \times H$ para uma fita GMI de comprimento 1 cm, submetida a uma corrente de nível CC de 40 mA (faixa de frequência entre 100 kHz e 500 kHz e campo magnético entre -5,0 Oe e 5,0 Oe).

O AG, neste caso, obteve como valor máximo de sensibilidade de fase $3,02^\circ \cdot \text{Oe}^{-1}$ para uma frequência de 500 kHz e campo magnético de 2,90 Oe. A Figura 4.71 apresenta um comparativo entre o *fitness* médio e o melhor *fitness* a cada geração, bem como, o indivíduo com melhor *fitness* (condicionamento ótimo). O resultado obtido mostra que o AG convergiu para o máximo global.




Figura 4.71 – *Fitness* médio e melhor *fitness* por geração e indivíduo com melhor *fitness* (condicionamento ótimo), para uma amostra GMI de comprimento 1 cm submetida a uma corrente de nível CC de 40 mA (faixa de frequência entre 100 kHz e 500 kHz e campo magnético entre -5,0 Oe e 5,0 Oe).

As Figuras 4.72 e 4.73 apresentam, respectivamente, a sensibilidade de fase e o módulo da sensibilidade de fase, em função da frequência da corrente de excitação (f) e do campo magnético externo aplicado (H), para o caso de uma fita GMI com 3 cm de comprimento, nível CC da corrente de excitação igual a 80 mA, frequência variando entre 75 kHz e 500 kHz, em incrementos de 10 kHz, e campo magnético variando entre -5,0 Oe e 5,0 Oe, em incrementos de 0,01 Oe. O valor máximo da sensibilidade de fase foi de $18,15^\circ \cdot \text{Oe}^{-1}$, para um campo magnético de 4,94 Oe e frequência de 85 kHz.




Figura 4.72 – $S_{fas} \times F \times H$, para uma fita GMI de comprimento 3 cm, submetida a uma corrente de nível CC de 80 mA (faixa de frequência entre 75 kHz e 500 kHz e campo magnético entre -5,0 Oe e 5,0 Oe).




Figura 4.73 – Mapa de cores $|S_{fas}| \times F \times H$, para uma fita GMI de comprimento 3 cm, submetida a uma corrente de nível CC de 80 mA (faixa de frequência entre 75 kHz e 500 kHz e campo magnético entre -5,0 Oe e 5,0 Oe).

O AG, neste caso, obteve como valor máximo de sensibilidade de fase $18,91^\circ \cdot \text{Oe}^{-1}$ para uma frequência de 82,86 kHz e campo magnético de 5,0 Oe. A

Figura 4.74 apresenta um comparativo entre o *fitness* médio e o melhor *fitness* a cada geração, bem como, o indivíduo com melhor *fitness* (condicionamento ótimo). O resultado obtido mostra que o AG convergiu para o máximo global.




Figura 4.74 – *Fitness* médio e melhor *fitness* por geração e indivíduo com melhor *fitness* (condicionamento ótimo), para uma amostra GMI de comprimento 3 cm submetida a uma corrente de nível CC de 80 mA (faixa de frequência entre 75 kHz e 500 kHz e campo magnético entre -5,0 Oe e 5,0 Oe).

As Figuras 4.75 e 4.76 apresentam, respectivamente, a sensibilidade de fase e o módulo da sensibilidade de fase, em função da frequência da corrente de excitação (f) e do campo magnético externo aplicado (H), para o caso de uma fita GMI com 5 cm de comprimento, nível CC da corrente de excitação igual a 80 mA, frequência variando entre 1 MHz e 4,5 MHz, em incrementos de 10 kHz, e campo magnético variando entre -2,0 Oe e 2,0 Oe, em incrementos de 0,01 Oe. O valor máximo da sensibilidade de fase foi de $-32,16^\circ \cdot \text{Oe}^{-1}$, para um campo magnético de -2,0 Oe e frequência de 2,09 MHz.




Figura 4.75 – $S_{fas} \times F \times H$, para uma fita GMI de comprimento 5 cm, submetida a uma corrente de nível CC de 80 mA (faixa de frequência entre 1 MHz e 4,5 MHz e campo magnético entre -2,0 Oe e 2,0 Oe).




Figura 4.76 – Mapa de cores $|S_{fas}| \times F \times H$, para uma fita GMI de comprimento 5 cm, submetida a uma corrente de nível CC de 80 mA (faixa de frequência entre 1 MHz e 4,5 MHz e campo magnético entre -2,0 Oe e 2,0 Oe).

O AG, neste caso, obteve como valor máximo de sensibilidade de fase $-32,16^\circ \cdot \text{Oe}^{-1}$ para uma frequência de 2,09 MHz e campo magnético de -2,0 Oe. A

Figura 4.77 apresenta um comparativo entre o *fitness* médio e o melhor *fitness* a cada geração, bem como, o indivíduo com melhor *fitness* (condicionamento ótimo). O resultado obtido mostra que o AG convergiu para o máximo global.




Figura 4.77 – *Fitness* médio e melhor *fitness* por geração e indivíduo com melhor *fitness* (condicionamento ótimo), para uma amostra GMI de comprimento 5 cm submetida a uma corrente de nível CC de 80 mA (faixa de frequência entre 1 MHz e 4,5 MHz e campo magnético entre -2,0 Oe e 2,0 Oe).

As Figuras 4.78 e 4.79 apresentam, respectivamente, a sensibilidade de fase e o módulo da sensibilidade de fase, em função da frequência da corrente de excitação (f) e do campo magnético externo aplicado (H), para o caso de uma fita GMI de comprimento 15 cm, nível CC da corrente de excitação igual a 0 mA, frequência variando entre 100 kHz e 2 MHz, em incrementos de 10 kHz, e campo magnético variando entre -2,0 Oe e 2,0 Oe, em incrementos de 0,01 Oe. O valor máximo da sensibilidade de fase foi de $6,49^\circ \cdot \text{Oe}^{-1}$, para um campo magnético de 0,24 Oe e frequência de 850 kHz.




Figura 4.78 – $S_{fas} \times F \times H$, para uma fita GMI de comprimento 15 cm, submetida a uma corrente de nível CC de 0 mA (faixa de frequência entre 100 kHz e 2 MHz e campo magnético entre -2,0 Oe e 2,0 Oe).




Figura 4.79 – Mapa de cores $|S_{fas}| \times F \times H$, para uma fita GMI de comprimento 15 cm, submetida a uma corrente de nível CC de 0 mA (faixa de frequência entre 100 kHz e 2 MHz e campo magnético entre -2,0 Oe e 2,0 Oe).

O AG, neste caso, obteve como valor máximo da sensibilidade de fase $6,49^\circ \cdot \text{Oe}^{-1}$ para uma frequência de 852,93 kHz e campo magnético de 0,25 Oe. A

Figura 4.80 apresenta um comparativo entre o *fitness* médio e o melhor *fitness* a cada geração, bem como, o indivíduo com melhor *fitness* (condicionamento ótimo). O resultado obtido mostra que o AG convergiu para o máximo global.




Figura 4.80 – *Fitness* médio e melhor *fitness* por geração e indivíduo com melhor *fitness* (condicionamento ótimo), para uma amostra GMI de comprimento 15 cm submetida a uma corrente de nível CC de 0 mA (faixa de frequência entre 100 kHz e 2 MHz e campo magnético entre -2,0 Oe e 2,0 Oe).

Por último, considerou-se o caso em que o nível CC, a frequência da corrente de excitação e o campo magnético externo são variáveis, dentro do espaço de busca.

A Figura 4.81 apresenta um comparativo entre o *fitness* médio e o melhor *fitness* a cada geração, bem como o indivíduo com melhor *fitness* (condicionamento ótimo), para o caso de uma amostra GMI de comprimento 1 cm. Para fins de otimização, nível CC e frequência da corrente de excitação foram limitados superiormente em 80 mA e 500 kHz, respectivamente. O campo magnético variou entre -5,0 Oe e 5,0 Oe. A sensibilidade ótima de fase determinada pelo AG foi de $8,81^\circ \cdot \text{Oe}^{-1}$ para uma frequência de 500 kHz, nível CC de 11,3 mA e campo magnético de 3,9 Oe.

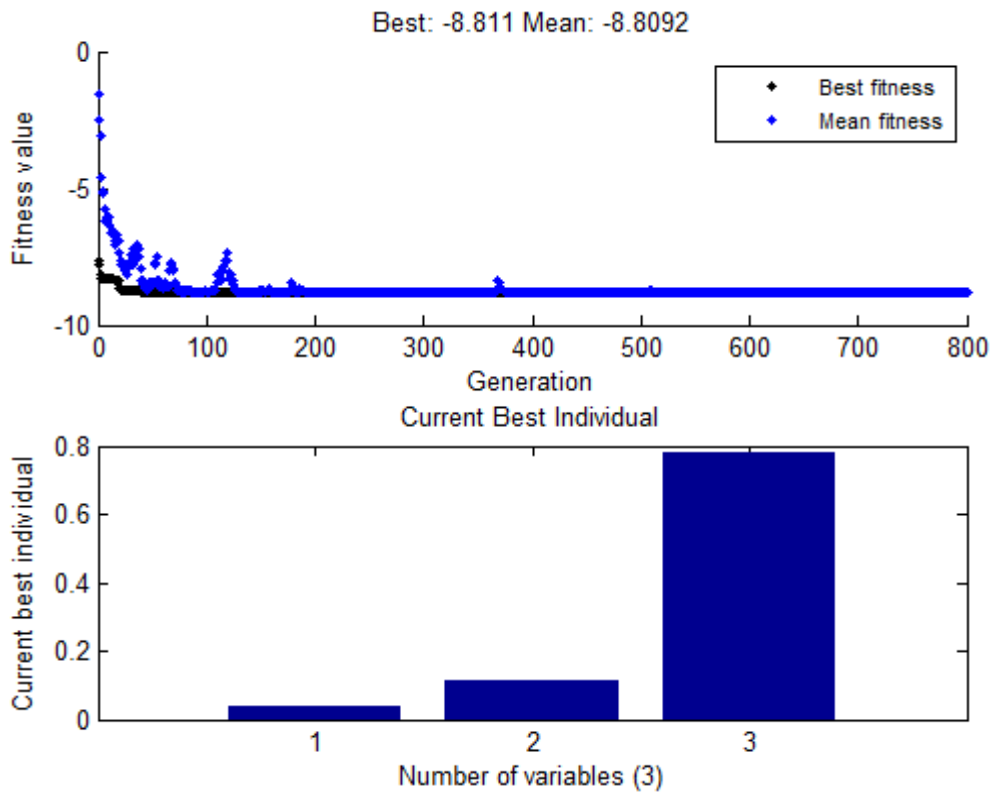


Figura 4.81 – *Fitness* médio e melhor *fitness* por geração e indivíduo com melhor *fitness* (condicionamento ótimo), para uma amostra GMI de comprimento 1 cm.

A Figura 4.82 apresenta um comparativo entre o *fitness* médio e o melhor *fitness* a cada geração, bem como o indivíduo com melhor *fitness* (condicionamento ótimo), para o caso de uma amostra GMI de comprimento 15 cm. Para fins de otimização, nível CC e frequência da corrente de excitação foram limitados superiormente em 100 mA e 10 MHz, respectivamente. O campo magnético variou entre -2,0 Oe e 2,0 Oe. A sensibilidade ótima de fase determinada pelo AG foi de $54,94^{\circ} \cdot \text{Oe}^{-1}$ para uma frequência de 893,8 kHz, nível CC de 51,36 mA e campo magnético de 0,18 Oe.




Figura 4.82 – *Fitness* médio e melhor *fitness* por geração e indivíduo com melhor *fitness* (condicionamento ótimo), para uma amostra GMI de comprimento 15 cm.

Em todos os casos, observa-se que o AG convergiu para uma solução ótima.

5 Conclusões e Trabalhos Futuros

O fenômeno GMI passou a ser intensamente estudado a partir da década de 90 e sua importância tem aumentado, principalmente, devido ao seu potencial de aplicação na fabricação de magnetômetros de alta sensibilidade e de baixo custo. A sensibilidade dos transdutores magnéticos está diretamente associada à sensibilidade de seus elementos sensores e no caso de fitas GMI, a sensibilidade é afetada por diversos parâmetros, tais como, amplitude, nível CC e frequência da corrente de excitação; dimensões (comprimento, largura, espessura) e campo magnético externo aplicado. Por sua vez, essa dependência ainda não é bem modelada quantitativamente, sendo que a busca do condicionamento ótimo é, usualmente, empírica. Assim, deve-se obter experimentalmente as curvas de fase e módulo da impedância em função do campo magnético externo para, a partir das mesmas, determinar as respectivas sensibilidades.

Costa Silva (2013), a partir da caracterização experimental de amostras GMI, determinou o conjunto de parâmetros de condicionamento responsável pela maximização da sensibilidade das amostras (comprimento da amostra, nível CC e frequência da corrente de excitação, além do campo magnético externo), bem como verificou que transdutores magnéticos baseados nas características de fase da impedância têm o potencial de elevar os valores de sensibilidade em pelo menos 100 vezes, quando comparados aos obtidos com transdutores baseados no módulo.

Dessa forma, utilizando-se os dados experimentais fornecidos pelo Laboratório de Biometrologia da PUC-Rio (LaBioMet), verificou-se que as redes neurais MLP com duas camadas escondidas em todos os casos modelaram melhor o comportamento da fase da impedância em função do campo magnético externo aplicado.

O primeiro modelo, constituído por quatro redes neurais MLP, uma para cada comprimento de amostra (1 cm, 3 cm, 5 cm e 15 cm), e tendo como variáveis de entrada o nível CC e a frequência da corrente de excitação, além do campo magnético externo, obteve um desempenho muito superior ao modelo composto

por uma única rede neural MLP, que tinha como variáveis de entrada as mesmas três anteriores, incluindo o comprimento da amostra.

Em todos os estudos de caso analisados, as redes conseguiram modelar o comportamento da fase da impedância de forma satisfatória. Este resultado de certa forma era esperado, devido ao fato de haver uma rede específica para cada comprimento de fita (1 cm, 3 cm, 5 cm e 15 cm). No entanto, o uso do modelo fica restrito a estes comprimentos de fita. Um novo comprimento de amostra exigirá necessariamente que uma nova rede neural seja treinada com os padrões experimentais referentes a este novo comprimento e acoplada ao modelo. É importante frisar que todas estas redes responderam adequadamente a padrões nunca vistos.

O modelo computacional composto por uma rede neural MLP única não modelou de forma satisfatória o comportamento da fase da impedância do efeito GMI das amostras de comprimento 1 cm e 15 cm. Isto se deve ao fato do total de dados experimentais referentes a estes comprimentos de amostras representarem, respectivamente, 0,99% e 1,27%, do total de padrões. Em função do número de padrões de treinamento destes tipos de amostra ser muito inferior ao dos demais comprimentos, a rede não conseguiu aprender o suficiente para permitir uma boa generalização a padrões nunca vistos destes comprimentos de amostras. A capacidade de generalização da rede foi afetada, uma vez que ela se especializou em amostras de comprimentos 3 cm e 5 cm.

Diversas topologias foram analisadas para determinação da topologia de rede com melhor capacidade de generalização (consideraram-se todas as combinações possíveis de 10 a 20 processadores em cada camada escondida). No entanto, no caso do modelo baseado em uma rede neural MLP única, com duas camadas escondidas, percebe-se que uma topologia com um número de neurônios maior do que 20 em cada camada escondida deve ser avaliada.

O Algoritmo Genético, responsável pela otimização da sensibilidade de fase da impedância do efeito GMI e determinação do condicionamento ótimo da amostra de modo que sua sensibilidade seja máxima, convergiu para o máximo global da função em todos os estudos de casos analisados.

A título de trabalhos futuros, sugere-se a alteração do modelo computacional proposto com a inclusão de outros parâmetros de interesse que afetam o comportamento da fase da impedância do efeito GMI. Uma outra frente

de trabalho é o desenvolvimento de um algoritmo genético que determine os parâmetros ótimos de configuração de cada rede neural MLP (minimização do erro RMSE).

O desenvolvimento de um modelo neurogenético baseado em redes RBF (*Radial Basis Function*) ao invés de MLP é uma alternativa que deve ser considerada e que permitiria identificar a estrutura neural que melhor mapearia os pares de entrada-saída.

Nesta dissertação, a sensibilidade de fase em função do campo magnético externo foi calculada por diferenciação numérica, utilizando aproximação por diferenças centrais. No entanto, a sensibilidade de fase poderia também ser determinada derivando-se analiticamente a saída da rede neural.

Um ponto importante a salientar é que a sensibilidade ótima de fase determinada pelo AG está associada a um condicionamento específico da amostra GMI e fora desta região, não necessariamente, a amostra permanecerá apresentando a mesma sensibilidade. Para fins de operação de um transdutor magnético GMI é interessante que a sensibilidade do transdutor se mantenha alta e aproximadamente constante dentro de uma determinada região (ΔH). Polarizando-se o sensor no ponto médio desta região, obtém-se a maior excursão simétrica possível. Portanto, uma melhoria importante a ser feita no AG é considerar que o fator a ser maximizado não é a sensibilidade de fase propriamente dita, mas sim, um parâmetro que é função tanto da sensibilidade de fase quanto do tamanho da faixa linear na qual deseja-se que o valor se mantenha constante.

Referências bibliográficas

ARAÚJO, J.F.D.F. **Construção de um magnetômetro Hall para caracterização de partículas magnéticas utilizadas em ensaios imunológicos**. Rio de Janeiro, 2009. Dissertação de Mestrado – Programa de Pós-graduação em Física, Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio).

ATALAY, F.E.; KAYA, H.; ATALAY, S. Giant magnetoimpedance effect in electrodeposited CoNiFe/Cu wires with varying Ni, Fe and Co content. **J. Alloy Compd.**, v. 420, p. 9–14, 2006.

BEACH, R.S.; BERKOWITZ, A.E. Giant magnetic-field dependent impedance of amorphous FeCoSiB wire. **Appl. Phys. Lett.**, Woodbury, v. 64, n. 26, p. 3652-3654, 1994a.

BEACH, R.S.; BERKOWITZ, A.E. Sensitive Field and Frequency-Dependence Impedance Spectra of FeCoSiB Wire and Ribbon. **Journal of Applied Physics**, v.76, n.10, p. 6209-6213, 1994b.

BOLL, R.; OVERSHOTT, K.J. **Sensors: A Comprehensive Survey – Vol. 5: Magnetic Sensors**, Wiley-VCH, 1989.

BRAGA, A.P.; LUDERMIR, T.B.; CARVALHO, A.C.P. **Redes Neurais Artificiais - Teoria e Aplicações**. ed.. LTC: Rio de Janeiro, 2007.

BYON, K.S.; YU, S.C.; KIM, C.G.; YOON, S.S. Asymmetric characteristics of magnetoimpedance in amorphous Fe_{77.5}Si_{7.5}B₁₅ wire. **J. Magn. Magn. Mater.**, v. 226–230, p. 718–720, 2001.

CARDOSO, F.A.C.M. **Algoritmos Genéticos para Interpolação Não-Linear de Imagem e Decodificação de Códigos Lineares**. Campinas, 1998. Dissertação de Mestrado – Programa de Pós-graduação em Engenharia Elétrica, Universidade Estadual de Campinas (UNICAMP).

CAVALCANTI, F.M.P. **Desenvolvimento e Caracterização de um Transdutor de Campo Magnético Baseado no Efeito da Magnetoimpedância Gigante**. Rio de Janeiro, 2005. Dissertação de Mestrado - Programa de Pós-graduação em Metrologia, Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio).

CAVALCANTI, F.M.P.; GUSMÃO, L.A.P.; HALL BARBOSA, C.R.; COSTA MONTEIRO, E.; GONÇALVES, L.A.P.; MACHADO, F.L.A. Characterization of a Magnetic Field Transducer based on the GMI Effect. In: XVIII IMEKO WORLD CONGRESS - Metrology for a Sustainable Development, Rio de Janeiro, 2006. **Proceedings of the XVIII IMEKO WORLD CONGRESS**, 2006, p. 1-4.

CAVALCANTI, F.M.P.; GUSMÃO, L.A.P.; BARBOSA, C.H.; COSTA MONTEIRO, E.; GONÇALVES, L.A.P.; MACHADO, F.L.A. Ring shaped magnetic field transducer based on the GMI effect. *Measurement Science & Technology*, v. 19, p. 1-10, 2008.

CHIRIAC, H.; TIBU, M.; MOGA, A.E.; HEREA, D.D. Magnetic GMI sensor for detection of biomolecules. *J. Magn. Magn. Mater.*, v. 293, p. 671–673, 2005.

CLARKE, J.; BRAGINSKI, A.I. **The SQUID Handbook**: Vol. I Fundamentals and Technology of SQUID's and SQUID systems, WILEY-VCH Verlag GmbH & Co. KGaA, 2004.

CLARKE, J.; BRAGINSKI, A.I. **The SQUID Handbook**: Vol. II Applications of SQUID's and SQUID systems, WILEY-VCH Verlag GmbH & Co. KGaA, 2006.

COISSON, M.; TIBERTO, P.; VINAI, F. Magnetoimpedance effect in nanocrystalline $\text{Fe}_{80}\text{Zr}_7\text{B}_6\text{Cu}_1$ melt-spun ribbons. *Phys. Stat. Soli. A*, v. 189, n. 3, p. 711-715, 2002.

COSTA SILVA, E.; GUSMÃO, L.A.P.; HALL BARBOSA, C.; COSTA MONTEIRO, E. (2008a). Magnetic Field Transducers based on the Phase Characteristics of GMI Sensors and Aimed to Biomedical Applications. In: The 13th International Conference on Biomedical Engineering, ICBME2008, Singapura, 2008. **Proceedings of the 13th International Conference on Biomedical Engineering**, 2008, v. 23, p. 652-656.

COSTA SILVA, E.; GUSMÃO, L.A.P.; HALL BARBOSA, C.; COSTA MONTEIRO, E. (2008b). Transdutor de Pressão para Medição de Ondas de Pulso Arterial, Baseado na Fase do Fenômeno GMI. In: XXI Congresso Brasileiro de Engenharia Biomédica (CBEB2008), Bahia, 2008. **Anais do XXI Congresso Brasileiro de Engenharia Biomédica**, 2008.

COSTA SILVA, E.; GUSMÃO, L.A.P.; COSTA MONTEIRO, E.; HALL BARBOSA, C. (2009a). Characterization of the Magnitude Impedance of Ribbon-Shaped GMI Samples and their use in Transducers aimed at Biomedical Applications. In: XI International Conference on Advanced Materials, Rio de Janeiro, 2009. **Proceedings of the XI International Conference on Advanced Materials**, 2009, p. 1.

COSTA SILVA, E.; GUSMÃO, L.A.P.; HALL BARBOSA, C.; COSTA MONTEIRO, E. (2009b). Transdutor de Pressão, Baseado nas Características de Fase do Efeito GMI, para Detecção de Ondas de Pulso Arterial. In: VIII Seminário Internacional em Engenharia Elétrica (SEMETRO), João Pessoa, Paraíba, 2009. **Anais do VIII SEMETRO**, 2009, p. 1-5.

COSTA SILVA, E.; HALL BARBOSA, C.; COSTA MONTEIRO, E.; GUSMÃO, L.A.P. (2009c). GMI impedance Phase Characteristics, focusing on its Dependence with the Frequency of the Excitation current. In: XXXII Brazilian Meeting on Condensed Matter Physics, Águas de Lindóia, São Paulo, 2009. **Anais do XXXII Brazilian Meeting on Condensed Matter Physics**. São Paulo: Sociedade Brasileira de Física (SBF), 2009, p. 141.

COSTA SILVA, E.; GUSMÃO, L.A.P.; HALL BARBOSA, C.; COSTA MONTEIRO, E. (2009d). High Sensitivity Triaxial Magnetic Field Transducer, Based on the Phase Characteristics of the GMI Effect. In: XIX IMEKO World Congress, Lisboa, 2009. **Proceedings of the XIX IMEKO World Congress**, 2009, p. 1755-1759.

COSTA SILVA, E. **Desenvolvimento de Transdutor Baseado na Fase da Magnetoimpedância Gigante para Medição de Campos Biomagnéticos**. Rio de Janeiro, 2010. Dissertação de Mestrado - Programa de Pós-graduação em Metrologia, Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio).

COSTA SILVA, E.; GUSMÃO, L.A.P.; HALL BARBOSA, C. H.; COSTA MONTEIRO, E.; MACHADO, F. L. A. (2011a). High sensitivity giant magnetoimpedance (GMI) magnetic transducer: magnitude versus phase sensing. **Measurement Science and Technology**, v. 22, p. 1-9, 2011.

COSTA SILVA, E.; GUSMÃO, L.A.P.; HALL BARBOSA, C.H.; COSTA MONTEIRO, E.; MACHADO, F. L. A. (2011b). Sensitivity improvement of GMI magnetic and pressure transducers for biomedical measurements. **Revista Brasileira de Engenharia Biomédica**, v. 27, p. 79-89, 2011.

COSTA SILVA, E. **Magnetômetros GMI de Alta Sensibilidade para Medição de Campos Magnéticos Ultra-fracos**. Rio de Janeiro, 2013. Tese de Doutorado - Programa de Pós-graduação em Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio).

CRASTO, R.V.P. **Magnetômetro de Fluxo Saturado (Fluxgate) em Arranjo Gradiométrico para Detecção de Dutos e Cabos**. Departamento de Eletrônica, Escola de Engenharia, Universidade Federal do Rio de Janeiro, UFRJ, Rio de Janeiro, RJ, Brasil, Julho, 2003.

DAVIS, L. **Handbook of Genetic Algorithms**, VNR Comp. Library, 1990.

DELOOZE, P.; PANINA, L.V.; MAPPS, D.J.; UENO, K.; SANO, H. Effect of transverse magnetic field on thin film magnetoimpedance and application to magnetic recording. **J. Magn. Magn. Mater.**, v. 272–276, p. 2266–2268, 2004.

DORNELES, L.S. **Interações Magnéticas e Magnetoresistência em $\text{CO}_{10}\text{CU}_{90}$** . Porto Alegre, 1997. Dissertação de Mestrado – Programa de Pós-graduação em Física, Universidade Federal do Rio Grande do Sul (UFRGS).

DUQUE, J.G.S. **Magnetoimpedância Gigante Linear e Não-linear em Ligas Amorfais**. Campinas, 2005. Tese de Doutorado – Programa de Pós-graduação do Instituto de Física “Gleb Wataghin”, Universidade Estadual de Campinas (UNICAMP).

FAUSETT, L. **Fundamentals of neural networks**. Prentice Hall: New York, 1994.

FILARDO, J.V. **Perdas Magnéticas**. Curitiba: UFPR, 200-. Disponível em: <<http://www.eletrica.ufpr.br/piazza/materiais/JulianoFilardo.pdf>>. Acesso em: 20 jun. 2012.

FOGEL, D.B. An Introduction to Simulated Evolutionary Computation, **IEEE Transactions on Neural Networks**, 5(1): 3-14, 1994.

GARCIA, J.M.; SINNECKER, J.P.; ASENJO, A.; VAZQUEZ, M. Enhanced magnetoimpedance in CoP electrodeposited microtubes. **J. Magn. Magn. Mater.**, v. 226-230, p. 704–706, 2001.

GELIANG, Y.; XIONGZHU, B.; BO, Y.; YUNLONG, L.; CHAO, X. Differential-type GMI magnetic sensor based on longitudinal excitation. **IEEE Sensors Journal**, v. 11, n. 10, p. 2273-2278, 2011.

GOLDBERG, D.E. **Genetic algorithms in search, optimization and machine learning**. Addison-Wesley Publishing Company, Inc.1989, 372 p, ISBN 0201157675.

GONÇALVES, L.A.P. **Efeito hall planar e magnetoimpedância gigante em liga ferromagnética amorfa Co₇₀Fe₅Si₁₅B₁₀**. Recife, 2006. Tese de Doutorado - Programa de Pós-graduação em Ciência de Materiais, Universidade Federal de Pernambuco (UFPE).

GUSMÃO, L.A.P.; CAVALCANTI, F.M.P.; HALL BARBOSA, C.; COSTA MONTEIRO, E.; MACHADO, F.L.A. Desenvolvimento de Transdutor Magnético baseado em Magnetoimpedância Gigante. In: 6th International Seminar on Electrical Metrology (SEMETRO), Rio de Janeiro, 2005. **Proceedings of the 6th International Seminar on Electrical Metrology (SEMETRO)**, 2005, p. 158-161.

HAUSER, H.; STEINDL, R.; HAUSLEITNER, C.; POHL, A.; NICOLICS, J. Wirelessly interrogable magnetic field sensor utilizing giant magnetoimpedance effect and surface acoustic wave devices. **IEEE Instrum. Meas.**, v. 49, p. 648–652, 2000.

HAUSER, H.; KRAUS, L.; RIPKA, P. Giant magnetoimpedance sensors. **IEEE Instrum. Meas. Mag.**, v. 4, n. 2, p. 28–32, 2001.

HAYKIN, S. **Redes Neurais. Princípios e prática**. Porto Alegre, RS: Bookman, 2001.

HOLLAND, J.H. **Adaptation in Natural and Artificial Systems**, University of Michigan Press, 1975.

HOLLAND, J.H. **Adaptation in Natural and Artificial Systems**”, 2nd edition, The MIT Press, 1992.

HONKURA, Y. Development of amorphous wire type MI sensors for automobile use. **J. Magn. Magn. Mater.**, v. 249, p. 375–377, 2002.

KIM, C.G.; JANG, K.J.; KIM, H.C.; YOON, S.S. Asymmetric giant magnetoimpedance in field-annealing Co-based amorphous ribbon. **J. Appl. Phys.**, v. 85, p. 5447-5449, 1999.

KIM, D.J.; PARK, D.G.; HONG, J.H. Nondestructive evaluation of reactor pressure vessel steels using the giant magnetoimpedance sensor. **J. Appl. Phys.**, v. 91, n. 10, p. 7421–7423, 2002.

KNOBEL, V.; PIROTA, K.R. Giant magnetoimpedance concepts and recent progress. **J. Magn. Magn. Mater.**, v. 242, p. 33–40, 2002.

KRAUS, L. GMI modeling and material optimization. **Sens. Actuators A**, v. 106, p. 187–194, 2003.

KURLYANDSKAYA, G.V.; SANCHEZ M.L.; HERNANDO, B.; PRIDA, V.M.; GORRIA, P.; TEJEDOR, M. Giant magnetoimpedance based sensitive element as a model for biosensors. **Appl. Phys. Lett.**, v. 82, p. 3053–3055, 2003.

KURLYANDSKAYA, G.V.; MIYAR, V.F. Surface modified amorphous ribbon based magnetoimpedance biosensor. **Biosensors and Bioelectronics**, v. 22, p. 2341–2345, 2007.

LENZ, J.E. A review of magnetic sensors. **Proc. IEEE**, v. 78, n. 6, p. 973–989, 1990.

LENZ, J.; EDELSTEIN, A.S. Magnetic Sensors and Their Applications. **IEEE Sensors Journal**, v. 6, n. 3, p. 631–649, 2006.

LIEBERMANN, H.H.; GRAHAM, C.D. IEEE Trans. Magn. **MAG-12**, 921 (1976).

LOPES, J.T.B. Estrutura e Propriedades dos Materiais: Estruturas Amorfas. Disponível em: <<http://jorgeteofilio.files.wordpress.com/2013/10/epm-apostila-capitulo07.pdf>>. Acesso em: 20 jun. 2012.

LORENA, H.N.S.R. Redes Neurais na previsão de Séries Temporais. In: I WorkComp-Sul, Santa Catarina, 2004. **Anais do I WorkComp-Sul**, 2004.

MACHADO, F.L.A.; SILVA, B.L.; MONTARROYOS, E. **Journal of Applied Physics**, 73 (10) 6387 (1993).

MACHADO, F.L.A.; SILVA, B.L.; REZENDE, S.M.; MARTINS, C.S. Giant ac magnetoresistance in the soft ferromagnet $\text{Co}_{70.4}\text{Fe}_{4.6}\text{Si}_{15}\text{B}_{10}$. **Journal of Applied Physics**, v. 75, n. 10, p. 6563–6565, 1994.

MACHADO, F.L.A.; MARTINS, C.S.; REZENDE, S.M. Giant magnetoimpedance in the ferromagnet $\text{Co}_{70-x}\text{Fe}_x\text{Si}_{15}\text{B}_{10}$. **Physical Review B**, v. 15, p. 3926, 1995.

MACHADO, F.L.A.; RODRIGUES, A.R.; PUÇA, A.A.; DE ARAÚJO, A.E.P. Highly Asymmetric Giant Magnetoimpedance. **Mater. Sci. Forum**, v. 302–303, n. 202–208, 1999.

MAHDI, A.E.; PANINA, L.; MAPPS, D. Some new horizons in magnetic sensing: high- T_c SQUIDS, GMR and GMI materials. **Sensors and Actuators A**, v. 105, p. 271–285, 2003.

MAKHANOVSKIY, D.P.; PANINA, L.V.; MAPPS, D.J. Asymmetric Magnetoimpedance in as-cast CoFeSiB Amorphous Wires due to ac Bias. **Appl. Phys. Lett.**, v. 77, p. 121-123, 2000.

MAKHANOVSKIY, D.P.; PANINA, L.V.; MAPPS, D.J. Field-dependent surface impedance tensor in amorphous wires with two types of magnetic anisotropy: Helical and circumferential. **Phys. Rev. B**, v. 63, 144424, 2001.

MANDAL, K.; GHATAK, S.K. **Physical Review B**, 47 (21) 14233 (1993).

MEHRABIAN, R.; KEAR, B.H.; COHEN, M. **Rapid solidification processing: principles and technologies**. Baton, Rouge, LA: Claitor's Pub. Div., 1978, p. 78–83.

MENDES, K.C. **Estudo da magneto-impedância gigante e do efeito hall em fitas amorfas de $\text{Co}_{70.4}\text{Fe}_{4.6}\text{Si}_{15}\text{B}_{10}$** . João Pessoa, 2000. Tese de Doutorado – Coordenação de Pós-graduação em Engenharia Elétrica, Universidade Federal da Paraíba (UFPB).

MICHALEWICZ, Z. **Genetic Algorithms + Data Structures = Evolution Programs**. Springer, USA, 1996, 387p, ISBN 3540606769.

MITCHELL, M. **An Introduction to Genetic Algorithms**. Boston, Massachusetts, USA: The MIT Press, 1996, 217p, ISBN-10 0-262-13316-4, ISBN-13 978-0-262-13316-6.

MOHRI, K.; KAWASHIMA, K.; KOHZAWA, T.; YOSHIDA, H. Magneto-inductive element. **IEEE Transactions on Magnetics**, v. 29, n. 2, p. 1245-1248, 1993.

PACHECO, M.A.C. Algoritmos Genéticos: Princípios e Aplicações. Disponível em: <<http://www.ica.ele.puc-rio.br/downloads/38/ce-apostila-comp-evol.pdf>>. Acesso em: 20 jun. 2012.

PANINA, L.V.; MOHRI, K.; UCHIYAMA, T.; NODA, M.; BUSHIDA, K. Giant magneto-impedance in Co-rich amorphous wires and films. **IEEE Transactions on Magnetics**, v. 31, n. 2, p.1249-1260, 1995.

PANINA, L.V.; MOHRI, K. Magneto-impedance in multilayer films. **Sens. Actuators A**, v. 81, p. 71–77, 2000.

PANINA, L.V. Asymmetrical giant magneto-impedance (AGMI) in amorphous wires. **Journal of Magnetism and Magnetic Materials**. v. 249, p. 278-287, 2002.

PHAN, M.H.; YU, S.C.; KIM, C.G.; VAZQUEZ, M. Origin of asymmetrical magnetoimpedance in a Co-based amorphous microwire due to dc bias current. **Appl. Phys. Lett.**, v. 83, p. 2871–2873, 2003.

PHAN, Manh-Huong; PENG, Hua-Xin. Giant magnetoimpedance materials: Fundamentals and applications. **Progress in Materials Science**, v. 53, p. 323-420, 2008.

PIROTA, K.R. Magnetoimpedância Gigante em Materiais Ferromagnéticos Amorfos: Uma Breve Introdução. **Revista Physicae**, v. 1, p. 37-44, 2000.

PIROTA, K.R. **Magnetoimpedância Gigante em Fios e Fitas Amorfos**. Campinas, 2002. Tese de Doutorado - Programa de Pós-graduação do Instituto de Física *Gleb Wataghin*, Universidade Estadual de Campinas (UNICAMP).

PIROTA, K.R.; KNOBEL, M.; GOMEZ-POLO, C. Recent experiments and models on giant magnetoimpedance. **Physica B**, v. 320, p. 127–134, 2002.

RAMOS LOUZADA, D.; HALL BARBOSA, C.; GUSMÃO, L.A.P.; CAVALCANTI, F.M.P.; COSTA MONTEIRO, E.; MACHADO, F.L.A. Desenvolvimento de transdutor de pressão de alta sensibilidade, baseado no fenômeno de magnetoimpedância gigante, para aplicação biomédica. In: XX CBEB - Congresso Brasileiro de Engenharia Biomédica, São Paulo, 2006. **Anais do XX CBEB**, 2006, p. 1267-1270.

RAMOS LOUZADA, D.; COSTA MONTEIRO, E.; GUSMÃO, L.A.P.; HALL BARBOSA, C. Medição não-invasiva de ondas de pulso arterial utilizando transdutor de pressão MIG. In: IV Latin American Congress on Biomedical Engineering, CLAIB2007, Isla Margarita, Venezuela, 2007. **IFMBE Proceedings CLAIB2007**, Carmen Mueller-Karger, Sara Wong, Alexandra La Cruz (Eds.), 2007, v. 18, p. 436–439.

RIPKA, P. **Magnetic Sensors and Magnetometers**, Artech House Publishers, 2001.

RIPKA, P. Advances in fluxgate sensors. **Sensors and Actuators A**, v. 106, p. 8–14, 2003.

SINNECKER, J.P. Materiais Magnéticos Doces e Materiais Ferromagnéticos Amorfos. **Revista Brasileira de Ensino de Física**, vol. 22, no. 3, Setembro, 2000.

SINNECKER, J.P.; GARCIA, J.M.; ASENJO, A.; VAZQUEZ, M.; GARCIA-ARRIBAS, A. Giant magnetoimpedance in CoP electrodeposited microtubes. **J. Mater. Res.**, v. 15, p. 751–755, 2000a.

SINNECKER, J.P.; KNOBEL, M.; PIROTA, K.R.; GARCIA, J.M.; ASENJO, A.; VAZQUEZ, M. Frequency dependence of the magnetoimpedance in amorphous CoP electrodeposited layers. **J. Appl. Phys.**, v. 87, p. 4825–4827, 2000b.

SOMMER, R.L.; CHIEN, C.L. **Applied Physical Letters**, 67 (22) 3346 (1995).

SOMMER, R.L.; CHIEN, C.L. **Physical Review B**, 53 (10) 5982-5985 (1996).

TEHRANCHI, M.M.; RANJBARAN, M.; EFTEKHARI, H. Double core giant magneto-impedance sensors for the inspection of magnetic flux leakage from metal surface cracks. **Sensors and Actuators A: Physical**, v. 170, n. 1-2, p. 55-61, 2011.

TOTSU, K.; HAGA, Y.; ESASHI, M. Three-axis magnetoimpedance effect sensor system for detecting position and orientation of catheter tip. **Sens. Actuators A**, v. 111, p. 304–309, 2004.

UCHIYAWA, T.; MOHRI, K.; ITHO, H.; NAKASHIMA, K.; OHUCHI, J.; SUDO, Y. Car traffic monitoring system using MI sensor built-in disk set on the road. **IEEE Trans. Magn.**, v. 36, p. 3670–3672, 2000.

UCHIYAMA, T.; NAKAYAMA, S.; MOHRI, K.; BUSHIDA, K. Biomagnetic field detection using very high sensitivity magnetoimpedance sensors for medical applications. **Phys. Status Solidi A**, v. 206, n. 4, p. 639–643, 2009.

VALENZUELA, R.; VAZQUEZ, M.; HERNANDO, A. A position sensor based on magnetoimpedance. **J. Appl. Phys.**, v. 79, p. 6549–6591, 1996.

XIAO, S.Q.; LIU, Y.H.; DAI, Y.Y.; ZHANG, L.; ZHOU, S.X.; LIU, G.D. Giant magnetoimpedance effect in sandwiched films. **J. Appl. Phys.**, v. 85, p. 4127–4130, 1999.

YELON, A.; MÉNARD, D.; BRITEL, M.; CIUREANU, P. Calculations of giant magnetoimpedance and of ferromagnetic resonance response are rigorously equivalent. **Appl. Phys. Lett.**, v. 69, p. 3084–3085, 1996.

ZHAO, WEN; BU, XIONGZHU; YU, GELIANG; XIANG, CHAO. Feedback-type giant magneto-impedance sensor based longitudinal excitation. **Journal of Magnetism and Magnetic Materials**, v. 324, n. 19, p. 3073-3077, 2012.