

**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE**  
**CENTRO DE CIÊNCIAS E TECNOLOGIA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA**

IDENTIFICAÇÃO DA HISTERESE TÉRMICA DE ATUADORES DE LIGAS  
COM MEMÓRIA DE FORMA USANDO REDES NEURAS ARTIFICIAIS

Luiz Fernando Alves Rodrigues

Campina Grande

Agosto/2011

**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE**  
**CENTRO DE CIÊNCIAS E TECNOLOGIA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA**

IDENTIFICAÇÃO DA HISTERESE TÉRMICA DE ATUADORES DE LIGAS  
COM MEMÓRIA DE FORMA USANDO REDES NEURAIS ARTIFICIAIS

Luiz Fernando Alves Rodrigues

Dissertação apresentada ao Programa de  
Pós-Graduação em Engenharia Mecânica  
como requisito parcial à obtenção do título  
de MESTRE EM ENGENHARIA  
MECÂNICA

Orientadores: Dr. Carlos José de Araújo  
Dr. Cícero da Rocha Souto

Agência Financiadora: CNPq

Campina Grande  
Agosto/2011

FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECA CENTRAL DA UFCG

R696i Rodrigues, Luiz Fernando Alves  
Identificação da Histerese Térmica de Atuadores de Ligas com  
Memória de Forma Usando Redes Neurais Artificiais / Rodrigues, Luiz  
Fernando Alves. — Campina Grande, 2011.  
119 f. : il. ; col.

Dissertação (Mestrado em Engenharia Mecânica) – Universidade  
Federal de Campina Grande, Centro de Ciências e Tecnologia.  
Referências.

Orientadores: Prof. Dr. Carlos José de Araújo e Prof. Dr. Cícero da  
Rocha Souto.

1. Ligas com Memória de Forma. 2. Atuadores de LMF. 3. Materiais  
Inteligentes. 4. Redes Neurais Artificiais. 5. Simulação. I.  
Título.

CDU – 621 (043)

UFCG - BIBLIOTECA - CAMPUS I	
22-11-11	4044-11
deaca	

IDENTIFICAÇÃO DA HISTERESE TÉRMICA DE ATUADORES DE LIGAS COM  
MEMÓRIA DE FORMA USANDO REDES NEURAIS ARTIFICIAIS

Luiz Fernando Alves Rodrigues

Dissertação aprovada em 31 de agosto de 2011, pela banca examinadora  
constituída dos seguintes membros:

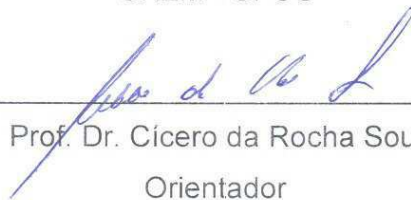
Banca Examinadora:



Prof. Dr. Carlos José de Araújo

Orientador

UAEM - UFCG



Prof. Dr. Cícero da Rocha Souto

Orientador

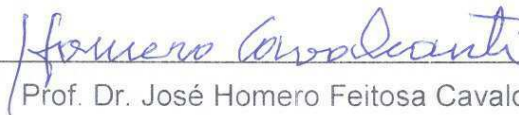
DEE - UFPB



Prof. Dr. Raimundo Carlos Freire Junior

Examinador Externo

DEM - UFRN



Prof. Dr. José Homero Feitosa Cavalcanti

Examinador Externo

Unipê – João Pessoa

## **DEDICATÓRIA**

A minha esposa Tassiana pelo seu enorme amor e carinho e, aos meus pais pelo incentivo nos vários anos de estudos.

## **CURRICULUM VITAE DO CANDIDATO**

- Engenheiro Mecânico pela UFCG (2009).
- Técnico em Mecânica de Manutenção pelo SENAI (2002).

## AGRADECIMENTOS

Primeiramente quero agradecer a Deus por estar sempre comigo em toda a minha vida e possibilitar a concretização de mais esse objetivo de tão grande importância.

Gostaria de agradecer ao professor Dr. Carlos José de Araújo pelo efetivo apoio dado como orientador durante todo o trabalho e, principalmente, na revisão do texto da Dissertação.

Ao professor Dr. Cícero da Rocha Souto pela grande contribuição durante o desenvolvimento da bancada de caracterização eletromecânica e a sua participação como orientador do mestrado.

A Dra. Kelen Cristina Oliveira Crivelaro pela disponibilização de tempo para as discussões sobre Redes Neurais Artificiais e que foram de vital importância para o desenvolvimento da arquitetura neural utilizada no trabalho.

Ao graduando Abdias Gomes dos Santos pelo auxílio durante o desenvolvimento inicial dos programas no Matlab<sup>®</sup>.

A todos que contribuíram direta ou indiretamente para a realização deste trabalho, entre os quais, todos aqueles que fazem parte do meu convívio particular que de alguma forma são parte do sucesso nos trabalhos. Em especial agradeço a minha amada esposa Tassiana Braga Rodrigues pelo apoio durante todo o desenvolvimento da Dissertação, a qual inúmeras vezes me ouviu incansavelmente falar sobre Ligas com Memória de Forma e Redes Neurais Artificiais.

# IDENTIFICAÇÃO DA HISTERESE TÉRMICA DE ATUADORES DE LIGAS COM MEMÓRIA DE FORMA USANDO REDES NEURAS ARTIFICIAIS

## RESUMO

As Ligas com Memória de Forma (LMF) podem recuperar uma deformação plástica por intermédio de um simples aquecimento que origina uma transformação de fase do tipo martensítica termoelástica. Este fenômeno, conhecido por Efeito Memória de Forma (EMF), é especialmente interessante para o desenvolvimento e concepção de atuadores na forma de fios finos ou fitas, já que estes elementos possuem a capacidade de se contrair entre 4 e 8 % do seu comprimento original. Nos casos em que a LMF tem seu deslocamento por EMF restringido, é possível provocar a geração de grandes forças de restituição. Por outro lado, o projeto de estruturas inteligentes usando atuadores de LMF pode ser dificultado em algumas aplicações pela presença de uma histerese térmica intrínseca ao comportamento de EMF. Devido a isso, estudos são frequentemente realizados com a intenção de caracterizar esse fenômeno de histerese para aperfeiçoar as aplicações com atuadores de LMF. Nesse sentido, este trabalho se propõe a usar a técnica de Redes Neurais Artificiais (RNA) para identificar a histerese térmica de atuadores de LMF de NiTi na forma de fios finos sob regime de carregamento isobárico (carga constante) e diferentes formas de aquecimento. Resultados do comportamento histerético foram coletados através de duas bancadas experimentais, sendo uma eletromecânica, que utiliza aquecimento resistivo (efeito Joule) e a outra termomecânica, que realiza o aquecimento por convecção forçada em meio líquido. São apresentados resultados do aprendizado da RNA e verificada a capacidade da rede de estimar o comportamento histerético do atuador de LMF para um comportamento não utilizado no treinamento. De uma forma geral, verificou-se que as RNA foram eficientes na simulação dos laços de histerese do deslocamento sob carga em função tanto da corrente elétrica de ativação quanto da temperatura.

# THERMAL HYSTERESIS IDENTIFICATION ON SHAPE MEMORY ALLOY ACTUATORS USING ARTIFICIAL NEURAL NETWORKS

## ABSTRACT

Shape Memory Alloys (SMA) can recover a induced plastic deformation through a simple heating which originates a thermoelastic martensitic phase transformation. This phenomenon is known as Shape Memory Effect (SME). It is especially interesting for actuators development and conception in the form of thin wires or ribbons because these elements have ability to recover around 4 to 8 % of its original length. If the SMA has its displacement by SME restricted, it is possible the generation of large recover forces when compared with its dimensions. On the other hand, the design of smart structures using SMA actuators can be hard in some applications due intrinsic thermal hysteresis associated with its SME behavior. Because of this, studies are often carried to characterize this hysteresis phenomenon for improve the applications with SMA actuators. In this sense, this work proposes to use Artificial Neural Networks (ANN) technique to identify the thermal hysteresis of NiTi SMA wire actuators under the regime of isobaric loads (constant loads) and different thermal activation modes. Results of hysteretic behavior were collected through two experimental test benches, one electromechanical which uses resistive heating (Joule Effect) and other thermomechanical through performing heat by forced convection in a liquid medium. It was shown the results of ANN learning and network's ability to estimate the hysteretic behavior of the SMA actuators from a behavior not used in training. In general, it was found that the ANN were efficient in the simulation of hysteresis loops under load as function of electrical current or temperature.



## PUBLICAÇÕES

RODRIGUES, L.F.A.; SOUTO, C.R.; DE ARAÚJO, C.J.; CAVALCANTI, J.H.F.  
Simulação do comportamento termomecânico de um atuador de liga com memória de forma utilizando redes neurais artificiais. In: CONGRESSO BRASILEIRO DE ENGENHARIA E CIÊNCIA DOS MATERIAIS, **Anais...** Campos do Jordão - SP. Novembro, 2010.

RODRIGUES, L.F.A.; SANTOS, A.G.; SILVA, A.F.C.; DE ARAÚJO, C.J.; SOUTO, C.R. Simulation of strain hysteresis loops in shape memory alloy actuators using neural networks. PROCEEDINGS OF COBEM 2011, 21<sup>ST</sup> BRAZILIAN CONGRESS OF MECHANICAL ENGINEERING, **Anais...** Natal - RN. Outubro, 2011.

## SUMÁRIO

	Pág.
1. INTRODUÇÃO .....	19
2. OBJETIVOS .....	21
3. MOTIVAÇÃO .....	22
4. REVISÃO BIBLIOGRÁFICA.....	23
4.1. LIGAS COM MEMÓRIA DE FORMA .....	23
4.1.1 <i>Características das ligas com memória de forma</i> .....	23
4.1.2 <i>Métodos de caracterização térmica</i> .....	26
4.1.3 <i>Aplicações</i> .....	27
4.2. REDES NEURAIS ARTIFICIAIS.....	30
4.2.1. <i>Evolução histórica das Redes Neurais Artificiais</i> .....	30
4.2.2. <i>Inspiração na neurociência</i> .....	31
4.2.3. <i>O neurônio biológico</i> .....	32
4.2.4. <i>O neurônio artificial</i> .....	33
4.2.5. <i>Topologia das RNA</i> .....	34
4.2.6. <i>Perceptron</i> .....	35
4.2.7. <i>Algoritmo Backpropagation</i> .....	35
4.2.8. <i>Aplicações de RNA</i> .....	36
4.3. ATUADORES DE LMF E RNA – ESTADO DA ARTE .....	37
5. MATERIAIS E MÉTODOS .....	41
5.1. BANCADA DE CARACTERIZAÇÃO ELETROMECÂNICA.....	42
5.2. BANCADA DE CARACTERIZAÇÃO TERMOMECÂNICA .....	49

5.3. DESENVOLVIMENTO DA ARQUITETURA DA RNA .....	53
<b>6. RESULTADOS E DISCUSSÕES.....</b>	<b>59</b>
6.1. IDENTIFICAÇÃO DA HISTERESE ELETROMECÂNICA .....	59
<i>6.1.1. Identificação usando uma camada escondida.....</i>	<i>62</i>
<i>6.1.2. Identificação usando duas camadas escondidas.....</i>	<i>68</i>
6.2. IDENTIFICAÇÃO DA HISTERESE TERMOMECÂNICA.....	71
<i>6.2.1. Identificação usando uma camada escondida.....</i>	<i>71</i>
<i>6.2.2. Identificação usando duas camadas escondidas.....</i>	<i>76</i>
<b>7. CONCLUSÕES.....</b>	<b>80</b>
<b>8. SUGESTÕES PARA PESQUISAS FUTURAS .....</b>	<b>82</b>
<b>9. REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>83</b>
<b>APÊNDICES .....</b>	<b>86</b>
APÊNDICE A .....	86
APÊNDICE B .....	95
APÊNDICE C .....	97
APÊNDICE D .....	100
APÊNDICE E .....	108
APÊNDICE F .....	111
<b>ANEXOS.....</b>	<b>119</b>
ANEXO A.....	119

## ÍNDICE DE TABELAS

Pag.

Tabela 1. Lista de algoritmos utilizados na identificação do banco de dados de VRE-temperatura. ....	56
--	----

## ÍNDICE DE FIGURAS

	Pág.
Figura 1. Representação esquemática do EMF de uma LMF de NiTi. (a) Mecanismo interno da transformação martensítica. (b) Curva tensão – deformação da estrutura martensítica. (adaptada de Williams, 2010).....	24
Figura 2. Comportamento termomecânico de um atuador de LMF sob carga. (a) Realização de trabalho mecânico (adaptado de Song et al, 2003). (b) Comportamento deformação-temperatura de um atuador de LMF em função do carregamento externo (adaptado de Lagoudas, 2008).....	25
Figura 3. Diagrama esquemático do fenômeno de superelasticidade das LMF. (adaptado de Williams, 2010). .....	25
Figura 4. Ilustração de uma curva deformação-temperatura de uma LMF.....	27
Figura 5. Aplicação de barras de LMF (em inglês <i>Shape Memory Alloys – SMA</i> ) em um avião de testes da Boeing (Mabe et al, 2006 apud Lagoudas, 2008)..	28
Figura 6. Uso de LMF superelástica na armação de óculos (Lagoudas, 2008). .....	28
Figura 7. Protótipo de mão desenvolvida com atuadores de LMF (Fariás et al, 2009).....	29
Figura 8. Neurônio Biológico (Mecânica atual, 2011). .....	32
Figura 9. Neurônio Artificial de McCulloch e Pitts (apud Rauber, 2010).....	33
Figura 10. Funções de transferência (adaptado de Rauber, 2010). .....	34
Figura 11. Topologias de redes neurais artificiais (Rauber, 2010).....	34
Figura 12. Classificação estrutural e funcional de redes neurais artificiais (Rauber, 2010). .....	35
Figura 13. Plataforma experimental desenvolvida para coleta dos dados do comportamento de um fio atuador de LMF (adaptado de Song et al, 2003). ..	38
Figura 14. Ativação e resposta do atuador de LMF. (a) Tensão aplicada e corrente elétrica medida em função do tempo. (b) Histerese do Deslocamento	

em função da Tensão elétrica. (c) Relação deslocamento-tempo. (adaptado de Song et al, 2003).....	39
Figura 15. Resposta do controle usando RNA. (a) Simulação usando RNA sobre os dados experimentais. (b) Controle de posição do atuador de LMF...	40
Figura 16. Fluxograma da metodologia adotada no trabalho.....	41
Figura 17. Bancada de caracterização eletromecânica (adaptada do trabalho de .....	43
Figura 18. Diagrama de blocos do funcionamento da bancada eletromecânica. ....	43
Figura 19. Interface do programa em LabVIEW <sup>®</sup> para ativação e coleta da resposta do fio de LMF na BCE. ....	44
Figura 20. Temperaturas de transformação de fase do atuador de LMF de NiTi. ....	45
Figura 21. Esquema do treinamento por ciclagem elétrica sob carga empregado na estabilização do atuador de LMF de NiTi. ....	46
Figura 22. Ciclagem para estabilização do deslocamento do fio de LMF de NiTi sob carga de 200 MPa. Evolução dos laços de histerese do deslocamento como função da corrente elétrica.....	47
Figura 23. Ativação do fio de NiTi submetido a uma onda triangular de corrente e carga de 200 MPa. (a) Variação do deslocamento em função do tempo. (b) Laços de histerese de deslocamento em função da corrente elétrica. ....	47
Figura 24. Ativação do fio de NiTi submetido a uma onda triangular reduzida de corrente e carga de 200 MPa. (a) Variação do deslocamento em função do tempo. (b) Laços de histerese de deslocamento em função da corrente elétrica. ....	48
Figura 25. Ilustração do funcionamento da BCT operando no modo de tração. Fonte: Nascimento Neto (2007). ....	49
Figura 26. Fotografia da BCT desenvolvida por Nascimento Neto (2007). (1) Estrutura rígida. (2) Cabo de tração. (3) Sensor de deslocamento LVDT. (4) Haste móvel. (5) Garra de tração. (6) Carga de tração. (7) Banho termoregulável. (8) Fonte de tensão e corrente. (9) Sistema de aquisição de dados. ....	50

Figura 27. Comportamento termomecânico isobárico do fio de NiTi de 1,5 mm de diâmetro. Curvas deformação – temperatura para diversos níveis de carga. ....	52
Figura 28. Superposição das curvas de histerese deformação – temperatura da .....	53
Figura 29. Diagrama de blocos da arquitetura neural usada para identificação da histerese de atuadores LMF. ....	54
Figura 30. Esquema da disponibilização dos experimentais a entrada da RNA. ....	55
Figura 31. RNA de apenas uma entrada e uma saída.....	59
Figura 32. Superposição da simulação da RNA sobre os dados experimentais do fio de LMF de NiTi sob 200 MPa e ativado por onda de corrente elétrica triangular. (a) Deslocamento-Tempo. (b) Deslocamento-Corrente Elétrica. ....	60
Figura 33. Erro de simulação da RNA em função do número de neurônios da rede.....	60
Figura 34. Superposição da simulação da RNA sobre os dados experimentais do fio de LMF NiTi sob 200 MPa e ativado por onda de corrente elétrica triangular reduzida. (a) Deslocamento-Tempo. (b) Deslocamento-Corrente Elétrica. ....	61
Figura 35. Erro da simulação da RNA em função do número de neurônios....	61
Figura 36. Superposição da simulação da RNA treinada com uma camada escondida, sobre os dados experimentais do fio de LMF NiTi para: (a) 150 MPa, (b) 250 MPa usados no treinamento da RNA e (c) 200 MPa usado para verificar o grau de estimação da RNA. ....	63
Figura 37. Evolução do erro da RNA treinada com uma camada escondida na simulação dos dados experimentais do fio de LMF NiTi submetido a 150 MPa, 250 MPa (treinamento) e 200 MPa (estimação). ....	64
Figura 38. Superposição da simulação da RNA treinada com uma camada escondida sobre os dados experimentais do fio de LMF NiTi para: (a) 100 MPa, (b) 200 MPa usados no treinamento da RNA e (c) 150 MPa usado para verificar o grau de estimação da RNA. ....	65

Figura 39. Evolução do erro da RNA treinada com uma camada escondida na simulação dos dados experimentais do fio de LMF NiTi submetido a 100 MPa, 200 MPa (treinamento) e 150 MPa (estimação). .....	66
Figura 40. Superposição da simulação da RNA treinada com uma camada escondida sobre os dados experimentais do fio de LMF NiTi para: (a) 50 MPa, (b) 150 MPa usados no treinamento da RNA e (c) 100 MPa usado para verificar o grau de estimação da RNA. ....	67
Figura 41. Evolução do erro da RNA treinada com uma camada escondida na simulação dos dados experimentais do fio de LMF NiTi submetido a 50 MPa, 150 MPa (treinamento) e 100 MPa (estimação). ....	67
Figura 42. Superposição da simulação da RNA treinada com duas camadas escondidas sobre os dados experimentais para: (a) 150 MPa, (b) 250 MPa usados no treinamento da RNA e (c) 200 MPa usado para verificar o grau de estimação da RNA. ....	68
Figura 43. Superposição da simulação da RNA treinada com duas camadas escondidas sobre os dados experimentais para: (a) 100 MPa, (b) 200 MPa usados no treinamento da RNA e (c) 150 MPa usado para verificar o grau de estimação da RNA. ....	69
Figura 44. Superposição da simulação da RNA treinada com duas camadas escondidas sobre os dados experimentais para: (a) 50 MPa, (b) 150 MPa usados no treinamento da RNA e (c) 100 MPa usado para verificar o grau de estimação da RNA. ....	70
Figura 45. Superposição da simulação da RNA treinada com uma camada escondida sobre os dados experimentais para: (a) 150 MPa, (b) 250 MPa usados no treinamento da RNA e (c) 200 MPa usado para verificar o grau de estimação da RNA. ....	71
Figura 46. Evolução do erro da RNA treinada com uma camada escondida na simulação dos dados experimentais do fio de LMF NiTi submetido a 150 MPa, 250 MPa (treinamento) e 200 MPa (estimação). ....	72
Figura 47. Superposição da simulação da RNA treinada com uma camada escondida sobre os dados experimentais para: (a) 100 MPa, (b) 200 MPa	



usados no treinamento da RNA e (c) 150 MPa usado para verificar o grau de estimaco da RNA. ....	73
Figura 48. Evoluo do erro da RNA treinada com uma camada escondida na simulao dos dados experimentais do fio de LMF NiTi submetido a 100 MPa, 200 MPa (treinamento) e 150 MPa (estimaco). ....	73
Figura 49. Superposio das curvas experimentais do comportamento do fio de NiTi sob os carregamentos de 50 MPa, 100 MPa e 150 MPa. ....	74
Figura 50. Superposio da simulao da RNA treinada com uma camada escondida sobre os dados experimentais para: (a) 50 MPa, (b)150 MPa usados no treinamento da RNA e (c) 100 MPa usado para verificar o grau de estimaco da RNA. ....	75
Figura 51. Evoluo do erro da RNA treinada com uma camada escondida na simulao dos dados experimentais do fio de LMF NiTi submetido a 50 MPa, 150 MPa (treinamento) e 100 MPa (estimaco). ....	75
Figura 52. Superposio da RNA treinada com duas camadas escondidas sobre os dados experimentais para: (a) 150 MPa, (b) 250 MPa (treinamento) e (b) 200 MPa (estimaco). ....	77
Figura 53. Superposio da RNA treinada com duas camadas escondidas sobre os dados experimentais para: (a) 100 MPa, (b) 200 MPa (treinamento) e (c) 150 MPa (estimaco). ....	78
Figura 54. Superposio da RNA treinada com duas camadas escondidas sobre os dados experimentais para: (a) 50 MPa, (b) 150 MPa (treinamento) e (c) 100 MPa (estimaco). ....	79

## SÍMBOLOS E ABREVIACÕES

$\Delta L$ . <i>Deslocamento</i>	Matlab. <i>Programa de Cálculo Numérico</i>
$\Sigma$ . <i>Somador</i>	Mf. <i>Final da formação de martensita</i>
Af. <i>Final da formação de austenita</i>	MLP. <i>Perceptron de Múltiplas Camadas</i>
As. <i>Início da formação de austenita</i>	Ms. <i>Início da formação de martensita</i>
Backpropagation. <i>Algoritmo backpropagation</i>	NA. <i>Neurônio Artificial</i>
BCE. <i>Bancada de Caracterização Eletromecânica</i>	NB. <i>Neurônio Biológico</i>
BCT. <i>Bancada de Caracterização Termomecânica</i>	RMS. <i>Root-Mean-Square</i>
d. <i>Atraso (delay)</i>	RNA. <i>Redes Neurais Artificiais</i>
DSC. <i>Calorimetria Diferencial de Varredura</i>	S1. <i>Saída 1</i>
E1. <i>Entrada 1</i>	S2. <i>Saída 2</i>
E2. <i>Entrada 2</i>	SMA. <i>Shape Memory Alloys</i>
EMF. <i>Efeito Memória de Forma</i>	T. <i>Temperatura</i>
$g_k$ . <i>Gradiente</i>	traincgf. <i>Algoritmo Conjugate Gradient Backpropagation with Fletcher-Reeves Restarts</i>
H. <i>Histerese</i>	traingd. <i>Algoritmo Gradiente Descent Backpropagation</i>
IA. <i>Inteligência Artificial</i>	traingda. <i>Algoritmo Gradient Descent Backpropagation with Adaptive Learning Rate</i>
Labview. <i>Programa de Controle Digital</i>	Traingdm. <i>Algoritmo Gradient Descent with Momentum Backpropagation</i>
LaMMEA. <i>Laboratório Multidisciplinar de Materiais e Estruturas Ativas</i>	
LMF. <i>Ligas com Memória de Forma</i>	
LVDT. <i>Linear Variable Differential Transformer</i>	

*trainlm. Algoritmo Levenberg-  
Marquardt*

*trainrp. Algoritmo Resilient  
Backpropagation*

*UAEM. Unidade Acadêmica de  
Engenharia Mecânica*

*UFCG. Universidade Federal de  
Campina Grande*

*VRE. Variação de Resistência  
Elétrica*

*$x_1, x_2, \dots, x_d$ . Conexões de entrada*

*$x_d$ . Valor Desejado*

*$x_e$ . Dado Experimental*

*$x_k$ . Vetor de pesos*

*$y$ . Sinal de saída*

*$\alpha_k$ . Taxa de Aprendizado*

*$\epsilon$ . Deformação*

## 1. INTRODUÇÃO

Os materiais inteligentes ou funcionais, têm se destacado dentre as novas tecnologias em desenvolvimento e são estudados em inúmeras pesquisas visando à concepção de novas aplicações em várias áreas do conhecimento humano. Esses materiais avançados podem reagir a impulsos do ambiente externo, tais como os provenientes de campos elétricos e magnéticos, variação de temperatura, intensidade luminosa, entre outros, tornando-se atraentes para aplicações em que essas reações não podem ser supridas por materiais convencionais.

Nesse contexto, destacam-se as Ligas com Memória de Forma (LMF) que são materiais metálicos considerados ativos ou inteligentes por possuírem a surpreendente capacidade de retornar a uma forma anterior a uma deformação plástica induzida, caso seja aplicado um campo de temperatura suficiente para gerar uma transformação de fase reversível, do tipo martensítica termoelástica. Esse fenômeno de recuperação de deformação plástica (nesse caso, pseudo-plástica) por aquecimento é conhecido por Efeito Memória de Forma (EMF) (Otsuka & Wayman, 1998; Lagoudas, 2008).

Como consequência do fenômeno EMF, as LMF produzidas na forma de fios finos ou fitas resultam em atuadores lineares por natureza, apresentando grande potencial para aplicações na robótica, setor automotivo e aeronáutico, medicina e na produção de atuadores miniaturizados em geral. Esse potencial de aplicações é resultado da grande capacidade de geração de força e deslocamento dos atuadores de LMF quando confrontados com as suas dimensões. Outra possibilidade de uso dos atuadores de LMF é na concepção de compósitos ativos, devido às forças de recuperação que podem ser desenvolvidas no interior da estrutura quando do seu aquecimento (Paine & Rogers, 1991; Jang & Kishi, 2005; De Araújo et al, 2008).

Entretanto, o projeto de estruturas inteligentes usando atuadores de LMF pode ser dificultado em algumas aplicações devido à presença de uma histerese térmica intrínseca ao seu comportamento de deslocamento em função da temperatura, associado ao EMF. O desenvolvimento de modelos

matemáticos para estimar esse comportamento pode exigir grande esforço matemático e computacional, sendo de difícil implementação em alguns casos (Lagoudas, 2008; Nascimento et al, 2009).

Por outro lado, trilhando um caminho paralelo ao da área de materiais e estruturas inteligentes, existe a área de pesquisa em inteligência artificial (IA), que inclui diversos métodos e sistemas que buscam reproduzir porções específicas do comportamento inteligente humano, tais como aprendizagem, processamento paralelo de informações, assimilação de padrões, entre outros (Ludwig Jr & Costa, 2007), os quais vêm encontrando cada vez mais aplicações industriais.

Dentre as diversas técnicas disponíveis no campo da IA, têm-se as Redes Neurais Artificiais (RNA), que são sistemas conexionistas baseados no funcionamento do sistema nervoso, especificamente, através dos mecanismos utilizados na unidade fundamental de processamento da informação biológica, ou seja, o neurônio biológico e suas conexões sinápticas (Rojas, 1996; Hagan 1996).

O uso de RNA para identificar a dinâmica da histerese de atuadores de LMF pode contribuir para expandir os limites de aplicação destes materiais inteligentes. Assim, a RNA conhecendo o comportamento do LMF para algumas situações, permitirá a extrapolação do conhecimento para outras situações que venham a acontecer. Além disso, é possível utilizá-la para o desenvolvimento de sistemas de controle dos atuadores de LMF. Considerando o enorme poder de atuação das RNA e a necessidade de se conhecer e prever o comportamento dinâmico de atuadores de LMF foi proposto este trabalho. Nesse caso, a RNA foi utilizada para aprender e prever o comportamento histerético de um atuador de LMF vislumbrando aplicação futura de controle.

## 2. OBJETIVOS

Este trabalho tem por objetivo geral estudar a identificação da histerese térmica de atuadores de ligas com memória de forma usando redes neurais artificiais (RNA).

Em termos específicos, visa:

- Desenvolver uma bancada de caracterização eletromecânica (BCE) para coletar resultados da histerese de atuadores de LMF de NiTi com ativação por corrente elétrica;
- Obter o comportamento histerético de atuadores de LMF de NiTi sob aplicação de diferentes carregamentos mecânicos e ondas de ativação por corrente elétrica;
- Identificar a dinâmica térmica de atuadores de LMF de NiTi usando RNA a partir de bancos de dados obtidos de uma bancada de caracterização termomecânica (BCT).
- Estimar o comportamento de histerese dos atuadores de LMF usando RNA.

### 3. MOTIVAÇÃO

Nesse trabalho, busca-se desenvolver um método eficiente para identificar a dinâmica do comportamento da histerese térmica de atuadores de LMF de NiTi para futura aplicação em trabalhos de controle do deslocamento destes atuadores via controlador inteligente a ser desenvolvido a partir de RNA. Desta forma, é necessário preliminarmente usar RNA para aprender as relações de deformação em função da temperatura e deslocamento em função da corrente elétrica dos atuadores de LMF a partir de bancos de dados obtidos de bancadas experimentais de caracterização térmica e elétrica, respectivamente. Trata-se do desenvolvimento de um método importante para o projeto de sistemas inteligentes que utilizem este tipo de material avançado (Song et al, 2003; Tai & Ahn, 2011).

Nesse sentido, observa-se que as aplicações de atuadores de LMF se restringem hoje, em boa parte, a controles do tipo “on-off” (ligado-desligado). Esse fato se deve principalmente a presença de uma histerese térmica intrínseca ao comportamento das LMF, o que torna difícil o controle do deslocamento do atuador. Muitas vezes, a magnitude deste fenômeno histerético limita a aplicação de LMF como atuadores.

Nota-se, com base na literatura (Lee, 2001; Song et al, 2003; Asua, 2007; Eyercioglu et al, 2008), que o uso de RNA para identificação do comportamento de LMF é possível. No Brasil, existem poucas pesquisas referentes aos atuadores de LMF e principalmente quanto ao seu uso conjugado com a técnica de RNA. Sendo assim, pela real necessidade de se conhecer mais profundamente o comportamento histerético desses materiais foi desenvolvido este trabalho.

## 4. REVISÃO BIBLIOGRÁFICA

### 4.1. Ligas com Memória de Forma

#### 4.1.1 Características das ligas com memória de forma

Quando deformadas plasticamente e sujeitas a um carregamento térmico apropriado, as LMF demonstram a capacidade de recuperar a forma anterior à deformação introduzida ou de gerar grandes forças de restituição caso restringindo seu retorno de forma. Essa propriedade está associada a uma transformação de fase no estado sólido, dependente da temperatura, do tipo martensítica termoelástica (Otsuka & Wayman, 1998). Este fenômeno é particularmente interessante para a produção de microatuadores e desenvolvimento de máquinas miniaturizadas, a partir dessas ligas (Kohl, 2010). Essa recuperação de forma pode se apresentar apenas no aquecimento (EMF simples – “*one-way shape memory effect*”) ou também no resfriamento (EMF duplo – “*two-way shape memory effect*”).

A Figura 1 ilustra o mecanismo da transformação de fase que gera o fenômeno de EMF, assim como sua resposta macromecânica. Conforme mostra a Figura 1(a), inicialmente tem-se uma LMF a temperatura mais baixa, no estado martensítico-1. Essa estrutura se caracteriza por ser bastante maleável, especialmente se comparada com a martensita do aços. Neste estado a LMF é deformada para um estado aparentemente plástico-3 por um carregamento qualquer, e em seguida, por um simples aquecimento a estrutura da LMF passa para o estado austenítico-1 conferindo a recuperação para uma forma específica. A partir daí, caso ocorra o resfriamento, a LMF voltará ao estado martensítico e um novo ciclo de EMF simples poderá ser iniciado. Na Figura 1(b) é possível visualizar o comportamento tensão-deformação típico de uma LMF no estado martensítico de baixa temperatura. Nessa figura o EMF simples é ilustrado pelo aquecimento de 3 para 1.



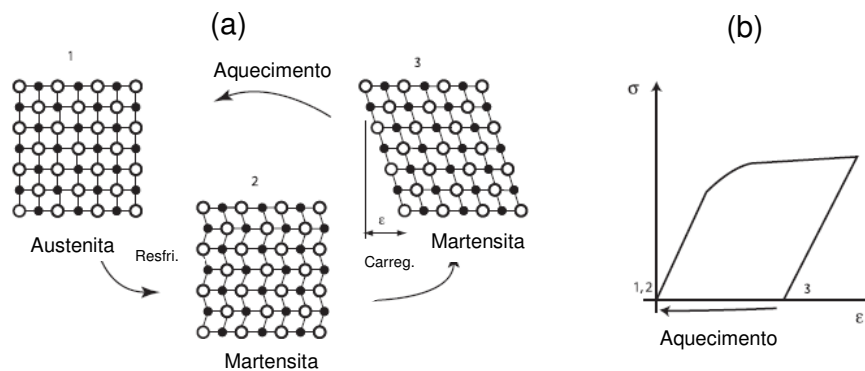


Figura 1. Representação esquemática do EMF de uma LMF de NiTi. (a) Mecanismo interno da transformação martensítica. (b) Curva tensão – deformação da estrutura martensítica. (adaptada de Williams, 2010).

Na Figura 2(a) é ilustrado um atuador de LMF na forma de fio fino sendo usado para levantar um peso, e, portanto, realizar um trabalho mecânico. Quando ocorre o aquecimento por efeito Joule do atuador pré-deformado pela carga externa, origina-se a contração com o conseqüente levantamento da carga. Entretanto, quando é cessada a passagem de corrente elétrica o atuador se resfria e volta a ser deformado pela carga.

Verifica-se na Figura 2(b) o comportamento da deformação em função da temperatura típico de um atuador LMF em função de carregamentos isobáricos impostos. Constata-se que à medida que a carga aumenta é necessário um acréscimo na temperatura (mais energia) para recuperação total da deformação do atuador, que também aumenta (EMF). Ainda nesta figura, pode-se observar a presença de uma histerese em temperatura (H) nas curvas deformação-temperatura, para todos os carregamentos impostos ao atuador de LMF. Essa histerese e o comportamento não linear da relação deformação-temperatura dificultam a utilização do controle clássico de atuadores de LMF. Além disso, a histerese gera um atraso (d - “*delay*”) na resposta desse tipo de atuador, em que um estímulo de entrada é aplicado (temperatura) e só após algum tempo depois o atuador começa a responder.

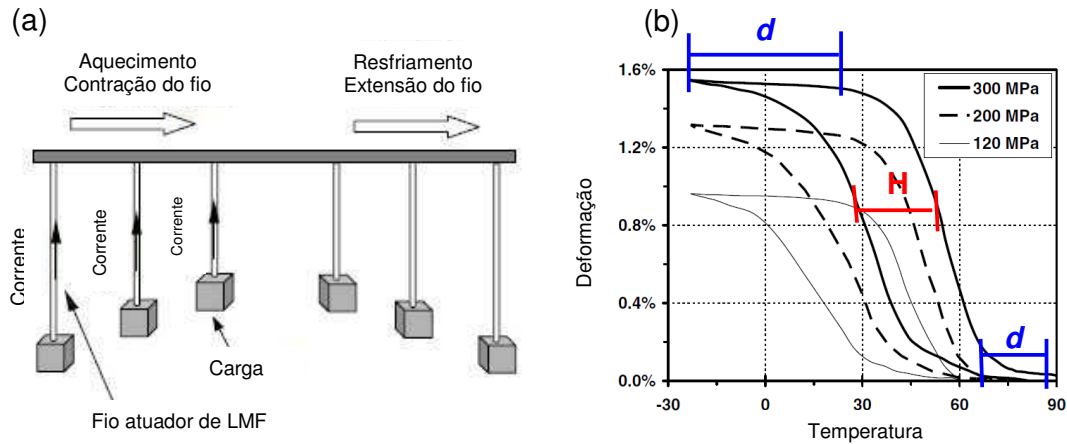


Figura 2. Comportamento termomecânico de um atuador de LMF sob carga. (a) Realização de trabalho mecânico (adaptado de Song et al, 2003). (b) Comportamento deformação-temperatura de um atuador de LMF em função do carregamento externo (adaptado de Lagoudas, 2008).

Outro comportamento termomecânico importante apresentado pelas LMF é o fenômeno de superelasticidade. Neste caso, a LMF é mantida sempre no seu estado mais quente, ou seja, na fase austenítica-1 conforme ilustra a Figura 3. Nesse caso, pode-se induzir a formação de martensita-2 por carregamento mecânico a temperatura constante, ou seja, deformando a LMF. Quando a carga é relaxada, a estrutura martensítica retorna totalmente para a fase austenítica, recuperando a forma anterior sem necessidade de aquecimento. Assim, o comportamento tensão-deformação do fenômeno de superelasticidade envolve grandes deformações reversíveis (1 – 2), que podem atingir valores situados entre 5 % e 10 % em tração.




Figura 3. Diagrama esquemático do fenômeno de superelasticidade das LMF. (adaptado de Williams, 2010).

Vale ressaltar que existe uma grande variedade de materiais que podem apresentar os fenômenos de EMF e superelasticidade, entretanto, do ponto de vista comercial, apenas as LMF com larga faixa de recuperação de forma são interessantes. Desta forma, destacam-se as LMF a base de NiTi, CuAlZn e CuAlNi. Neste trabalho se fará uso apenas do EMF sob carga, de maneira semelhante aquela ilustrada na Figura 2.

#### **4.1.2 Métodos de caracterização térmica**

A caracterização precisa do comportamento termomecânico de uma LMF é realizada fazendo uso de técnicas de análise térmica, como a Calorimetria Diferencial de Varredura (DSC) e a Análise Dinâmico Mecânica (DMA), além de resistência elétrica e ensaios de tração e compressão em função da temperatura (Otsuka & Wayman, 1998; Lagoudas, 2008). Na técnica mais empregada (calorimetria DSC) é feita a medição da quantidade de calor absorvido ou liberado por uma amostra de LMF durante um ciclo térmico (resfriamento e aquecimento) que incorpore as temperaturas de transformação de fase. A partir da utilização do método das tangentes (Otsuka & Wayman, 1998) é possível obter, para a transformação martensítica direta (resfriamento) e reversa (aquecimento), o início e final de formação da martensita ( $M_s$ ,  $M_f$ ) e austenita ( $A_s$  e  $A_f$ ), respectivamente. Estas temperaturas são amplamente difundidas na literatura e determinam de forma quantitativa regiões distintas do comportamento termomecânico das LMF. Mostra-se na Figura 4, a curva típica de um material de LMF semelhante ao exemplo da Figura 2, no regime de deformação-temperatura. A determinação das 4 temperaturas características ( $M_s$ ,  $M_f$ ,  $A_s$  e  $A_f$ ) do comportamento das LMF define a região de atuação do material, juntamente com a histerese térmica (H).

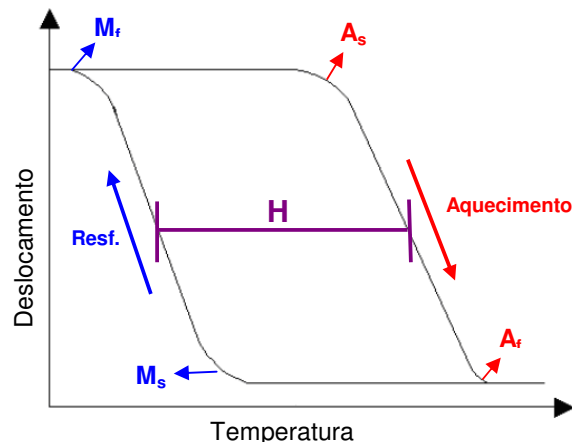


Figura 4. Ilustração de uma curva deformação-temperatura de uma LMF.

### 4.1.3 Aplicações

Diversos setores industriais apresentam potencial para aplicar os comportamentos diferenciados das LMF, entretanto se destacam devido à relações custo-benefício mais favoráveis, as áreas naturalmente mais consumidoras de alta tecnologia como aeroespacial, médica, automotiva, entre outras.

A Figura 5 mostra uma aplicação de barras de LMF de NiTi em um avião da Boeing. Nesse caso a LMF é usada para fazer variar a geometria de uma parte do compartimento externo da turbina (*chevron*), melhorando o desempenho durante o voo a grandes altitudes. Nessa aplicação, devido a grande velocidade e altitude da aeronave, o *chevron* fabricado em LMF se transforma para o estado martensítico, mais maleável, facilitando a deformação das extremidades em “V” para uma forma que melhora o desempenho aerodinâmico do avião, pois facilita a mistura de gases de exaustão reduzindo ruídos.



Figura 5. Aplicação de barras de LMF (em inglês *Shape Memory Alloys – SMA*) em um avião de testes da Boeing (Mabe et al, 2006 apud Lagoudas, 2008).

Na Figura 6 apresenta-se uma aplicação do fenômeno de superelasticidade de uma LMF no uso em armação de óculos, o que confere ao produto uma maior durabilidade.




Figura 6. Uso de LMF superelástica na armação de óculos (Lagoudas, 2008).

Outro exemplo de aplicação médica de LMF, mais precisamente na área de reabilitação robótica, é o desenvolvimento de próteses para membros

superiores do corpo humano. O protótipo de mão atuada por fios finos de LMF mostrado na Figura 7 tem a vantagem de apresentar baixo ruído se comparado com as próteses disponíveis no mercado, normalmente fabricadas usando motores elétricos e mecanismos pneumáticos.



Figura 7. Protótipo de mão desenvolvida com atuadores de LMF (Fárias et al, 2009).

No caso de aplicações para o setor automobilístico, as LMF podem ser usadas como sensores e atuadores de impacto em veículos. O comportamento superelástico gera um efetivo sistema de dissipação de energia de vibração e impacto (Lagoudas, 2008).

Nos dias atuais, sistemas ativos incorporando estes materiais eletro-termo-responsivos estão na fronteira do conhecimento e do interesse tecnológico a nível mundial, conforme demonstra os conceitos aplicativos divulgados no recente trabalho de Sun et al (2012).

Vale ressaltar que aplicações que necessitam de um controle efetivo da posição de atuadores de LMF são de difícil projeto e execução devido a presença da histerese térmica dessas ligas. Nesse contexto, o modelamento matemático é utilizado para aproximar o comportamento histerético da LMF, porém sua implementação muitas vezes é difícil já que a transformação de fase é dependente de diversos parâmetros. Como exemplo, as Equações 1 e 2

mostram o modelo matemático sugerido por Ikuta et al (1991) que permite determinar a fração transformada da LMF no resfriamento e no aquecimento.

$$\xi = \frac{1 - \xi_A}{1 + \exp\left[\frac{6,2}{Mf - Ms} \left(T - \frac{Ms + Mf}{2}\right)\right]} + \xi_A \text{ (resfriamento)} \quad (1)$$

$$\xi = \frac{\xi_m}{1 + \exp\left[\frac{6,2}{Af - As} \left(T - \frac{As + Af}{2}\right)\right]} \text{ (aquecimento)} \quad (2)$$

Uma alternativa a aplicação do modelamento matemático pode ser a utilização de RNA para o aprendizado do comportamento histerético da LMF, que é comparativamente mais simples de ser aplicado e capaz de captar comportamentos dinâmicos, como a inércia térmica de aquecimento por passagem de corrente elétrica, por exemplo.

## 4.2. Redes Neurais Artificiais

### 4.2.1. Evolução histórica das Redes Neurais Artificiais

As RNA são provavelmente, a mais antiga das técnicas de inteligência artificial (IA). Sua concepção se deu a partir da observação dos mecanismos de transmissão de informação e aprendizagem das redes de neurônios biológicos, buscando sua reprodutibilidade a partir de equacionamentos matemáticos, capazes de gerenciar informações tal como as conexões sinápticas, além disso, circuitos eletrônicos foram usados (resistores variáveis e amplificadores) para de forma análoga reproduzir esses comportamentos inteligentes (Ludwig Jr. & Costa, 2007).

O ponto marcante para o campo de estudo das RNA foi a apresentação de um modelo de neurônio artificial por McCulloch & Pitts (1943, apud Hagan, 1996). Essa publicação fez surgir inúmeras atividades nessa linha de pesquisa que geraram a concepção do perceptron proposto por Rosenblatt em 1958, e o adaline resultado do estudo de Windrow & Hoff em 1960 (Ludwig Jr. & Costa, 2007)

O perceptron desenvolvido foi implantado na máquina MARK I PERCEPTRON gerando grande expectativa sobre as capacidades de futuros robôs inteligentes. Entretanto, com a publicação de Minsky & Papert (1969, apud Ludwig Jr. & Costa, 2007), foram feitas duras críticas sobre as limitações do perceptron em relação ao problema do “ou exclusivo”, deixando a comunidade científica descontente com relação aos possíveis avanços em sistemas inteligentes com o uso de RNA (Ludwig Jr. & Costa, 2007). Várias soluções foram propostas para resolver o problema, mas somente com a publicação, em 1986, de Rumelhart sobre o algoritmo de “retropropagação do erro” (error backpropagation) é que uma solução definitiva para o problema foi encontrada (Hagan & Demuth, 1996).

Logo após o ressurgimento das RNA houve uma intensificação dos estudos em IA e diversos sistemas especialistas se popularizaram. Após este período de renascimento, houve um crescimento das aplicações de IA, por exemplo, em tomografia, pesquisas em campos de petróleo e base de dados inteligentes (Barreto, 2002).

#### **4.2.2. Inspiração na neurociência**

Dentre os aspectos mais importantes do cérebro humano que o capacitam de um comportamento inteligente, são especialmente atrativas para serem simuladas por uma RNA :

- Robustez e tolerância a falhas, o que implica que a eliminação de alguns neurônios não afeta a funcionalidade global;
- Capacidade de aprendizagem: tarefas podem ser aprendidas pelo processo de treinamento a partir do ajuste de pesos;
- Processamento de informação incerta: caso a informação seja fornecida incompleta, afetada por ruído ou parcialmente contraditória, uma resposta correta é possível;
- Paralelismo: Inúmeros neurônios podem estar ativos no mesmo momento, ou sejam não é necessário que uma instrução seja processada uma após a outra (Raubert, 2010).



Deve-se observar que estas características inteligentes de que é dotado o sistema nervoso não são passíveis de simulação por sistemas computacionais tradicionais. Além disso, as RNA possuem uma grande capacidade de aprender e simular comportamentos, que no caso específico do fenômeno histerético de EMF pode ser feito por um simples treinamento de rede evitando o uso de modelos matemáticos como aqueles representados pelas Equações 1 e 2 anteriormente apresentadas.

#### 4.2.3. O neurônio biológico

A Figura 8 apresenta um neurônio biológico (NB) típico composto por um corpo celular ou soma, um axônio tubular e várias ramificações arbóreas conhecidas como dendritos. Reações químicas e elétricas são responsáveis pelo processamento de informação. A saída da informação do soma (corpo) é realizada por impulsos elétricos propagados através do axônio. No axônio existem inúmeras ramificações arbóreas que distribuem a informação para neurônios vizinhos. A ligação com outros neurônios é realizada através de sinapses que estão conectadas a uma dendrite do neurônio receptor. A sinapse libera uma substância química quando excitada por impulso do axônio. A substância se transmite entre sinapse e dendrite realizando a conexão entre dois neurônios vizinhos. De acordo com as excitações (ou inibições) transmitidas das células vizinhas para a célula em consideração, esta processa a informação e a transmite via seu axônio (Raubert, 2010).

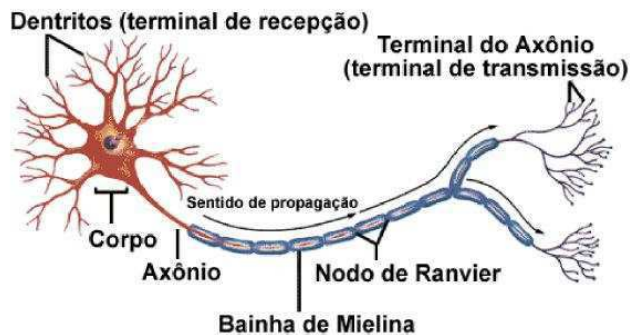


Figura 8. Neurônio Biológico (Mecânica atual, 2011).

#### 4.2.4. O neurônio artificial

Na Figura 9 é apresentado um modelo matemático de um neurônio artificial (NA).




Figura 9. Neurônio Artificial de McCulloch e Pitts (apud Rauber, 2010).

Este modelo é composto por quatro elementos básicos:

- Um conjunto de  $d$  conexões de entrada ( $x_1, x_2, \dots, x_d$ ), caracterizadas por pesos ( $w_1, w_2, \dots, w_d$ );
- Um somador ( $\Sigma$ ) para acumular os sinais de entrada;
- Uma função de ativação que limita o intervalo permissível de amplitude do sinal de saída ( $y$ ) a um intervalo fixo (Ferneda, 2006).
- Um limiar de ativação  $\mu$ .

Nota-se comparando as Figuras 8 e 9 a semelhança da estrutura do NA e NB com suas entradas ( $x_1, x_2, \dots, x_d$ ) similares as características dos dendritos e as espessuras destes no NB favorecendo uma maior ou menor condução de pulsos elétricos, o que é simulado pelos pesos variáveis no NA. O corpo do NB soma todos os impulsos recebidos pelos dendritos e gera uma resposta ou inibição elétrica pelo axônio. Similamente, o NA processa as informações das entradas, multiplicadas pelo peso correspondente gerando um resultado lançado como saída.

Do ponto de vista prático, as RNA possuem a capacidade de aprender o comportamento de um sistema linear ou não-linear através da introdução de dados experimentais a rede através do ajuste de seus pesos variáveis.

Neste sentido, as RNA podem empregar diversos modelos ou funções na

sua construção. Na Figura 10 são apresentadas as funções de ativação mais usadas para aproximação de funções.




Figura 10. Funções de transferência (adaptado de Rauber, 2010).

#### 4.2.5. Topologia das RNA

A partir da união de diversos neurônios artificiais se obtém as RNA, que são mais ou menos flexíveis matematicamente dependendo da forma como estão interligados. As topologias mais comuns, apresentadas na Figura 11 são as de propagação para frente e a com realimentação.

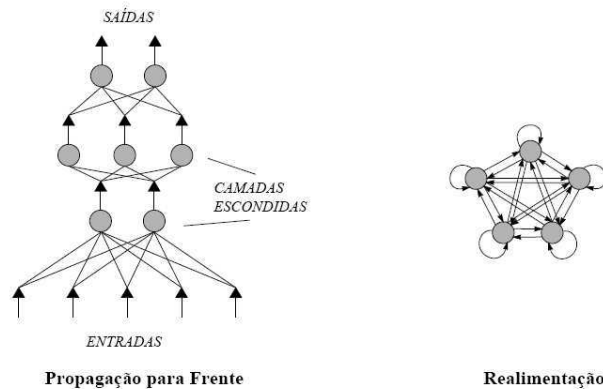


Figura 11. Topologias de redes neurais artificiais (Rauber, 2010).

A partir das topologias apresentadas na Figura 11 derivam-se inúmeros métodos com capacidade de armazenar informação, que podem ser com aprendizagem supervisionada ou não-supervisionada, conforme é evidenciado no fluxograma da Figura 12. Os modelos apresentados são os mais utilizados nas inúmeras aplicações de simulação e controle utilizando RNA. Estes foram validados em diversos trabalhos, e cada um apresenta aplicações particulares e limitações próprias.

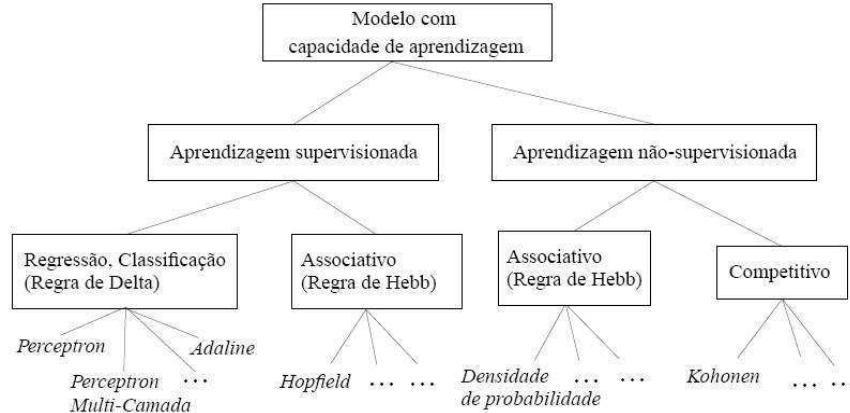


Figura 12. Classificação estrutural e funcional de redes neurais artificiais (Rauber, 2010).

#### 4.2.6. Perceptron

Uma topologia de rede bastante simplificada para o desenvolvimento do estudo de RNA utilizou uma única camada de neurônio que possui a capacidade de alterar seus pesos, treinando a rede de forma a se obter um valor desejado na saída do neurônio a partir de sinais de entrada (aprendizado supervisionado), proposto por Rosenblatt em 1961, essa configuração de RNA ficou conhecida como perceptron (Demuth, 2010).

A técnica de treinamento usada foi chamada de regra de aprendizado do perceptron, e possui a habilidade de generalizar a partir de vetores de treinamento e pesos disponibilizados entre as conexões. O perceptron é especialmente adequado para resolver problemas de classificação e constitui a base do estudo de RNA mais complexas.

O uso do perceptron está limitado à classificação de dados linearmente separáveis conforme foi apresentado no trabalho de Minsky & Papert em 1969, para o uso com dados não linearmente separáveis se faz uso do algoritmo backpropagation proposto por Rumelhart em 1986 (Demuth, 2010).

#### 4.2.7. Algoritmo Backpropagation

A partir da generalização da regra de aprendizagem de Widrow-Hoff em

1960, e funções de transferência não linearmente diferenciáveis foi criado o algoritmo backpropagation. O termo que dá nome ao algoritmo se refere à maneira como se calcula o gradiente de redes de várias camadas. Uma rede apropriadamente treinada pode gerar respostas razoáveis quando se apresenta entradas não oferecidas durante o treinamento (Demuth, 2010).

Nesse tipo de configuração, uma RNA de múltiplas camadas, recebe o sinal de entrada e o multiplica pelos pesos correspondentes gerando um valor de entrada para a camada de neurônios seguinte que calcula uma resposta linear ou não linear de acordo com a função de transferência. O resultado na saída da camada será novamente multiplicado pelos pesos e terá o mesmo efeito descrito até a camada de saída, onde é comparado com os valores desejados, calculando-se o erro. A derivada da função de ativação para o correspondente neurônio é utilizada desde a camada de saída até a entrada da rede para o cálculo do erro. O ajuste dos pesos é feito mediante o erro atribuído a camada de neurônios. A Equação 3 mostra matematicamente como é realizado o ajuste de pesos para uma dada iteração.

$$\mathbf{x}_k + 1 = \mathbf{x}_k - \alpha_k \mathbf{g}_k \quad (3)$$

Onde  $x_k$  é o vetor de pesos e bias,  $g_k$  é o corrente gradiente (calculado em função do erro) e  $\alpha_k$  é a taxa de aprendizado.

#### 4.2.8. Aplicações de RNA

As RNA podem ser usadas para simulação e/ou controle em diversas aplicações e em vastas áreas do conhecimento humano. Por exemplo, na área:

- Aeroespacial - é utilizada para aumentar o desempenho do piloto automático, simulação de voo, sistemas de controle da aeronave, simulação de componentes;
- Automotiva – sistemas de elevação automática, análise de garantias;
- Defesa Militar – reconhecimento facial, novos tipos de sensores, radares, processamento de sinais, monitoramento de alvos.

### 4.3. Atuadores de LMF e RNA – estado da arte

Para estimar o comportamento termomecânico de uma LMF é possível se fazer uso de diversos métodos, tais como modelagem constitutiva com solução pelo método dos elementos finitos (Lagoudas, 2008; Ma et al, 2008), equacionamento matemático (Nascimento et al, 2009), e RNA (Song et al 2003; Asua et al, 2007).

Nesse contexto, recentemente Nascimento et al (2009) criaram um novo modelo matemático para estimar a histerese de uma LMF no regime de deformação sob carga ( $\varepsilon$ ) em função da temperatura ( $T$ ). Para validar o modelo, foi desenvolvida uma bancada experimental para determinar o comportamento  $\varepsilon-T$  de um fio de NiTi com EMF sob carregamentos constantes. O modelo desenvolvido apresentou boa aproximação com os resultados experimentais, entretanto algumas discrepâncias ainda verificadas foram atribuídas a limitações na implementação numérica e a grande assimetria das curvas  $\varepsilon-T$ .

O trabalho de Eyercioglu et al (2008) usou uma RNA com algoritmo *backpropagation* para estimar as temperaturas de transformação de fase de uma LMF a base de ferro.

Asua et al, (2007), discutiram sobre a histerese térmica de uma liga NiTi com memória de forma. Estes autores afirmam que devido à resposta termomecânica da LMF ser não linear, atuadores desenvolvidos a partir desses materiais têm seus limites de precisão diminuídos. A partir dessa problemática foi desenvolvido um método de controle inteligente para aplicações que envolvem posicionamento de sistemas baseados em LMF. A RNA desenvolvida apresentou excelente capacidade de aprender o fenômeno, demonstrando a sua aplicabilidade no controle da histerese térmica apresentada por esses atuadores.

Lee et al (2001) compararam o desempenho do controle de ângulo de um cateter ativado por micro-molas de LMF usando RNA e um controlador PID. Constatou-se vantagem na utilização da medição de resistência elétrica da LMF para obter informações sobre seu posicionamento, entretanto, como a

resposta da liga é não linear o controle fica difícil por métodos tradicionais.

Tai & Ahn (2010) desenvolveram um controlador, usando RNA, para controlar a posição de um atuador de LMF para diversos tipos de referência de sinal (degrau, senoidal, triangular), ou seja, com a utilização do controlador o deslocamento do atuador se deu de acordo com o perfil de ativação desejado.

Song et al (2003) desenvolveram um novo controlador para atuadores de LMF usando RNA. Os dados para os testes com RNA foram obtidos a partir da bancada experimental mostrada na Figura 13. Nesse sistema, um sinal de tensão sai do sistema de controle para uma fonte programável (*Current amplifier*) que amplifica a tensão por um fator 4 nos terminais do fio de LMF (*SMA wire actuator*) resultando em uma corrente elétrica suficiente para aquecê-lo. Um sensor de deslocamento tipo *Linear Variable Differential Transformer* (LVDT) é instalado para medir o deslocamento do fio de LMF. Quando desligada a alimentação, o fio atuador se resfria e é deformado por uma mola convencional de aço (*Bias spring*).

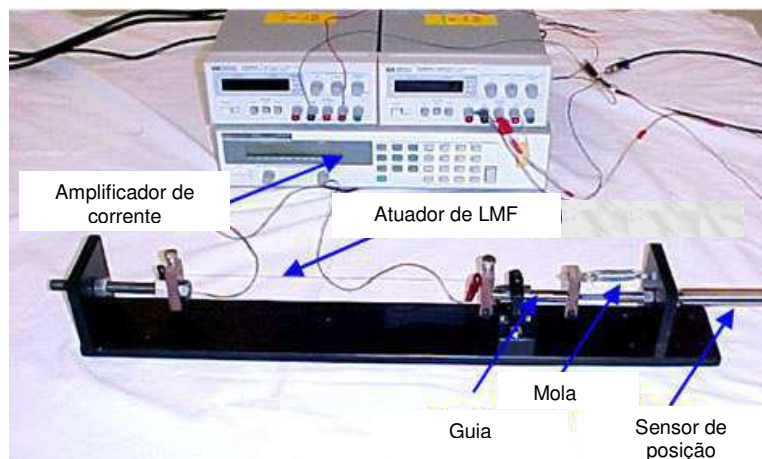


Figura 13. Plataforma experimental desenvolvida para coleta dos dados do comportamento de um fio atuador de LMF (adaptado de Song et al, 2003).

Semelhantemente ao trabalho de Lee et al (2001), estes autores também constataram que atuadores de LMF exibem uma larga histerese que frequentemente dificulta o controle de seu deslocamento. O sistema desenvolvido, que conta com controle em tempo real e utiliza RNA, teve como objetivo diminuir essa dificuldade e permitir a compensação (redução) da

histerese térmica do atuador. Verificou-se que o deslocamento desejado do atuador LMF foi bastante próximo do obtido pela RNA. Na Figura 14, são mostrados os resultados obtidos com a plataforma experimental desenvolvida e na Figura 15 os resultados da simulação da RNA e o controle de posição do atuador.

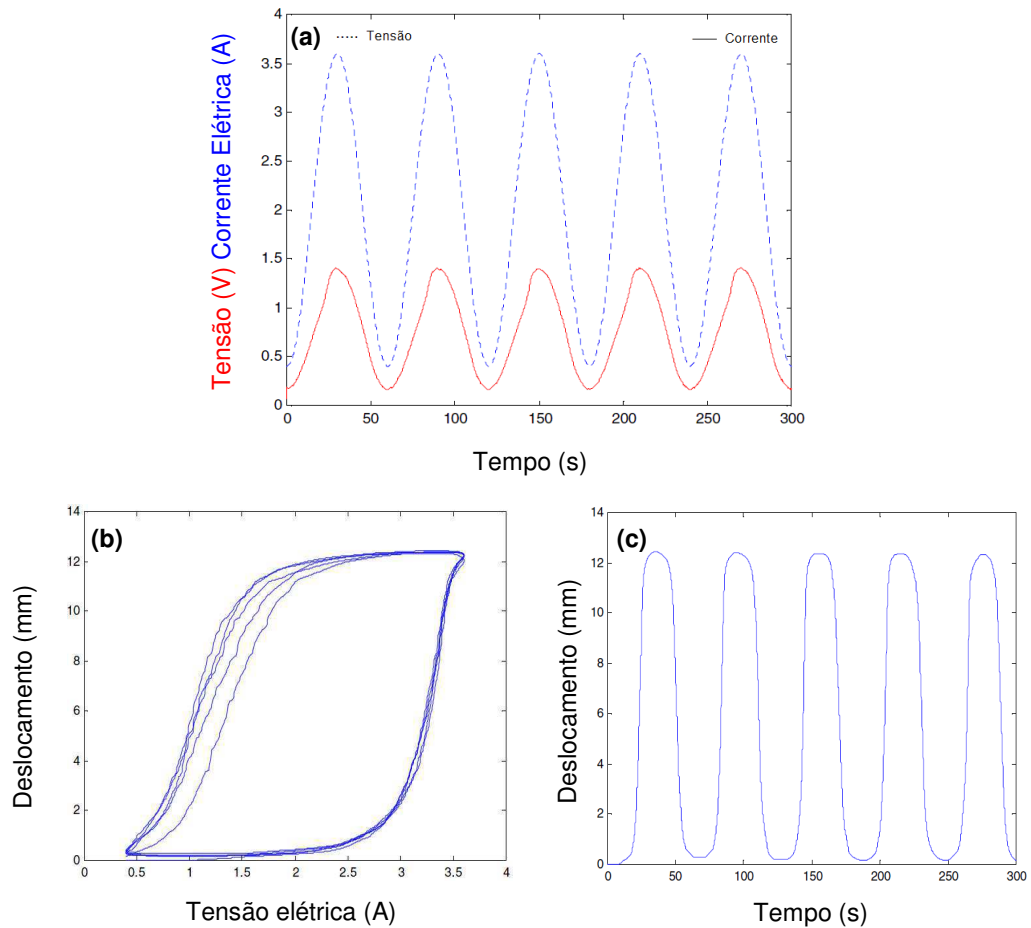


Figura 14. Ativação e resposta do atuador de LMF. (a) Tensão aplicada e corrente elétrica medida em função do tempo. (b) Histerese do Deslocamento em função da Tensão elétrica. (c) Relação deslocamento-tempo. (adaptado de Song et al, 2003).



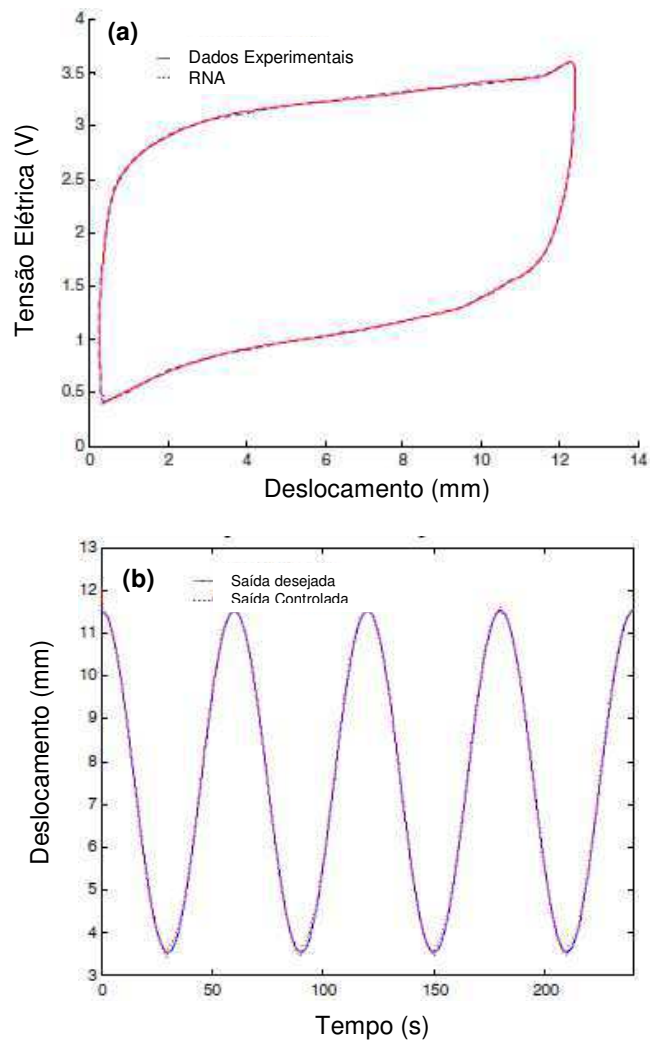


Figura 15. Resposta do controle usando RNA. (a) Simulação usando RNA sobre os dados experimentais. (b) Controle de posição do atuador de LMF (adaptado de Song et al, 2003).

## 5. MATERIAIS E MÉTODOS

Este trabalho foi desenvolvido no Laboratório Multidisciplinar de Materiais e Estruturas Ativas (LaMMEA) da Unidade Acadêmica de Engenharia Mecânica (UAEM) na Universidade Federal de Campina Grande (UFCG) e seguiu a fluxograma descrito na Figura 16. Para aplicação da RNA foram empregados dois bancos de dados relativos aos laços de histerese de deslocamento-corrente elétrica e deformação-temperatura, sob carregamento constante, a exemplo da ilustração mostrada na Figura 2. O fluxo à direita na Figura 16 considera o uso de um banco de dados de ativação térmica enquanto o da esquerda mostra a sequência metodológica utilizando ativação por corrente elétrica.

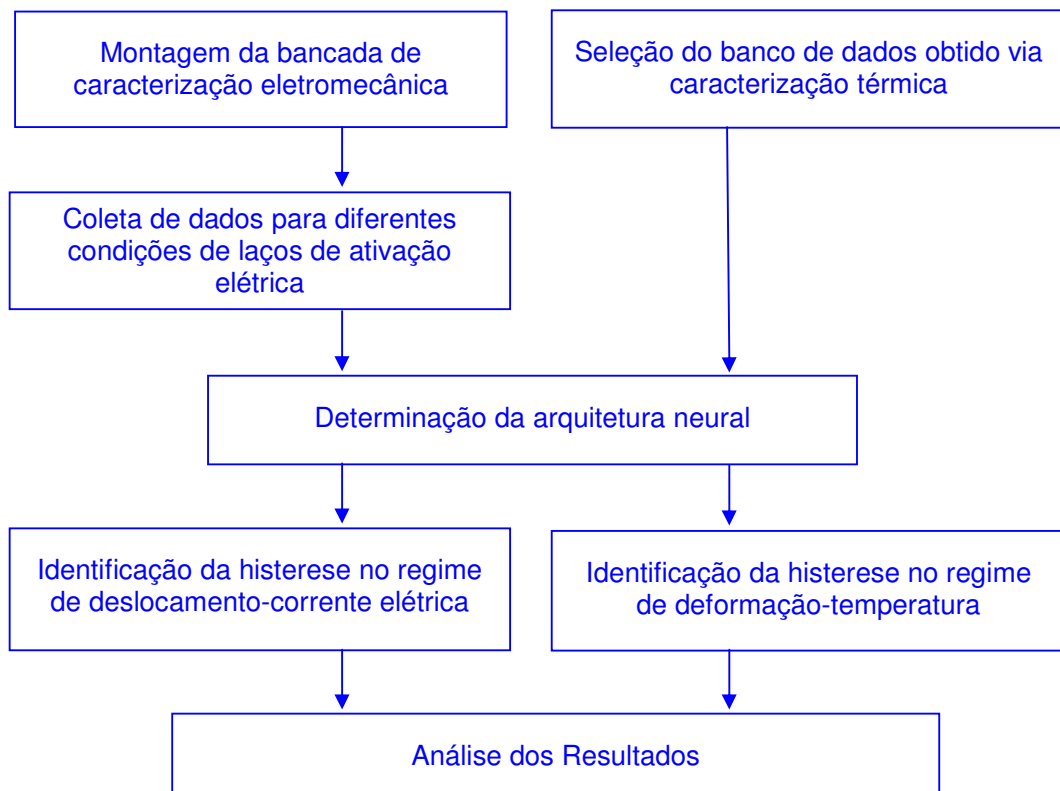


Figura 16. Fluxograma da metodologia adotada no trabalho.

Para a aplicação da sequência estabelecida na Figura 16, fez-se uso de duas bancadas experimentais para a coleta de dados da histerese dos

atuadores de LMF. A primeira bancada, denominada de Bancada de Caracterização Eletromecânica (BCE), foi desenvolvida para determinação do comportamento de fios finos de LMF sob carga constante, via ativação por corrente elétrica. O projeto desta bancada foi desenvolvido com base na máquina de fadiga construída inicialmente por Lima (2004) e modificada por Viana (2008), tendo sido melhorada em diferentes aspectos neste trabalho. Utilizou-se a BCE para a obtenção da resposta em deslocamento de um fio atuador de LMF de NiTi com diâmetro de 0,29 mm. A segunda plataforma experimental, denominada de Bancada de Caracterização Térmica (BCT), foi desenvolvida por Nascimento Neto (2007) com o objetivo de determinar as principais propriedades termomecânicas de atuadores de LMF em regime de tração e flexão, como as temperaturas de transformação, histerese em temperatura, efeito memória de forma sob carga constante e geração de força em função da temperatura sob deformação imposta. A BCT foi utilizada por Rodrigues & De Araújo (2008), para obter bancos de dados do comportamento da deformação em função da temperatura de um fio e uma fita de LMF de NiTi. Essa base de dados foi utilizada neste trabalho. Nas seções 5.1 e 5.2 são descritos os modos de utilização das duas bancadas.

### **5.1. Bancada de caracterização eletromecânica,**

A Figura 17 mostra uma ilustração esquemática da BCE mencionada anteriormente. Esta plataforma foi desenvolvida para determinação do comportamento de atuadores do tipo fios finos de LMF via ativação por passagem controlada de corrente elétrica (aquecimento por efeito Joule). O sistema é composto de um microcomputador (1), uma placa de aquisição de dados c-digital (2), um circuito amplificador de corrente (3), uma fonte de tensão (4), uma estrutura mecânica para fixação de um fio de LMF tensionado por pesos (5) e uma fonte de tensão simétrica (6) (ver Figura A1 do anexo A) dedicada ao sensor de deslocamento LVDT (*Linear Variable Displacement Transducer*). Nesta bancada o programa computacional Labview<sup>®</sup>, com ferramentas do Matlab<sup>®</sup>, processa a ativação do fio atuador de LMF através da

placa de aquisição de dados. Concomitantemente, o programa coleta e armazena os dados de deslocamento do atuador de LMF.

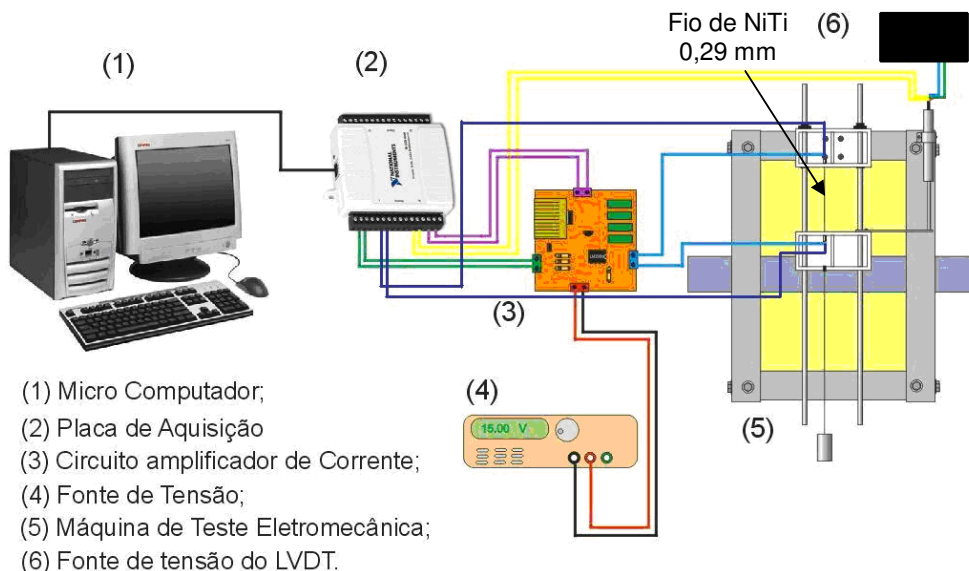


Figura 17. Bancada de caracterização eletromecânica (adaptada do trabalho de Viana, 2008).

Conforme indicado na Figura 18, neste método de caracterização os sinais (1) são processados e enviados pelo programa LabVIEW® (computador) para a placa analógico-digital que os transmite (2) para o circuito amplificador de corrente (ver Figura A.2 do Anexo A), o qual, usando a alimentação (3) de uma fonte de tensão, amplifica e conduz (4) ao fio de LMF uma corrente suficiente para provocar o aquecimento necessário a sua transformação completa.

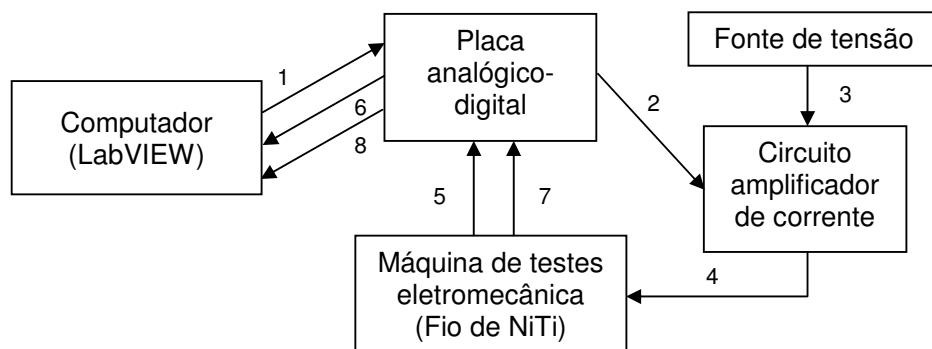


Figura 18. Diagrama de blocos do funcionamento da bancada eletromecânica.

O aquecimento do fio de LMF, por efeito Joule, provoca a transformação de fase por variação da temperatura. Simultaneamente, o sinal de tensão elétrica nos terminais do fio de LMF é coletado (5) e enviado (6) pela placa de aquisição (placa analógico-digital) ao programa LabVIEW<sup>®</sup> que processa os dados de ativação do fio de LMF. Além disso, o sensor de deslocamento LVDT faz a leitura do deslocamento do fio de LMF e os sinais de tensão (7) característicos deste sensor são coletados pela placa de aquisição que transmite a informação (8) para ser processada pelo programa LabVIEW<sup>®</sup>.

Utilizando a BCE da Figura 17 é possível gerar ondas de corrente de ativação nas formas triangular e triangular reduzida devido a implementação de um *script* (algoritmo) do Matlab<sup>®</sup> no programa desenvolvido em ambiente LabVIEW<sup>®</sup>. O algoritmo faz todo o processamento do incremento e redução do sinal de ativação do fio LMF conforme desejado. Na Figura 19 apresenta-se uma vista geral da interface do programa LabVIEW<sup>®</sup> utilizada para controlar a aplicação de corrente elétrica e armazenar a resposta em deslocamento do fio atuador de LMF.

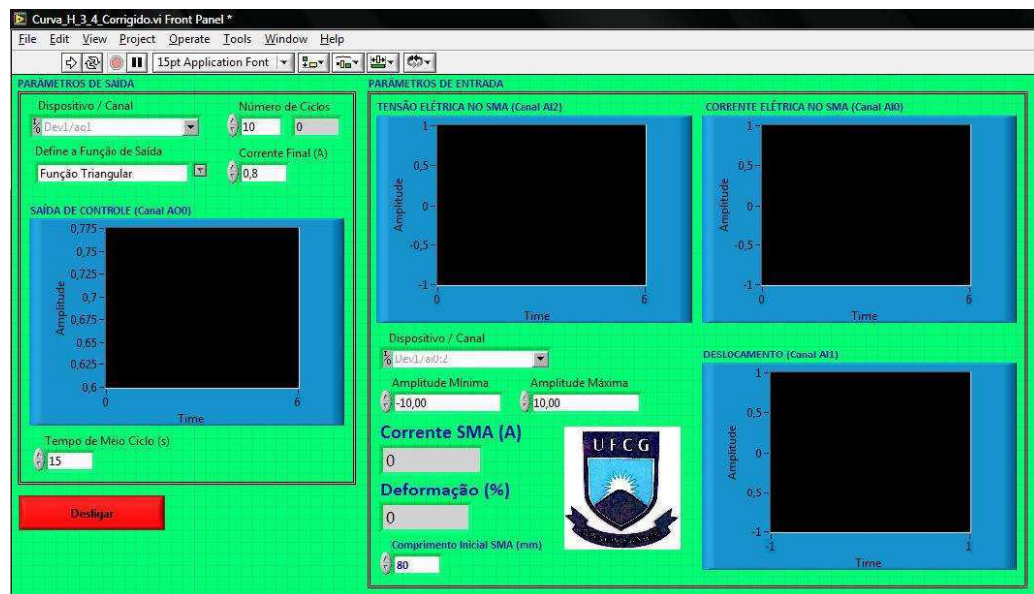


Figura 19. Interface do programa em LabVIEW<sup>®</sup> para ativação e coleta da resposta do fio de LMF na BCE.

Usando a BCE foi realizado inicialmente um procedimento de estabilização da resposta de um fio de LMF NiTi de 0,29 mm de diâmetro e comprimento útil de 100 mm, fornecido pela empresa Memory Metalle (Alemanha) sob a marca comercial de liga M. O fio de NiTi foi tratado termicamente a uma temperatura de 450 °C por 15 minutos e resfriado ao ar, para maximizar a intensidade do fenômeno de memória de forma

A Figura 20 mostra o resultado da medição das temperaturas de transformação de fase desse fio de LMF NiTi por ensaio de calorimetria DSC. Para essa medida foi utilizado o calorímetro DSC do LaMMEA da UFCG, marca TA Instruments, modelo Q20, com uma taxa de aquecimento e resfriamento de 5 °C/min.

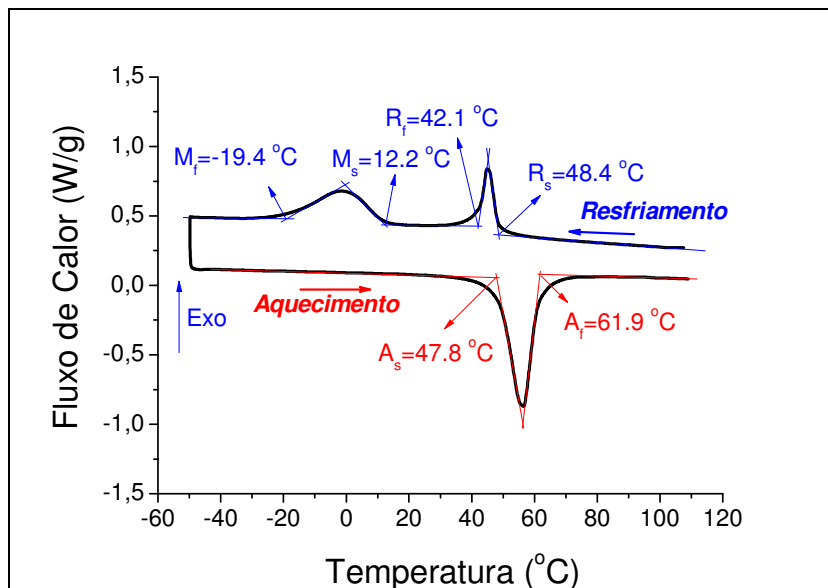


Figura 20. Temperaturas de transformação de fase do atuador de LMF de NiTi.

Verifica-se na Figura 20 que a transformação de fase do fio de NiTi durante o resfriamento ocorre em duas etapas. Na primeira etapa, entre 48 °C e 42 °C (R<sub>s</sub> e R<sub>f</sub>) forma-se a estrutura martensítica conhecida por fase R (Romboédrica) e continuando o resfriamento entre 12 °C e - 19 °C (M<sub>s</sub> e M<sub>f</sub>) essa estrutura se transforma na fase martensita monoclinica (Otsuka & Wayman, 1998; Lagoudas, 2008). Durante o aquecimento a reversão dessa transformação ocorre em uma única etapa entre 48 °C e 62 °C (A<sub>s</sub> e A<sub>f</sub>). Assim

sendo, as temperaturas  $M_s$  e  $M_f$  estão localizadas abaixo da temperatura ambiente ( $\sim 27\text{ }^\circ\text{C}$ ), implicando numa transformação parcial do fio de NiTi utilizado, correspondente a região da fase R e austenítica (Otsuka & Wayman, 1998; Lagoudas, 2008). Desta forma, o potencial de deslocamento por expansão e contração do atuador de LMF de NiTi será apenas parcial, já que se utilizou o fio com temperaturas igual ou superior a ambiente ( $\sim 28\text{ }^\circ\text{C}$ ).

Para a estabilização mecânica do fio de LMF de NiTi foi efetuado um procedimento de ciclagem sob carga (conhecido como treinamento) usando uma onda de corrente elétrica triangular, conforme ilustra a Figura 21. Foram realizados 3000 ciclos de ativação sob carregamento mecânico de aproximadamente 200 MPa.

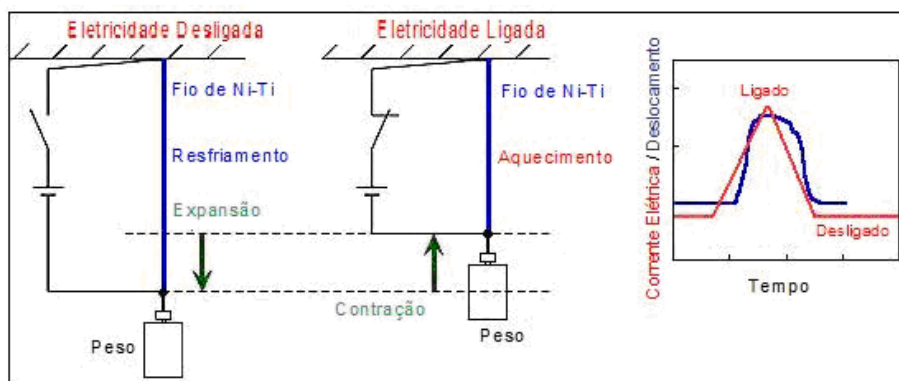


Figura 21. Esquema do treinamento por ciclagem elétrica sob carga empregado na estabilização do atuador de LMF de NiTi.

Na Figura 22 é mostrado o comportamento geral de estabilização do deslocamento do fio de LMF de NiTi. Observou-se uma importante variação da faixa de deslocamento do fio nas primeiras centenas de ciclos, resultante do seu alongamento gradual (acomodação de defeitos) sob os ciclos de carregamento e descarregamento térmico e a presença da carga de 200 MPa. A partir de aproximadamente 2000 ciclos o deslocamento do fio tende a ser praticamente estável. Para o treinamento foram executados os 3000 ciclos a fim de garantir a estabilidade do fio de LMF de NiTi.

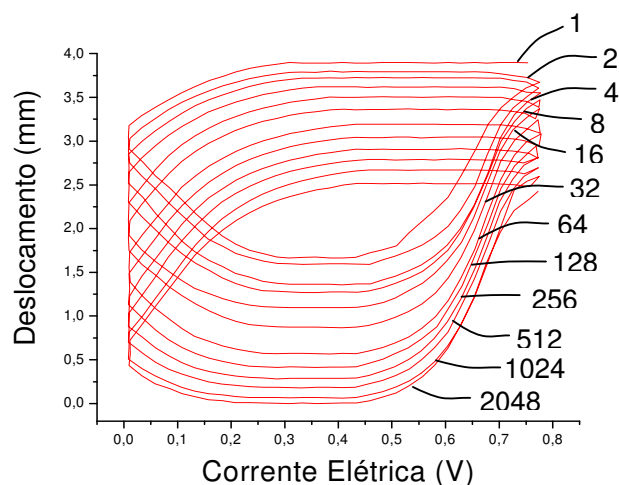


Figura 22. Ciclagem para estabilização do deslocamento do fio de LMF de NiTi sob carga de 200 MPa. Evolução dos laços de histerese do deslocamento como função da corrente elétrica.

Após o processo de treinamento para estabilização da resposta do fio atuador, foi realizada a caracterização eletromecânica do fio de LMF de NiTi para os carregamentos de 50, 100, 150, 200 e 250 MPa na forma de onda triangular e no carregamento de 200 MPa na forma de onda triangular reduzida. Nas Figuras 23 e 24, verifica-se o resultado da aplicação de uma onda triangular e triangular reduzida para ativação do fio de NiTi sob carregamento de 200 MPa, respectivamente para a onda triangular e triangular reduzida.

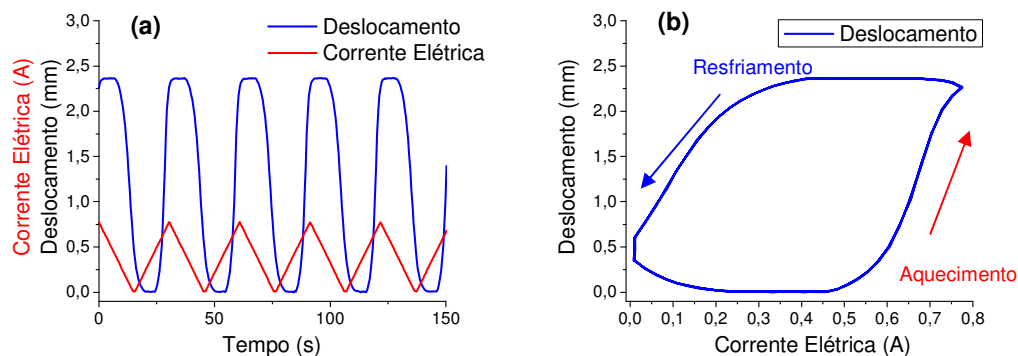


Figura 23. Ativação do fio de NiTi submetido a uma onda triangular de corrente e carga de 200 MPa. (a) Variação do deslocamento em função do tempo. (b) Laços de histerese de deslocamento em função da corrente elétrica.



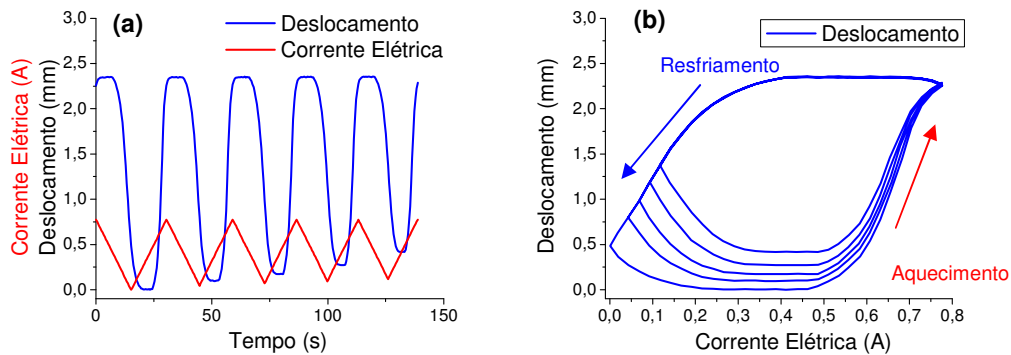


Figura 24. Ativação do fio de NiTi submetido a uma onda triangular reduzida de corrente e carga de 200 MPa. (a) Variação do deslocamento em função do tempo. (b) Laços de histerese de deslocamento em função da corrente elétrica.

Como pode ser observado na Figura 23 existe um atraso entre a corrente aplicada e a resposta do fio de LMF de NiTi. Isso ocorre principalmente devido a inércia na transferência de calor durante o resfriamento do fio atuador, de forma que a expansão do fio nessa fase não acompanha a redução da corrente elétrica na mesma velocidade, gerando esse atraso. Mesmo assim, nota-se que os laços de histerese no deslocamento estão exatamente sobrepostos uns sobre os outros como resultado da aplicação da onda triangular de corrente.

Na Figura 24 observa-se que a ativação do atuador de LMF de NiTi usando uma onda triangular reduzida gera laços de histerese incompletos (sublaços). Verifica-se na Figura 24(a) que a onda triangular é reduzida sempre a partir do pico de corrente no aquecimento (0,80 A), fazendo com que os sublaços, mostrados na Figura 24(b), se iniciem exatamente a partir da curva de deslocamento durante o resfriamento. Na realidade para obter os sublaços faz-se em sequencia uma série de resfriamentos parciais do fio de LMF através da redução da corrente elétrica para um valor mínimo sempre crescente.

## 5.2. Bancada de caracterização termomecânica

A Figura 25 mostra uma ilustração esquemática da BCT mencionada anteriormente. Essa bancada pode ser utilizada em vários modos de carregamento mecânico no atuador de LMF (Nascimento Neto, 2007).

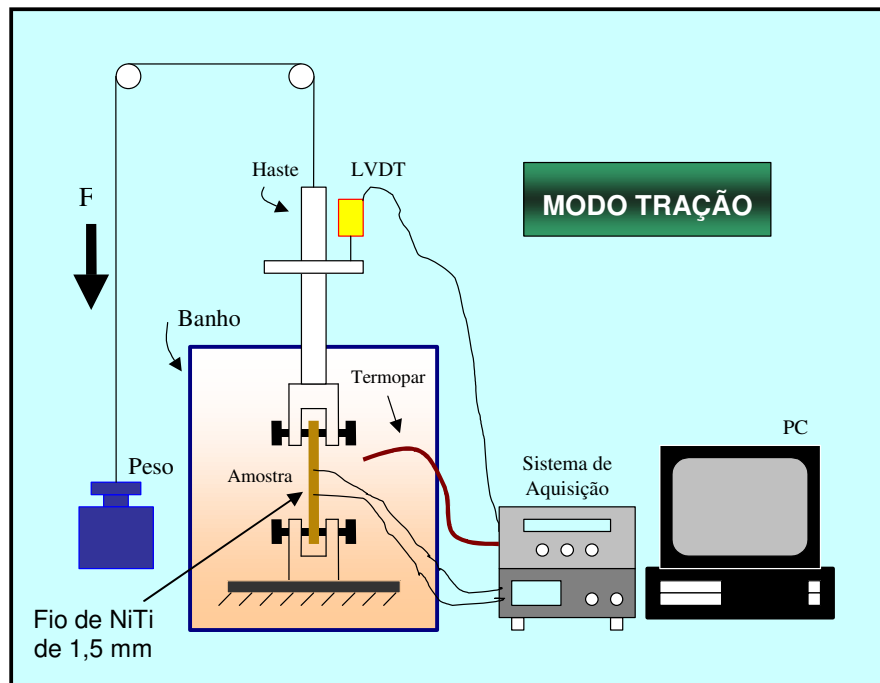


Figura 25. Ilustração do funcionamento da BCT operando no modo de tração. Fonte: Nascimento Neto (2007).

A plataforma da Figura 25, como mencionado anteriormente, foi desenvolvida para determinação do comportamento termomecânico de atuadores de LMF via ativação por variação de temperatura do ambiente em que o atuador está inserido. Na Figura 26, apresenta-se uma foto da estrutura completa da BCT.



Figura 26. Fotografia da BCT desenvolvida por Nascimento Neto (2007). (1) Estrutura rígida. (2) Cabo de tração. (3) Sensor de deslocamento LVDT. (4) Haste móvel. (5) Garra de tração. (6) Carga de tração. (7) Banho termoregulável. (8) Fonte de tensão e corrente. (9) Sistema de aquisição de dados.

Para a caracterização termomecânica de amostras de LMF, usando a BCT, deve-se aplicar um carregamento mecânico constante, através de pesos, com subsequente variação controlada de sua temperatura. Para o modo de tração ilustrado na Figura 25, uma amostra de fita ou fio de LMF de comprimento situado entre 20 e 50 mm é fixado na garra de tração (5) conectada a haste móvel (4) em que é aplicada um carregamento constante por intermédio do cabo de tração (2) e dos pesos (6). Esse carregamento é responsável por impor uma deformação inicial na amostra de LMF, medida pelo sensor de deslocamento LVDT (3). A amostra LMF sob carga é imersa no banho termoregulável (7) juntamente com um termopar tipo K. O sensor de deslocamento e o termopar são ligados a dois canais do sistema de aquisição de dados (9), e os dados de deslocamento e temperatura são armazenados em um computador.

O banho termoregulável permite trabalhar na faixa de - 30 a 200 °C, com um reservatório de 13 litros de óleo de silicone Rhodorsil 47V 50 da Rhodia Silicones, em que a amostra de ensaio fica imersa.

O sistema de aquisição de dados, da marca Agilent, modelo 34970A, utiliza o programa *Agilent BenchLink Date Logger Utilities* para gerenciar os ensaios realizados, permitindo fazer a medição de tensão elétrica, deslocamento e temperatura.

Para quantificar o deslocamento do atuador de LMF durante a mudança de sua forma por ação da temperatura se faz uso de um sensor LVDT, semelhante aquele usado na BCE, da marca Solartron.

Utilizando a BCT, Rodrigues & De Araújo (2008) caracterizaram um fio e fita de LMF de NiTi, no regime de carregamento isobárico (modo tração), obtendo entre outras, curvas características de deformação em função da temperatura. Durante o desenvolvimento do trabalho foram empregados fios de NiTi com diâmetro de 1,5 mm, adquiridos junto a empresa Memory-Metalle GmbH (Alemanha). Esses fios são fabricados a partir da mesma liga M, referente ao fio de NiTi de 0,29 mm utilizado na BCE. Assim, as temperaturas de transformação mostradas na Figura 20 valem também para o fio de 1,5 mm. O fio de NiTi no estado como fornecido foi inicialmente recozido a 450 °C por 20 minutos em um forno de resistência elétrica da marca EDG, modelo Titan Platinum Quartz, visando eliminar as tensões residuais oriundas do processo de fabricação e maximizar a transformação martensítica que origina os fenômenos de memória de forma.

A Figura 27 mostra o conjunto de curvas de histerese deformação-temperatura para o fio atuador de LMF NiTi obtido com a BCT no regime de tração em diferentes níveis de carregamento. A ciclagem térmica foi realizada entre -10 °C e 120 °C.

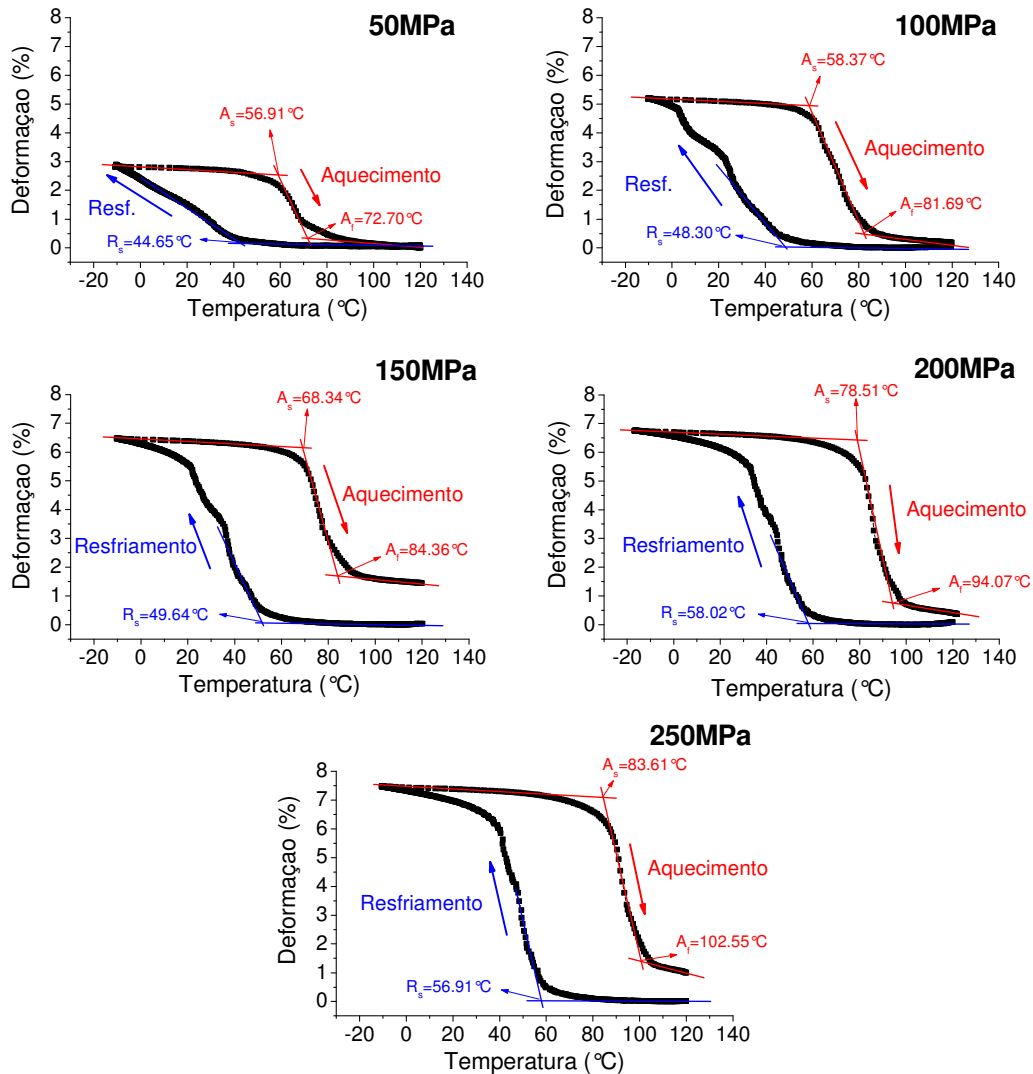


Figura 27. Comportamento termomecânico isobárico do fio de NiTi de 1,5 mm de diâmetro. Curvas deformação – temperatura para diversos níveis de carga.

Verifica-se que a deformação por expansão durante o resfriamento aumenta com o aumento da carga externa, tendendo posteriormente a uma saturação. Ao mesmo tempo, durante o aquecimento verifica-se um acúmulo de deformação sob carga na temperatura de 120 °C, principalmente para as cargas de 150 MPa e 250 MPa. A diferença entre estas duas deformações, que corresponde à contração do fio atuador durante o aquecimento, é o efeito memória de forma sob carga, que varia de aproximadamente 3 % a 5,5 %, apresentando tendência de saturação com o aumento do carregamento. Este

comportamento é típico de atuadores de LMF (De Araújo et al, 1997; De Araújo, 1999; Lagoudas, 2008).

A partir do conjunto de curvas deformação – temperatura da Figura 27 é possível determinar as temperaturas de transformação, sob carga, do atuador de LMF de NiTi, aplicando tangentes nas curvas de resfriamento e aquecimento. Nota-se um aumento das temperaturas de transformação à medida que se aumenta a carga aplicada ao fio de LMF. Este aumento fica melhor demonstrado na Figura 28, com a visualização do deslocamento das curvas de deformação em função da temperatura para a direita. Este comportamento de aumento das temperaturas de transformação com a carga é geralmente linear, e conhecido na literatura como uma lei de Clausius-Clayperon para LMF (Otsuka & Wayman, 1998; Lagoudas, 2008).

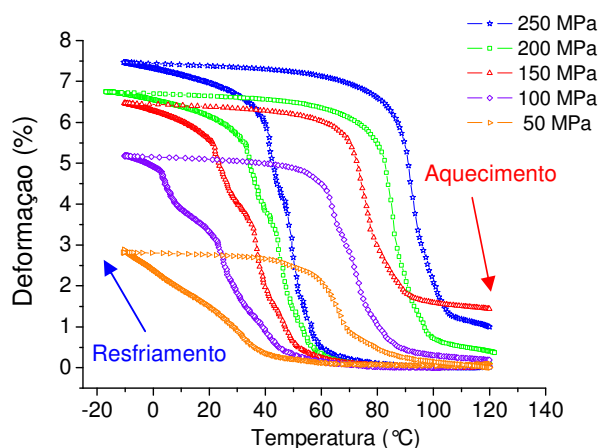


Figura 28. Superposição das curvas de histerese deformação – temperatura da Figura 27.

### 5.3. Desenvolvimento da arquitetura da RNA

Uma grande parte do esforço para o desenvolvimento desse trabalho foi dedicado a geração do conceito da arquitetura neural que permitisse identificar a histerese de atuadores de LMF sob diferentes níveis de intensidade do carregamento externo.

O uso de uma topologia neural com aprendizado supervisionado foi sempre evidente devido à disponibilidade dos dados para os testes. Assim, foi

escolhida a configuração na forma de *Perceptron* de Múltiplas Camadas (do inglês *Multi Layer Perceptron* – MLP) e como algoritmo, foi empregado o *backpropagation*, já que este é um aproximador universal de funções e se indica a simulação de dados não separáveis linearmente, caso clássico do comportamento de LMF devido principalmente a presença de histerese e a própria característica do deslocamento em função da temperatura durante a transformação de fase.

Após inúmeras tentativas conceituais para o desenvolvimento da RNA, de como seriam dispostas as entradas e saídas da rede para que identificasse o comportamento da histerese, se chegou a uma topologia bastante simples para a arquitetura neural, a qual é mostrada na Figura 29.




Figura 29. Diagrama de blocos da arquitetura neural usada para identificação da histerese de atuadores LMF.

Na Figura 29, observa-se que a RNA tem duas entradas, uma para os parâmetros temperatura ou corrente elétrica e outra para o valor da carga. Duas saídas (com função linear), que podem gerar quaisquer dos perfis desejados, a saber, deformação ou deslocamento da LMF, dependendo do banco de dados usado, se da BCT ou BCE. Entre as camadas de entrada e saída existem as camadas escondidas. Pode-se ter apenas uma camada escondida (com função de transferência sigmóide) ou duas (com função de transferência sigmóide na primeira e linear na segunda). Vale ressaltar que todos os neurônios da rede têm um parâmetro adicional, o bias.

A Figura 30 auxilia na visualização de como foi realizada a entrada dos dados normalizados e qual resposta na saída da rede era esperada. Tomando com referência a rede da Figura 29, na entrada 1 (Temperatura ou Corrente Elétrica) foi colocado um valor  $E1'$ , obtido experimentalmente e, na Entrada 2 (Carga) o valor da carga  $E2'$  usada no experimento. Nesse caso, a resposta

desejada na saída da rede seria os valores  $S1'$  para o resfriamento e  $S2'$  para o aquecimento conforme Figura 30. Não sendo os valores de saída iguais ao desejados (os mesmo valores dos obtidos experimentalmente), um erro era calculado pela rede para atualização dos seus pesos. O processo de cálculo do erro e conseqüente ajuste de pesos se deram até que ocorresse a convergência, ou seja, os valores obtidos pela rede e os obtidos experimentalmente apresentassem diferença mínima. Resumidamente, quando se fornece a RNA as entradas  $E1'$  e  $E2'$  se deseja na saída os valores de  $S1'$  e  $S2'$  de forma simultânea. Como se pode observar, neste trabalho não se separou as curvas de resfriamento e aquecimento em treinamentos individuais da rede, sendo desta forma disponibilizadas em conjunto para um mesmo treinamento da RNA.




Figura 30. Esquema da disponibilização dos experimentais a entrada da RNA.

Para o desenvolvimento dos parâmetros ótimos de aprendizado da RNA, foram efetuados testes com 6 algoritmos dos 17 disponíveis na *toolbox* do programa Matlab<sup>®</sup> (Demuth, 2010) dedicada as RNA. Para verificar qual seria o melhor algoritmo a utilizar, considerando o tempo de treinamento e a melhor identificação do comportamento da histerese, foi utilizado um banco de dados de variação de resistência elétrica (VRE) em função da temperatura (T) do fio de LMF de NiTi sob carregamento de 250 MPa obtido na BCT por Rodrigues & De Araújo (2008). O uso de um banco de dados de VRE-T foi escolhido devido a possibilidade de maior complexidade no comportamento de histerese quando comparado com a característica de deformação-temperatura,



o que pode resultar em uma maior dificuldade no aprendizado da RNA e portanto uma melhor escolha do algoritmo a ser utilizado nas identificações seguintes.

O erro médio quadrático (do inglês *Root-Mean-Square* – RMS) foi calculado para todos os pontos obtidos na simulação da RNA de acordo com a configuração otimizada de cada algoritmo (ou seja, no melhor coeficiente de correlação), conforme definido pela Equação 4.

$$e_{\text{RMS}} = \sqrt{\frac{\sum_{i=1}^N (X_d - X_e)^2}{\sum_{i=1}^N X_e^2}} \times 100 \% \quad (4)$$

Em que  $x_d$  representa o dado de saída da RNA treinada,  $x_e$  representa o dado experimental e  $N$  o número de pontos do banco de dados.

A Tabela 1 apresenta a lista dos algoritmos testados e a comparação entre seus parâmetros em comum.

Tabela 1. Lista de algoritmos utilizados na identificação do banco de dados de VRE-temperatura.

<b>Algoritmo</b>	<b>Número de iterações</b>	<b>Taxa de aprendizado</b>	<b>Fator de Tempo</b>	<b>Menor Erro (%)</b>
<i>traingd</i>	5000	0,0015	Grande	0,77
<i>traingdm</i> <i>M=0,2</i>	5000	0,0015	Grande	1,41
<i>traingda</i>	1000	0,05-1,00	Médio	1,44
<i>trainrp</i>	Variável	delt_inc delt_dec	Pequeno	5,03
<i>traingcf</i>	Variável	Variável	Pequeno	1,01
<i>trainlm</i>	Variável	Variável	Pequeno	0,65

O algoritmo *traingd* (Gradiente Descent Backpropagation) foi testado impondo-se um máximo de 5000 iterações (ver Tab. A1, Apêndice A). Fixou-se a taxa de aprendizado em 0,0015, já que taxas maiores ocasionam a desestabilização do aprendizado da rede. Verificou-se que uma quantidade ínfima de neurônios não satisfaz uma boa resposta da simulação da rede em

comparação com os dados experimentais (exemplos: testes 1 e 2). Por outro lado, uma quantidade muito grande de neurônios desestabiliza o aprendizado.

O segundo algoritmo testado para o banco de dados do fio de NiTi sob carregamento de 250 MPa, foi o algoritmo `traingdm` (Gradient descent with momentum backpropagation) (ver Tab. A2, Apêndice A). Utilizou-se nesse, os mesmos parâmetros de rede anteriormente mencionados e o parâmetro característico desse algoritmo,  $\text{momento}=0,2$ , definido a partir de testes preliminares da qualidade da resposta da RNA. Com este algoritmo a rede apresentou baixo coeficiente de correlação.

Outro algoritmo testado foi o `traingda` (Gradient Descent Backpropagation with Adaptive Learning Rate) o qual apresenta a mesma configuração do `traingd`, mas com taxa de aprendizado variável em função do desempenho do aprendizado. Assim, foram introduzidas no algoritmo duas taxas, uma de 0,05 e outra 1,00 (ver Tab. A3, Apêndice A). Como padrão do algoritmo a quantidade de iterações é de 1000, que foi mantida para verificar a eficiência do aprendizado com o algoritmo. Observou-se que para os parâmetros de rede adotados, não se obteve uma boa resposta do coeficiente de correlação. Assim, para esses parâmetros, pode-se afirmar que este algoritmo não é o mais apropriado para o aprendizado do comportamento do atuador LMF.

Além desses algoritmos foi testado o `trainrp` (Resilient Backpropagation) que tem em sua estrutura um fator de incremento ( $\text{delt\_inc}$ ) e outro de redução ( $\text{delt\_dec}$ ) calculado a partir da mudança dos pesos (ver Tab. A4, Apêndice A). Enquanto a alteração dos pesos caminha em uma direção o fator  $\text{delt\_inc}$  gera uma maior compensação desses. Por outro lado, se a alteração dos pesos começa a oscilar, o fator  $\text{delt\_dec}$  gera uma redução na compensação dos pesos e bias. O resultado deste método é um treinamento extremamente rápido da rede. Notou-se que o erro obtido seguindo o método adotado apresentou o pior resultado quando comparado com os demais algoritmos testados.

O quinto algoritmo testado foi o `traincgf` (Conjugate Gradient Backpropagation with Fletcher-Reeves Restarts), o qual atualiza seus pesos a

cada iteração, como também trabalha em função do negativo do gradiente, ou seja, na direção em que se diminui o erro muito mais rápido (ver Tab. A5, Apêndice A). Algumas das características desse algoritmo merecem ser destacadas como: alto coeficiente de correlação e baixo tempo de treinamento (situando-se igual ou menor que 6 segundos), neste ponto sendo bem inferior ao *traind*, o que agiliza o trabalho para se obter os parâmetros de rede.

Outros métodos (algoritmos) estão disponíveis no Matlab, entre eles o algoritmo *trainlm* (Levenberg-Marquardt) que converge rapidamente seu treinamento, entretanto tem um alto custo computacional. Seguindo a metodologia adotada foram efetuados testes com a RNA usando o algoritmo *trainlm*. Verificou-se para este algoritmo um alto coeficiente de correlação em praticamente todos os testes realizados (ver Tab. A6, Apêndice A). Para a escolha da melhor configuração de rede foi observado o melhor resultado do coeficiente de correlação para o regime de testes. Assim, tem-se na configuração com 15 neurônios os melhores parâmetros de RNA para simulação de um banco de dados único usando o algoritmo *trainlm*.

Resumidamente, observou-se que os três primeiros algoritmos são sensíveis a taxa de aprendizado (que é fixa) podendo desestabilizar o treinamento da rede, caso esta seja muito alta para uma dada configuração da RNA (ver Tabelas A1 e A2 do apêndice A). Alguns arranjos neurais apresentaram altos coeficientes de correlação, entretanto não demonstraram repetitividade nos resultados, o que foi atribuído a uma otimização particular dos pesos (disponibilizados aleatoriamente pelo Matlab<sup>®</sup>) no momento do treinamento para o arranjo testado e não se repete para outros parâmetros de inicialização randômicos.

O algoritmo escolhido para a continuação dos testes de identificação foi o *trainlm* (Levenberg-Marquardt) utilizando como referência seu baixo tempo para treinamento, alto coeficiente de correlação (reduzido erro) e a própria indicação da literatura referente a *toolbox* do Matlab<sup>®</sup> (Demuth, 2010).

## 6. RESULTADOS E DISCUSSÕES

Preliminarmente aos testes de estimação do comportamento de histerese dos atuadores de LMF, realizou-se um mapeamento das configurações ótimas de uma rede, com apenas uma entrada, para a identificação da histerese do deslocamento em função da corrente elétrica. Em seguida, utilizando a configuração de RNA mostrada na Figura 29, foi verificada a capacidade da rede treinada estimar o comportamento histerético intermediário do atuador LMF com carregamento entre dois bancos de dados utilizados para o treinamento. Esse levantamento da capacidade de estimação da RNA foi efetuado utilizando inicialmente uma camada escondida de neurônios, variando de 1 a 25. Em seguida, foi verificada a resposta da rede para duas camadas escondidas (ocultas), com a primeira camada variando de 1 à 10 neurônios e a segunda de 2 à 8. Na seção 6.1 são apresentados os resultados desta análise para os bancos de dados eletromecânicos, usando a BCE, e na seção 6.2 os dados de origem termomecânica obtidos com a BCT.

### 6.1. Identificação da histerese eletromecânica

Antes de verificar a capacidade da RNA (Figura 29) treinada estimar um comportamento do fio de LMF NiTi com 0,29 mm de diâmetro, realizou-se uma varredura da capacidade de um RNA identificar o comportamento do deslocamento do fio ao longo do tempo de ativação para as ondas triangular e triangular reduzida. Desta forma, conforme ilustra a Figura 31, foi fornecida a uma rede com apenas uma entrada os dados do tempo e desejando na saída a resposta do deslocamento do fio atuador. Para esta RNA foi utilizada apenas uma camada escondida com função de transferência sigmóide.




Figura 31. RNA de apenas uma entrada e uma saída.

A metodologia aplicada foi fazer variar a quantidade de neurônios de 1 a 25 na camada escondida e verificar o erro da simulação da RNA treinada frente aos dados experimentais.

Na Figura 32 são apresentados os resultados da superposição da simulação (com menor erro) da RNA treinada sobre os dados experimentais de ativação do fio de LMF de NiTi submetido a onda triangular de corrente elétrica.

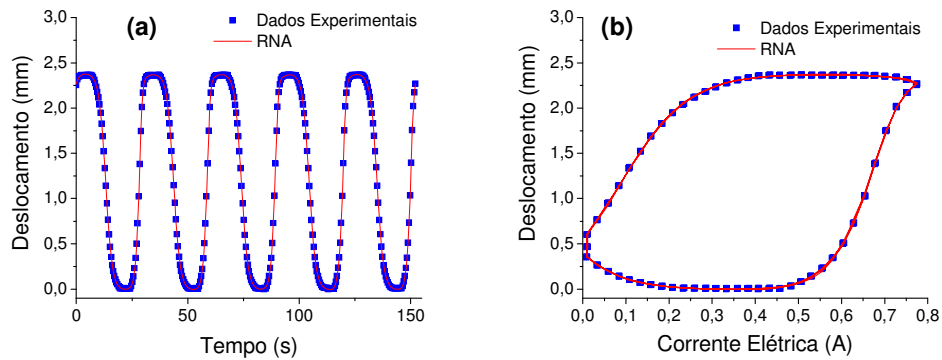


Figura 32. Superposição da simulação da RNA sobre os dados experimentais do fio de LMF de NiTi sob 200 MPa e ativado por onda de corrente elétrica triangular. (a) Deslocamento-Tempo. (b) Deslocamento-Corrente Elétrica.

Na tabela B1, do Apêndice B, são apresentados os resultados dos testes efetuados para o perfil de onda triangular. Observa-se que o menor erro obtido foi de 0,54 % durante o teste com 22 neurônios na camada escondida. Mostra-se na Figura 33 a tendência de diminuição do erro de simulação da RNA com o aumento do número de neurônios.

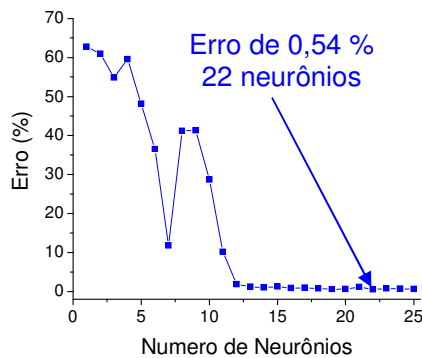


Figura 33. Erro de simulação da RNA em função do número de neurônios da rede.

A Figura 34 apresenta a superposição da simulação da RNA, treinada com 24 neurônios na camada escondida, sobre os dados experimentais coletados a partir da bancada da Figura 17, com o fio de LMF de NiTi submetido a 200 MPa.

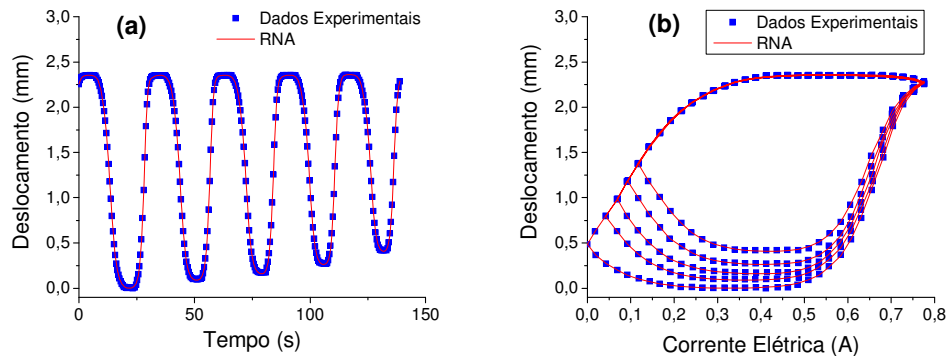


Figura 34. Superposição da simulação da RNA sobre os dados experimentais do fio de LMF NiTi sob 200 MPa e ativado por onda de corrente elétrica triangular reduzida.

(a) Deslocamento-Tempo. (b) Deslocamento-Corrente Elétrica.

Na tabela B2 do Apêndice B, são mostrados os resultados dos testes de simulação da RNA para a onda de ativação elétrica triangular reduzida. Conforme se pode observar, o menor erro apresentado pela simulação da RNA para a onda de ativação triangular reduzida foi de 0,46 % para a configuração com 24 neurônios na camada escondida. Mostra-se na Figura 35 a tendência de redução do erro da simulação da RNA com o aumento do número de neurônios.




Figura 35. Erro da simulação da RNA em função do número de neurônios.

Essa capacidade da RNA aprender os comportamentos das Figuras 32 e 34 é bastante interessante, já que o uso de controladores clássicos para acompanhar o atraso na resposta da LMF em função do tipo de onda de ativação pode ser bastante difícil devido à necessidade de uma estrutura de controle robusta. Além disso, com esse potencial de aprendizagem da RNA, pretende-se a identificação do comportamento da LMF utilizando entradas de onda de corrente elétrica ou temperatura diferentes do habitual.

#### **6.1.1. Identificação usando uma camada escondida**

Na Tabela C1 do Apêndice C, são apresentados os resultados dos testes de identificação da histerese eletromecânica realizados para os bancos de dados correspondentes aos carregamentos de 150 MPa, 250 MPa (treinamento) e 200 MPa (estimação), sob o fio de LMF NiTi. Conforme se pode observar, a RNA apresentou erro de 3,98 % para a estimação do banco de dados de 200 MPa na configuração com apenas 2 neurônios na camada escondida. Os erros para a simulação dos bancos de dados de 150 MPa e 250 MPa foram de 9,50 % e 8,08 %, respectivamente. A Figura 36, mostra o resultado da superposição da simulação da RNA sobre os bancos de dados de 150 MPa, 250 MPa (treinamento) e 200 MPa (estimação).

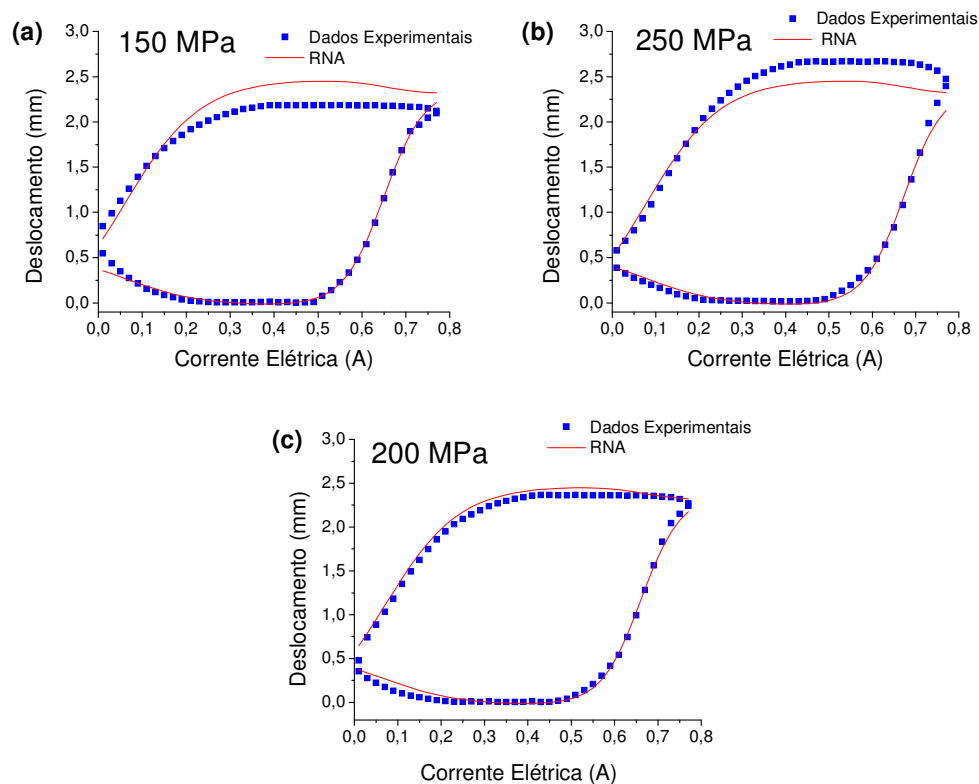


Figura 36. Superposição da simulação da RNA treinada com uma camada escondida, sobre os dados experimentais do fio de LMF NiTi para: (a) 150 MPa, (b) 250 MPa usados no treinamento da RNA e (c) 200 MPa usado para verificar o grau de estimação da RNA.

Observando a Figura 37 verifica-se que, à medida que se aumenta o erro na estimação do banco de dados de 200 MPa, os erros na simulação dos bancos de dados utilizados no treinamento (150 MPa e 250 MPa) tendem a diminuir. Essa variação do erro pode ser fruto do grau de generalização da rede, ou seja, quanto mais especialista a RNA for para os bancos de dados usados no treinamento maior será o erro na estimação do terceiro banco de dados.



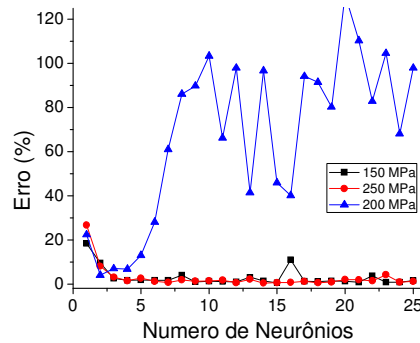


Figura 37. Evolução do erro da RNA treinada com uma camada escondida na simulação dos dados experimentais do fio de LMF NiTi submetido a 150 MPa, 250 MPa (treinamento) e 200 MPa (estimação).

Na Tabela C2 do Apêndice C, são apresentados os resultados dos testes de identificação da histerese eletromecânica realizados para os bancos de dados de 100 MPa, 200 MPa (treinamento) e 150 MPa (estimação). Conforme se pode observar, a RNA apresentou um erro de 5,70 % para a estimação do banco de dados de 200 MPa na configuração com apenas 2 neurônios, enquanto que na simulação dos bancos de dados de 100 MPa e 200 MPa esses erros foram de 13,96 % e 9,42 %, respectivamente.

A Figura 38 mostra o resultado da superposição da simulação da RNA sobre os bancos de dados de 100 MPa, 200 MPa (treinamento) e 150 MPa (estimação).

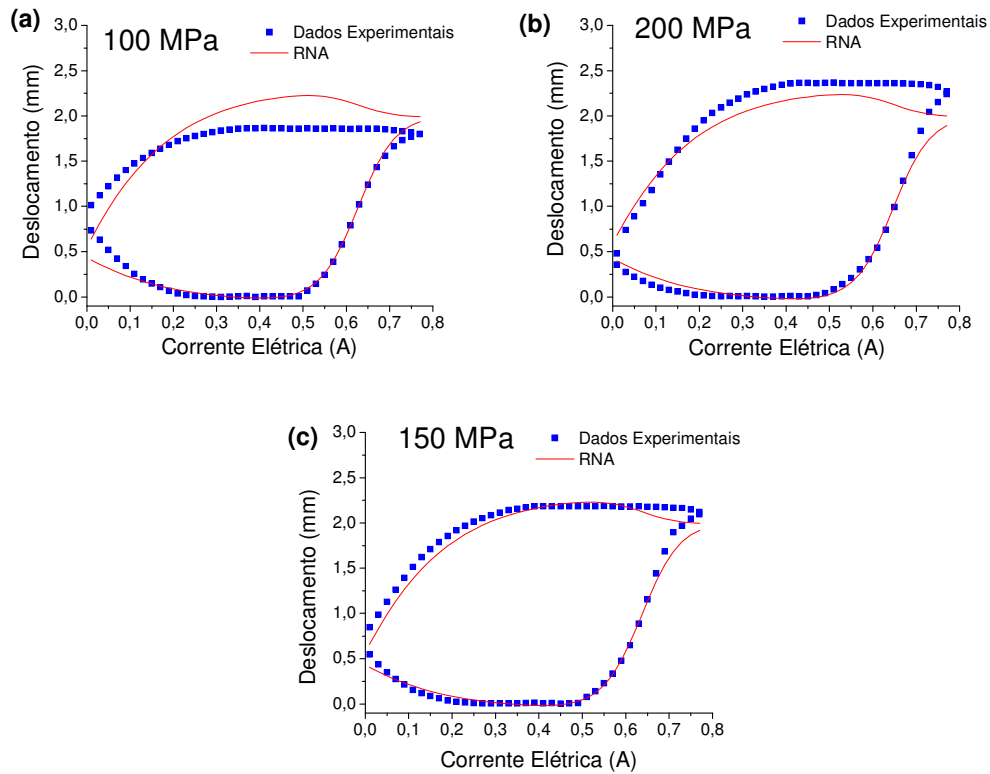


Figura 38. Superposição da simulação da RNA treinada com uma camada escondida sobre os dados experimentais do fio de LMF NiTi para: (a) 100 MPa, (b) 200 MPa usados no treinamento da RNA e (c) 150 MPa usado para verificar o grau de estimação da RNA.

Novamente se constatou a tendência de aumento do erro na estimação (banco de dados de 150 MPa) à medida que a rede se torna especialista nos bancos de dados usados no treinamento (100 MPa e 200 MPa), conforme indica o comportamento da Figura 39.




Figura 39. Evolução do erro da RNA treinada com uma camada escondida na simulação dos dados experimentais do fio de LMF NiTi submetido a 100 MPa, 200 MPa (treinamento) e 150 MPa (estimação).

Na Tabela C3 do Apêndice C, são apresentados os resultados dos testes de identificação da histerese eletromecânica realizados para os bancos de dados de 50 MPa, 150 MPa (treinamento) e 100 MPa (estimação). Conforme se pode observar, a RNA apresentou o erro de 24,30 % para a estimação do banco de dados de 100 MPa na configuração com apenas 5 neurônios, enquanto que na simulação dos bancos de dados de 50 MPa e 150 MPa, esses erros foram de 14,85 % e 7,95 %, respectivamente. O alto erro apresentado pela rede durante a estimação pode ser fruto do alto grau de variação dos perfis das curvas para as cargas mais baixas, de 50 MPa, 150 MPa e 100 MPa, o que dificulta uma estimação do comportamento da histerese com um erro mínimo.

A Figura 40 mostra o resultado da superposição da simulação da RNA sobre os bancos de dados de 50 MPa, 150 MPa (treinamento) e 100 MPa (estimação).

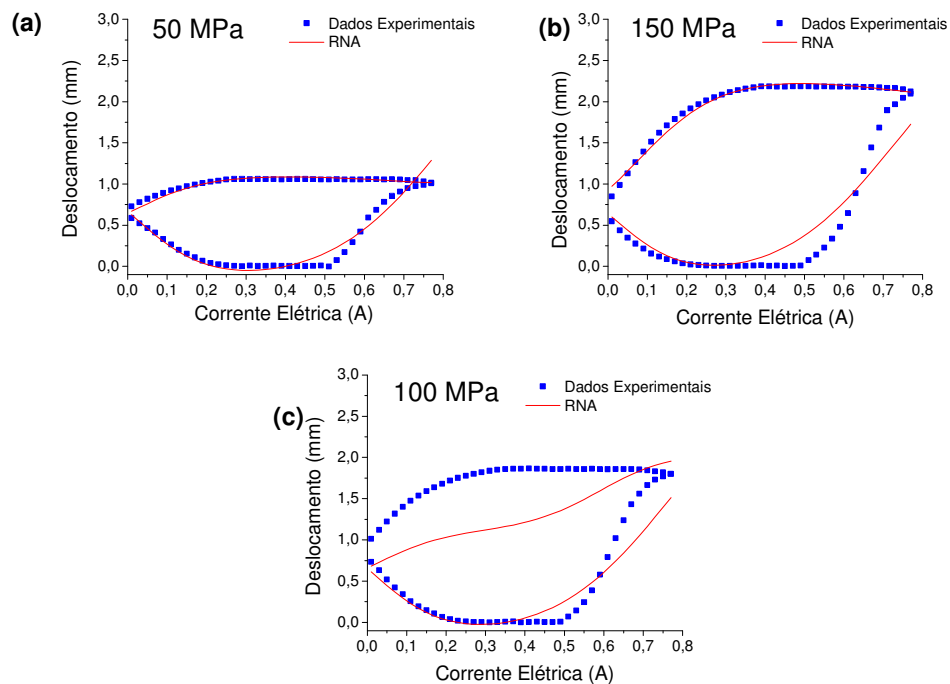


Figura 40. Superposição da simulação da RNA treinada com uma camada escondida sobre os dados experimentais do fio de LMF NiTi para: (a) 50 MPa, (b) 150 MPa usados no treinamento da RNA e (c) 100 MPa usado para verificar o grau de estimativa da RNA.

Mostra-se na Figura 41, a variação do erro na simulação da RNA para os bancos de dados de 50 MPa, 150 MPa (treinamento) e 100 MPa (Simulação).




Figura 41. Evolução do erro da RNA treinada com uma camada escondida na simulação dos dados experimentais do fio de LMF NiTi submetido a 50 MPa, 150 MPa (treinamento) e 100 MPa (estimativa).

### 6.1.2. Identificação usando duas camadas escondidas

Conforme revela a Tabela D1 do Apêndice D, no caso das simulações dos bancos de dados de 150 MPa, 250 MPa (treinamento) e 200 MPa (estimação), observou-se diversas configurações em que o erro para estimação do banco de dados de 200 MPa ficou abaixo de 10 %. Na melhor configuração (2-3) obtida, se observou um leve aumento do erro de 3,98 % (erro para a configuração com uma camada escondida, ver seção 6.1.1) para 4,02 %. Já para as simulações dos bancos de dados utilizados no treinamento, o erro foi de 8,94 % e 8,63 %, respectivamente para os bancos de dados de 150 MPa e 250 MPa. Estes erros foram praticamente equivalentes ao caso da utilização de apenas uma camada escondida, em que se constataram erros de 9,50 % e 8,08 %, respectivamente.

A Figura 42 mostra os resultados da superposição da simulação da rede treinada para os bancos de dados de 150 MPa, 200 MPa (treinamento) e 250 MPa (estimação).

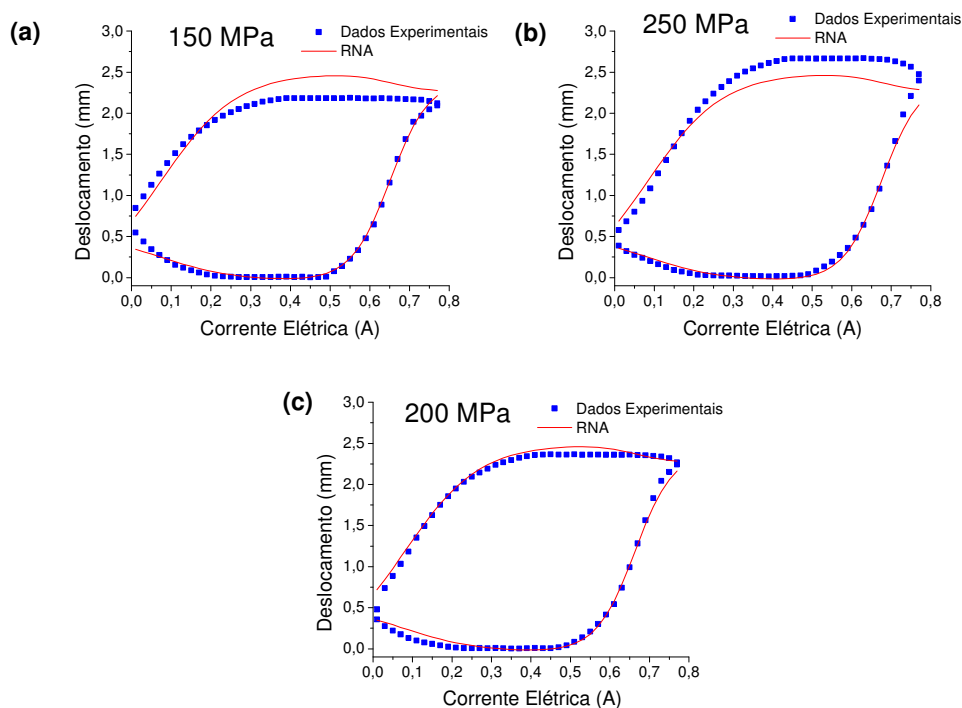


Figura 42. Superposição da simulação da RNA treinada com duas camadas escondidas sobre os dados experimentais para: (a) 150 MPa, (b) 250 MPa usados no treinamento da RNA e (c) 200 MPa usado para verificar o grau de estimação da RNA.

A Tabela D2, do Apêndice D, mostra os resultados das simulações para os bancos de dados de 100 MPa, 200 MPa (treinamento) e 150 MPa (estimação) para a RNA com duas camadas escondidas. Observa-se, para a estimação do banco de dados de 150 MPa, uma redução do erro (quando se compara os testes com uma e duas camadas escondidas) de 5,70 % para 4,02 % na configuração com 2 neurônios na primeira camada e 5 na segunda. Já para os bancos de dados utilizados no treinamento houve uma leve redução para a simulação do banco de dados de 100 MPa, de 13,96 % para 12,77 % e um leve aumento para o banco de dados de 200 MPa de 9,42 % para 9,88 %.

A Figura 43 mostra o resultado da simulação da RNA treinada para os bancos de dados de 100 MPa, 200 MPa e 150 MPa.

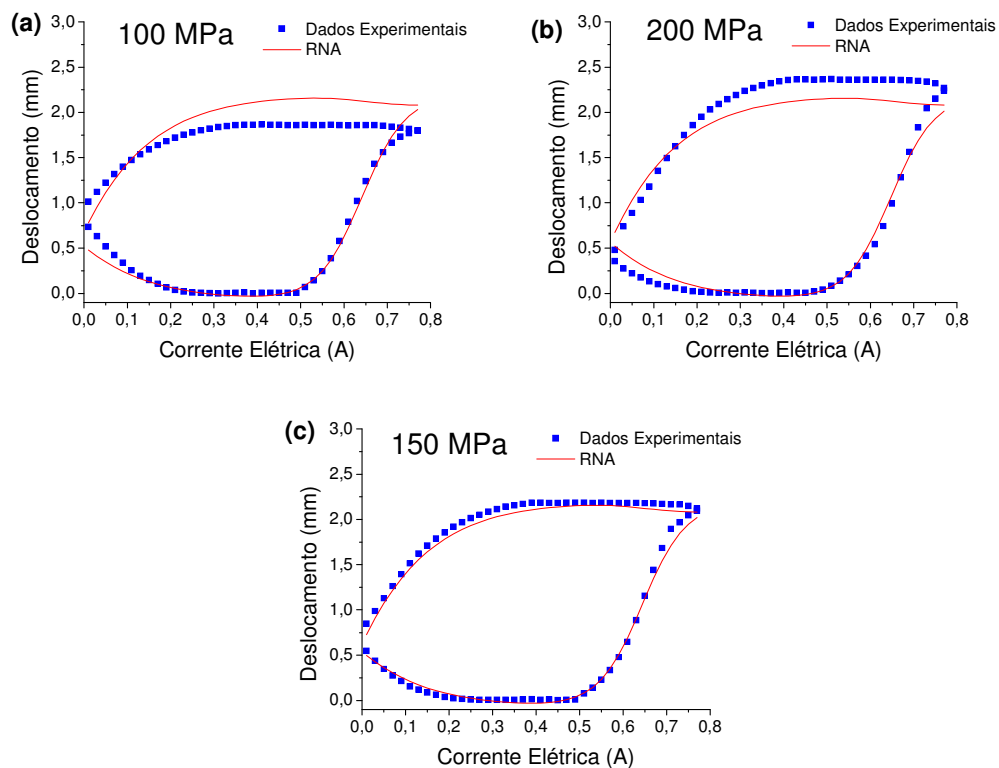


Figura 43. Superposição da simulação da RNA treinada com duas camadas escondidas sobre os dados experimentais para: (a) 100 MPa, (b) 200 MPa usados no treinamento da RNA e (c) 150 MPa usado para verificar o grau de estimação da RNA.

Conforme indica a Tabela D3, do Apêndice D, foi utilizada também a configuração de rede com duas camadas escondidas para os bancos de dados

de 50 MPa, 150 MPa (treinamento) e 100 MPa (estimação). Nesse caso se obteve uma redução do erro na estimação, de 24,30 % para 13,85 % (comparando a quantidade de camadas escondidas) na configuração de rede com 4 neurônios na primeira camada escondida e 5 na segunda. Para este banco de dados houve uma grande redução do erro, já que foram reduzidos mais de 10 pontos percentuais. O erro para a simulação dos bancos de dados utilizados no treinamento ficaram em 6,14 % e 2,94 %, respectivamente para os bancos de dados de 50 MPa e 150 MPa. Estes erros também foram menores que os apresentados para a configuração com apenas uma camada escondida, em que se observaram erros de 14,85 % e 7,95 %, respectivamente.

Na Figura 44, são apresentados os resultados das superposições da simulação da RNA treinada para os três bancos de dados de referência: 50 MPa, 150 MPa e 100 MPa.

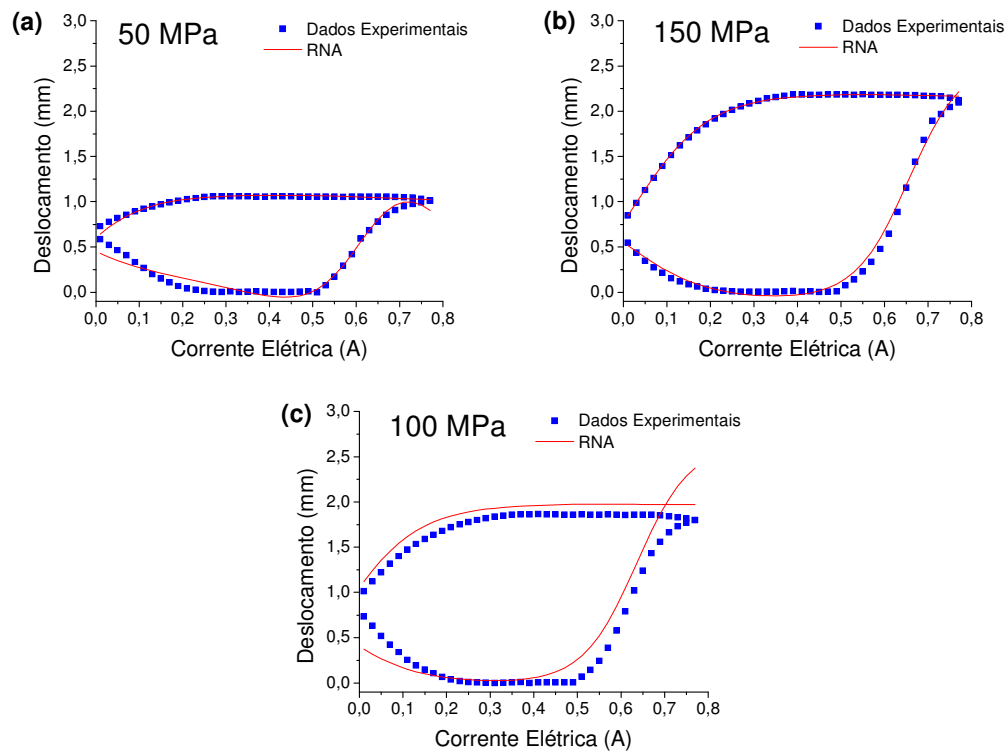


Figura 44. Superposição da simulação da RNA treinada com duas camadas escondidas sobre os dados experimentais para: (a) 50 MPa, (b) 150 MPa usados no treinamento da RNA e (c) 100 MPa usado para verificar o grau de estimação da RNA.

## 6.2. Identificação da histerese termomecânica

### 6.2.1. Identificação usando uma camada escondida

Na Tabela E1 do apêndice E, são apresentados os resultados dos testes de identificação da histerese termomecânica realizados para os bancos de dados de 150 MPa, 250 MPa (treinamento) e 200 MPa (estimação). Verificou-se que o menor erro na estimação da rede treinada com apenas uma camada escondida se deu com 3 neurônios, ficando em torno de 8,13 %.

A Figura 45 mostra a superposição das simulações da RNA para a melhor configuração de rede obtida.




Figura 45. Superposição da simulação da RNA treinada com uma camada escondida sobre os dados experimentais para: (a) 150 MPa, (b) 250 MPa usados no treinamento da RNA e (c) 200 MPa usado para verificar o grau de estimação da RNA.

Observando a Tabela E1, do Apêndice E, e a Figura 46 é possível notar que a rede se torna mais especialista nos bancos de dados usados no treinamento quando se aumenta o número de neurônios, entretanto perde a



capacidade de generalização resultando em uma pior estimaco do banco de dados no fornecido durante o treinamento. Essa caracterstica tambm foi observada para o treinamento com os bancos de dados eletromecnicos (conforme discutido na seo 6.1.1). Isso fica mais bem evidenciado quando se compara o teste 3 e o teste 25, em que a simulaco da rede para os bancos de dados usados no treinamento (150 MPa e 250 MPa) ficou em 4,28 %, 3,73 % e 0,79 %, 0,78 %, respectivamente, enquanto que as estimaces (200 MPa) para os mesmos testes apresentaram erros da ordem de 8,13 % e 143,30 %, respectivamente.




Figura 46. Evoluo do erro da RNA treinada com uma camada escondida na simulaco dos dados experimentais do fio de LMF NiTi submetido a 150 MPa, 250 MPa (treinamento) e 200 MPa (estimaco).

Na Tabela E2 do Apndice E, so mostrados os testes efetuados com o treinamento da RNA (com uma camada escondida) para os bancos de dados de 100 MPa e 200 MPa e estimaco do banco de dados de 150 MPa. O menor erro na estimaco foi de 13,19 %, ou seja, com a rede tendo 4 neurnios na camada escondida. J os erros da simulaco para os bancos de dados utilizados no treinamento foram de 2,90 e 2,09 %, respectivamente, para os bancos de dados de 100 MPa e 200 MPa.

A Figura 47 apresenta a superposio da simulaco da RNA sobre os dados experimentais usados para o treinamento e verificao da aproximao da estimaco da rede.

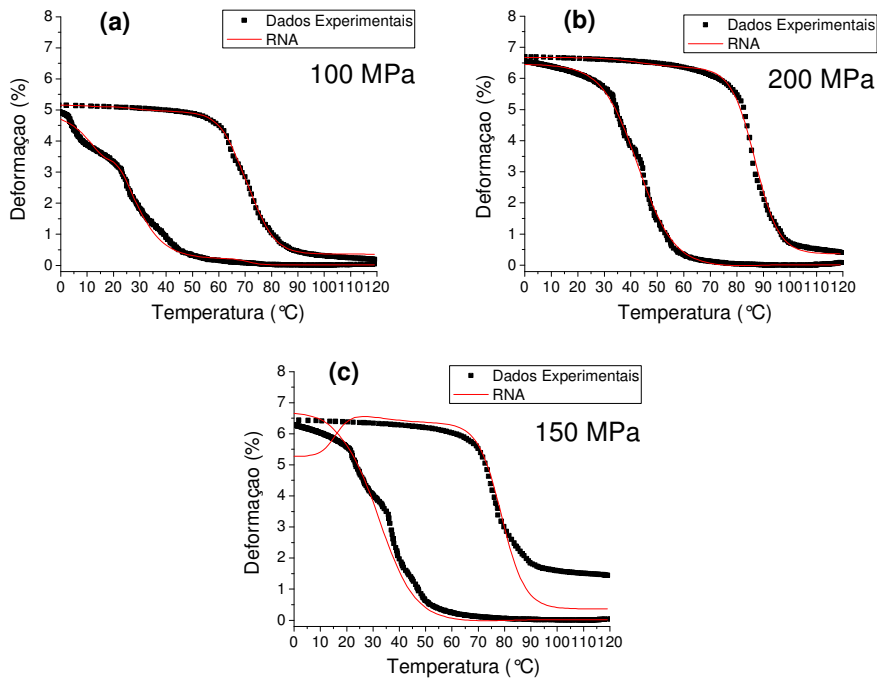


Figura 47. Superposição da simulação da RNA treinada com uma camada escondida sobre os dados experimentais para: (a) 100 MPa, (b) 200 MPa usados no treinamento da RNA e (c) 150 MPa usado para verificar o grau de estimação da RNA.

A mesma regra de especialização da RNA observada para os resultados da Tabela E1 é válida para os resultados da Tabela E2, ou seja, a RNA perde a capacidade de generalizar conforme se aumenta o número de neurônios como pode ser observado na Figura 48.




Figura 48. Evolução do erro da RNA treinada com uma camada escondida na simulação dos dados experimentais do fio de LMF NiTi submetido a 100 MPa, 200 MPa (treinamento) e 150 MPa (estimação).

Para o caso da estimação do banco de dados de 100 MPa e a RNA treinada com os bancos de dados de 50 MPa e 150 MPa, conforme se pode observar na Tabela E3 do Apêndice E, verificou-se um alto erro na estimação da RNA, sendo o menor para a configuração com 4 neurônios na camada escondida, situando-se em 28,81 %. Este alto erro foi atribuído a grande diferença entre as curvas de deformação-temperatura, conforme pode ser observado na Figura 49, em que se superpõe os três comportamentos do fio atuador de LMF NiTi.




Figura 49. Superposição das curvas experimentais do comportamento do fio de NiTi sob os carregamentos de 50 MPa, 100 MPa e 150 MPa.

Na Figura 50 é mostrada a superposição das simulações sobre os respectivos dados experimentais para os três bancos de dados mostrados na Figura 49.

Pode-se observar na Figura 50, que ocorreu uma grande dispersão da simulação frente ao comportamento a ser estimado (banco de dados de 100 MPa). Por outro lado a RNA apresentou uma boa aproximação para os dados utilizados durante o treinamento, apresentando erros de 8,85 e 3,71 %, respectivamente para os bancos de dados de 50 e 150 MPa, conforme Tabela E3, do Apêndice E.

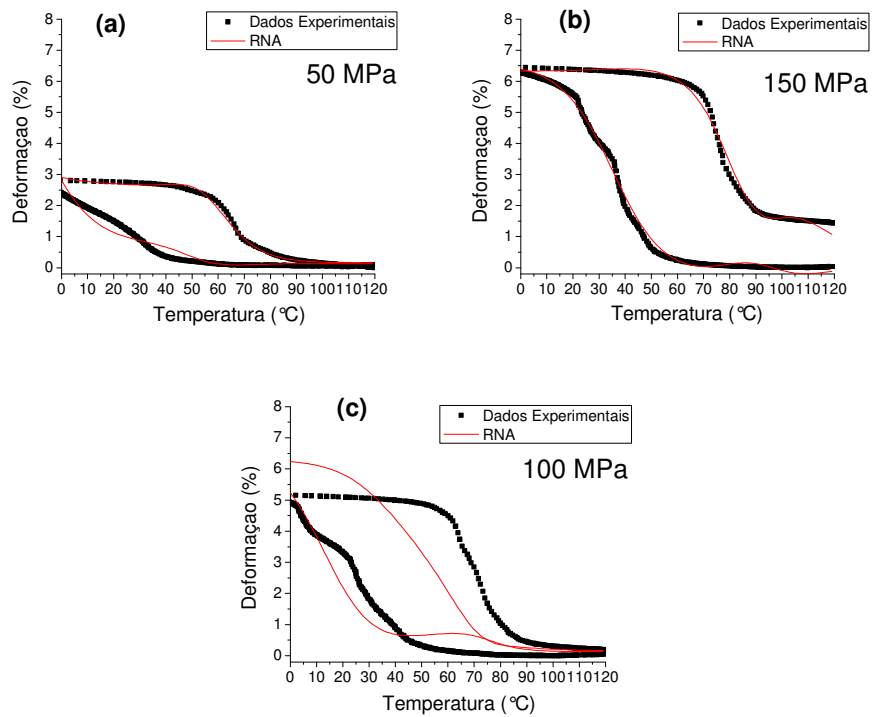


Figura 50. Superposição da simulação da RNA treinada com uma camada escondida sobre os dados experimentais para: (a) 50 MPa, (b) 150 MPa usados no treinamento da RNA e (c) 100 MPa usado para verificar o grau de estimação da RNA.

Mostra-se na Figura 51 a evolução do erro na estimação do banco de dados de 100 MPa com o aumento do número de neurônios.




Figura 51. Evolução do erro da RNA treinada com uma camada escondida na simulação dos dados experimentais do fio de LMF NiTi submetido a 50 MPa, 150 MPa (treinamento) e 100 MPa (estimação).

## **6.2.2. Identificação usando duas camadas escondidas**

Com o objetivo de verificar se é possível reduzir o erro dos testes com uma camada escondida, foram realizados treinamentos da RNA com duas camadas escondidas variando o número de neurônios na primeira camada de 1 a 10 e na segunda de 2 a 8. Nas Tabelas F1, F2 e F3 do Apêndice F são apresentados os resultados desses testes em que se utilizam as mesmas configurações de disponibilização de dados.

Conforme mostra Tabela F1, do Apêndice F, no caso das simulações dos bancos de dados de 150 MPa, 250 MPa (treinamento) e 200 MPa (estimação), observou-se diversas configurações em que o erro para estimação do banco de dados de 200 MPa ficou abaixo de 10 %. Na melhor configuração (5-2) obtida se teve uma redução do erro de 8,13 % (erro para a configuração com uma camada escondida, ver seção 6.2.1) para 6,82 %. Já para as simulações para os bancos de dados utilizados no treinamento, o erro foi de 2,67 % e 1,80 % respectivamente para os bancos de dados de 150 MPa e 250 MPa. Estes erros foram menores que o caso da utilização de apenas uma camada escondida, em que se constataram os erros de 4,28 % e 3,73 %, respectivamente.

A Figura 52 mostra os resultados da superposição da simulação da rede treinada para os bancos de dados de 150 MPa, 250 MPa (treinamento) e 200 MPa (estimação).




Figura 52. Superposição da RNA treinada com duas camadas escondidas sobre os dados experimentais para: (a) 150 MPa, (b) 250 MPa (treinamento) e (c) 200 MPa (estimação).

A Tabela F2, do Apêndice F, mostra os resultados das simulações para os bancos de dados de 100 MPa, 200 MPa (treinamento) e 150 MPa (estimação) para a RNA com duas camadas escondidas em que se apresentou para a estimação do banco de dados de 150 MPa uma redução do erro, (quanto se compara os testes com uma e duas camadas escondidas) de 13,19 % para 11,02 % na configuração com 4 neurônios na primeira camada e 5 na segunda. Entretanto, fazendo a mesmo comparativo em relação às camadas escondidas, para esta mesma configuração de bancos de dados utilizados no treinamento houve um aumento do erro de 2,90 % e 2,09 % para 8,80 % e 6,02 %, respectivamente para os bancos de dados de 100 MPa e 200 MPa. A Figura 53 mostra o resultado da simulação da RNA treinada para os bancos de dados de 100 MPa, 200 MPa e 150 MPa.




Figura 53. Superposição da RNA treinada com duas camadas escondidas sobre os dados experimentais para: (a) 100 MPa, (b) 200 MPa (treinamento) e (c) 150 MPa (estimação).

Conforme mostra a Tabela F3, do Apêndice F, a configuração de rede com duas camadas escondidas foi utilizada também para os bancos de dados de 50 MPa, 150 MPa (treinamento) e 100 MPa (estimação) reduzindo o erro de 28,81 % para 18,52 % (comparando a quantidade de camadas escondidas) na configuração de rede com 2 neurônios na primeira camada escondida e 5 na segunda. Para este banco de dados houve uma boa redução do erro, já que foram reduzidos mais de 10 pontos percentuais. Além disso, aproximadamente esse mesmo percentual de erro na estimação é verificado para outras configurações, o que mostra certa reprodutibilidade dos resultados para diferentes configurações. O erro para a simulação dos bancos de dados utilizados no treinamento ficaram em 19,93 % e 8,41 %, respectivamente para os bancos de dados de 50 MPa e 150 MPa, o que representou um aumento em comparação com a configuração de rede com apenas uma camada escondida.

Na Figura 54, são apresentados os resultados das superposições da simulação da RNA treinada para os três bancos de dados de referência: 50 MPa, 150 MPa e 100 MPa.

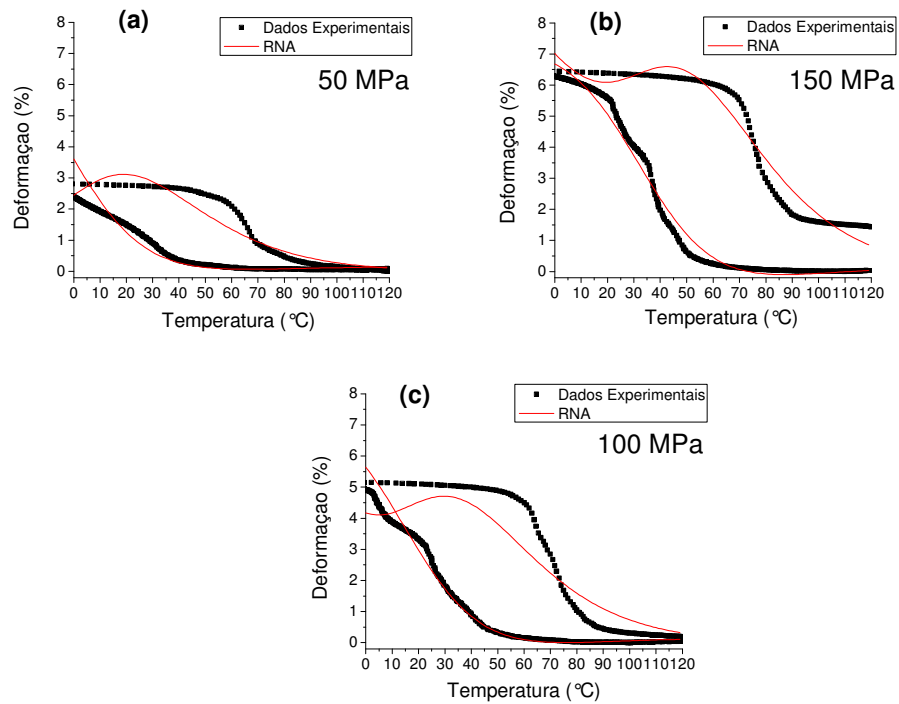


Figura 54. Superposição da RNA treinada com duas camadas escondidas sobre os dados experimentais para: (a) 50 MPa, (b) 150 MPa (treinamento) e (c) 100 MPa (estimação).



## 7. CONCLUSÕES

Neste trabalho foi estudada a capacidade de uma RNA aprender o comportamento da histerese de fios atuadores de uma LMF de NiTi a partir de bancos de dados de ativações elétrica e térmica. Adicionalmente, verificou-se a capacidade de estimação de uma RNA com o algoritmo de Levenberg-Marquardt (trainlm), disponível no Matlab<sup>®</sup>, para um banco de dados não fornecido a rede durante o treinamento.

Através dos resultados obtidos, foi possível concluir que a configuração de RNA utilizada permite a identificação do comportamento da histerese elétrica da LMF de NiTi com alto grau de precisão. Neste caso, foram observados que os menores erros obtidos durante os testes com a RNA de apenas uma camada escondida (especialmente desenvolvida para verificar a capacidade de aprendizagem das RNA) foram de 0,54 % na configuração com 22 neurônios nesta camada e 0,46 % para a configuração de 24 neurônios, respectivamente para o caso de aplicação da onda triangular de corrente elétrica e onda triangular de corrente elétrica reduzida. A ordem de grandeza desses erros pode ser considerada bastante pequena, demonstrando um alto grau de identificação do comportamento do atuador LMF pela RNA. Observou-se também que em ambos os casos há uma tendência de diminuição do erro de simulação da RNA com o aumento do número de neurônios.

No caso da RNA com duas entradas e saídas (utilizada para estimar um comportamento do atuador LMF sob carga) verificou-se que a RNA obtém erros aceitáveis na estimação dos bancos de dados que contém o comportamento da LMF, principalmente para os maiores carregamentos (150 MPa e 200 MPa). No caso dos bancos de dados de origem elétrica, sob carga de 200 MPa, a RNA de 2 entradas e 2 saídas apresentou erro de 3,98 % e 4,02 %, respectivamente na rede com única camada escondida e com 2 camadas escondidas. Esses valores demonstraram que não houve melhora de resultados com o acréscimo da segunda camada escondida. Já para a estimação dos dados do banco de 150 MPa, também de origem elétrica, observou-se uma redução do erro de 5,70 % para 4,02 % com o acréscimo da

segunda camada escondida. Neste caso, ocorreu uma melhora na aproximação da estimação da RNA. Adicionalmente, para a estimação do banco de dados de 100 MPa (de origem elétrica) houve uma boa redução do erro com o acréscimo da segunda camada escondida, diminuindo de 24,30 % para 13,85 %, o que representa uma vantagem na sua utilização.

Os testes de estimação (utilizado a RNA com duas entradas e duas saídas) para os bancos de dados de origem térmica apresentaram praticamente a mesma tendência de redução do erro com a inclusão da segunda camada escondida. No caso, da estimação do banco de dados de 200 MPa, o erro com uma camada escondida foi de 8,13 %, enquanto que com duas camadas esse erro foi de 6,82 %. Para o carregamento de 150 MPa a redução foi de 13,19 % para 11,02 %. Já para o de 100 MPa o erro caiu de 28,81 % para 18,52 %.

Diante dos resultados obtidos, verifica-se que a técnica de RNA pode ser utilizada para aprender o comportamento de histerese de atuadores baseados em LMF e ainda ser útil para estimar um comportamento não disponibilizado a rede durante o treinamento, tornando-se uma ferramenta bastante interessante para o desenvolvimento e aprimoramento de aplicações que usam LMF na forma de atuadores.

## 8. SUGESTÕES PARA PESQUISAS FUTURAS

Com base nos resultados e conclusões obtidas desta pesquisa, é possível sugerir as seguintes opções de trabalhos futuros:

- A partir da capacidade de aprendizagem das RNA, criar um controlador neural capaz de controlar a resposta de deslocamento do atuador;
- Utilizar diferentes funções de ativação por corrente elétrica de modo a se obter diferentes comportamentos das LMF;
- Estudar a capacidade de generalização da RNA determinando pesos e bias iniciais sempre iguais para os comportamentos estudados da LMF. Nesse sentido, impor diferentes performances para o treinamento da rede, a fim de melhorar o grau de estimação da RNA;
- Utilizar RNA para estimar outros comportamentos das LMF, como por exemplo, a resposta da variação de resistência elétrica em função da temperatura ou corrente elétrica, como também o regime de superelasticidade.

## 9. REFERÊNCIAS BIBLIOGRÁFICAS

ASUA, E.; ETXEBARRIA, V.; GARCIA-ARRIBAS, A. Neural Network-Based Micropositioning Control of Smart Shape Memory Alloy Actuators. **Engineering Application of Artificial Intelligence**. Espanha, 2007.

BARRETO, J.M., **Indrodução(sic) às Redes Neurais Artificiais**. Universidade Federal de Santa Catarina – UFSC, Departamento de Informática e de Estatística, Laboratório de Conexionismo e Ciências Cognitivas, Florianópolis – SC, 2002.

DE ARAÚJO, C.J. **Comportement cyclique de fils en alliage à mémoire de forme Ti-Ni-Cu: analyse electro-thermomécanique, dégradation et fatigue par cyclage thermique sous contrainte**. Thèse de Doctorat – INSA de Lyon, France, 1999.

DE ARAÚJO, C.J., RODRIGUES, L.F.A., COUTINHO NETO, J.F., REIS, R.P.B., “Fabrication and Static Characterization of Carbon-Fiber-Reinforced Polymers with Embedded NiTi Shape Memory Wire Actuators”. **Smart Materials and Structures**, v. 17, p. 065004, 2008,

DEMUTH, H.; BEALE, M.; HAGAN, M., **Neural Network Toolbox™ 6**, Revised for Version 6.0.4 (Release 2010a), Editora: The MathWorks, Inc., 2010.

EYERCIOGLU, O., KANCA, E., PALA, M., OZBAY, E., “Prediction of Martensite and Austenite Start Temperatures of The Fe-Based Shape Memory Alloys by Artificial Neural Networks”. **Journal of Materials Processing Technology**, v. 200, pp. 146-152., 2007.

FARIAS, V.; SOLIS, L.; MELÉNDEZ, L.; GARCÍAS, C.; VELÁZQUEZ, R., **A Four-Fingered Robot Hand with Shape Memory Alloys**, IEEE AFRICON, 23 - 25 Setembro, Nairobi, Kenya, 2009.

FERNEDA, E., **Redes Neurais e Sua Aplicação em Sistemas de Recuperação de Informação**. Documentação da Faculdade de Filosofia Ciências e Letras de Ribeirão Preto – USP, 2006.

HAGAN, M.T.; DEMUTH, H.B.; **Neural Network Design**. 1996. 734p.

IKUTA, K.; TSUKAMOTO, M.; HIROSE, S.; Mathematical Model and Experimental Verification of Shape Memory Alloy for Designing Micro Actuator, **Proceedings of the IEEE on Micro Electromechanical Systems, an Investigation of Microstructures, Sensors, Actuators, Machines, and Robots**, pp.103-108, 1991.

JANG, B.K.; KISHI, T.; Thermomechanical Response of TiNi Fiber-Impregnated CFRP Composites. **Materials Letters**, v. 59, pp. 2472 – 2475, 2005.

KOHL, M. **Shape Memory Microactuators**, Springer, 2010, 266p.

LAGOUDAS, D.; **Shape Memory Alloys (Modeling and Engineering Applications)**, Editora: Springer Science+Business Media, LLC, 2008.

LEE, H.J., LEE, J.J., KWON, D.S., YOON, Y.S.; Neural network based control of SMA actuator for the active catheter. **Int. J. Human-friendly Welfare Robotic Systems**, v. 2, p. 40-45, 2001.

LIMA, I.S.T.; **Projeto e Construção de uma Máquina de Fadiga para Fios com Memória de Forma**. Relatório de Atividades PIBIC/CNPq. Universidade Federal de Campina Grande, Campina Grande - PB, Brasil, 70p, 2004.

LUDWIG Jr, O.; COSTA, E.M.; **Redes Neurais: Fundamentos e Aplicações com programas em C**. Editora Ciência Moderna Ltda, 2007.

MA, H., CHO, C., WILKINSON, T. A Numerical Study on Bolted End-Plate Connection Using Shape Memory Alloys, **Materials and Structures**, v. 41, p.1419–1426, 2008.

MECÂNICA ATUAL, **Redes Neurais Artificiais** – Parte 2. Disponível em [www.mecanicaatual.com.br](http://www.mecanicaatual.com.br). Acesso em 27/05/2011.

NASCIMENTO, M.M.S.F.; DE ARAÚJO, C.J.; ALMEIDA, L.A.L.; ROCHA NETO, J.S.; LIMA, A.M.N. A mathematical model for the strain–temperature hysteresis of shape memory alloy actuators. **Materials & Design**, Vol. 30, Issue 3, pp. 551-556, 2009.

NASCIMENTO NETO, M.P., **Concepção e Desenvolvimento de uma Máquina Multifuncional para Testes Eletro-Termo-Mecânicos de Materiais com Memória de Forma**. 2007. 65f. Dissertação (Mestrado em Ciências e Engenharia de Materiais), Centro de Ciências e Tecnologia. Universidade Federal de Campina Grande, Campina Grande.

OTSUKA, K.; WAYMAN, C.M.; 1998, **Shape Memory Materials**. Cambridge, UK: Cambridge University Press.

PAINE, J.S.N.; ROGERS, C.A.; The Effect of Thermoplastic Composite Processing on The Performance of Embedded Nitinol Actuators. **Journal of Thermoplastic Composite Materials**, v. 4, p.102 – 122, 1991.

RAUBER, T.W., **Redes Neurais Artificiais**. Disponível em <<http://www.cic.unb.br>> Acesso em 02 de junho de 2010.

RODRIGUES, L.F.A., De Araújo, C.J., **Comportamento Termomecânico de Ligas NiTi com Memória de Forma: Caracterização para Aplicação em**

**Compósitos Ativos.** V Congresso de Iniciação Científica da Universidade Federal de Campina Grande, 2008

ROJAS, R., **Neural Networks: A Systematic Introduction.** Springer-Verlag, Berlin, 1996. 453p.

SONG, G.; CHAUDHRY, V.; BATUR, C., Precision Tracking Control of Shape Memory Alloy Actuators Using Neural Networks and a Sliding-Mode Based Robust Controller. **Smart Materials and Structures**, v. 12, p. 223–231, 2003.

SUN, L.; HUANG, W.M.; DING, Z.; ZHAO, Y.; WANG, C.C.; PURNAWALI, H.; TANG, C. Stimulus-Responsive Shape Memory Materials: A Review, **Materials and Design**, v. 33, p. 577-640, 2012.

TAI, N.T; AHN, K.K.; A RBF Neural Network Sliding Mode Controller for SMA Actuator, **International Journal of Control, Automation, and Systems**. v. 8(6), pp. 1296-1305, 2010.

VIANA, J.G., **Melhoramento de uma Máquina Eletromecânica e uso do Programa Computacional Labview para Testes em Materiais com Efeito Memória de Forma.** Trabalho de Conclusão Curso (TCC) Unidade Acadêmica de Engenharia Mecânica (UFCG), Campina Grande-PB, 2008.

WILLIAMS, E., SHAW, G., ELAHINIA, M., Control of an Automotive Shape Memory Alloy Mirror Actuator, **Mechatronics**, v.20, p.527–534, 2010.

## APÊNDICES

### Apêndice A

A1. Parametros de treinamento e resultados para a simulação do banco de dados do fio de NiTi sob carregamento de 250 MPa

Quantidade de testes	Treinamento				Resultados			
	Algoritmo	Camada de Neurônios	Taxa de aprendizado	Número de iterações	Tempo (s)	Performance	Gradiente	Regressão Linear
1	traingd	1	0,0015	5000	101	36,0000	0,1975	0,84993
2	traingd	2	0,0015	5000	106	1,8600	0,2580	0,99277
3	traingd	3	0,0015	5000	108	0,3010	0,1510	0,99884
4	traingd	4	0,0015	5000	106	0,2980	0,1150	0,99885
5	traingd	5	0,0015	5000	113	0,1390	0,0490	0,99946
6	traingd	6	0,0015	5000	109	0,1330	0,0550	0,99949
7	traingd	7	0,0015	5000	109	0,2690	0,0934	0,99896
8	traingd	8	0,0015	5000	106	0,1030	0,0503	0,99960
9	traingd	9	0,0015	5000	109	0,0993	0,0381	0,99962
10	traingd	10	0,0015	5000	108	0,0578	0,0455	0,99978
11	traingd	11	0,0015	5000	108	0,1030	0,0651	0,99960
12	traingd	12	0,0015	5000	110	0,0900	0,0799	0,99965
13	traingd	13	0,0015	5000	109	0,0506	0,0515	0,99980
14	traingd	14	0,0015	5000	110	0,0480	0,0302	0,99981
15	traingd	14	0,0015	5000	113	0,0967	0,0316	0,99963
16	traingd	14	0,0015	5000	111	0,0459	0,0384	0,99982
17	traingd	14	0,0015	5000	111	0,0466	0,0336	0,99982
18	traingd	15	0,0015	5000	113	0,0585	0,0520	0,99977
19	traingd	15	0,0015	5000	110	0,0449	0,0308	0,99983
20	traingd	15	0,0015	5000	116	0,0515	0,0422	0,99980

21	traingd	15	0,0015	5000	111	0,0498	0,0348	0,99981
22	traingd	15	0,0016	5000	112	0,0456	0,0380	0,99982
23	traingd	15	0,0017	290	7	Desestabilizou		
24	traingd	16	0,0015	5000	112	0,0289	0,0256	0,99989
25	traingd	16	0,0015	5000	109	0,0318	0,0455	0,99988
26	traingd	16	0,0015	5000	116	0,0264	0,0269	0,99990
<b>27</b>	<b>traingd</b>	<b>16</b>	<b>0,0015</b>	<b>5000</b>	<b>115</b>	<b>0,0239</b>	<b>0,0310</b>	<b>0,99991</b>
28	traingd	16	0,0016	316	8	Desestabilizou		
29	traingd	17	0,0015	328	7	Desestabilizou		
32	traingd	17	0,0013	5000	111	0,0671	0,0589	0,99974
33	traingd	17	0,0010	5000	113	0,0684	0,0687	0,99974
34	traingd	18	0,0015	266	6	Desestabilizou		
35	traingd	18	0,0015	268	6	Desestabilizou		

A2. Parametros de treinamento e resultados para a simulação do banco de dados do fio de NiTi sob carregamento de 250 MPa

Quantidade de testes	Treinamento				Resultados			
	Algoritmo	Camada de Neurônios	Taxa de aprendizado	Número de iterações	Tempo (s)	Performace	Gradiente	Regressão Linear
1	traingdm	1	0,0015	5000	113	31,8000	0,2150	0,85635
2	traingdm	2	0,0015	5000	114	1,8500	0,2530	0,99262
3	traingdm	3	0,0015	5000	114	1,9300	0,1950	0,99212
4	traingdm	4	0,0015	5000	116	0,3770	0,2840	0,99854
5	traingdm	5	0,0015	5000	115	0,2120	0,0619	0,99919
6	traingdm	6	0,0015	5000	118	0,1270	0,0249	0,99950
7	traingdm	7	0,0015	5000	116	0,1760	0,0387	0,99934
8	traingdm	8	0,0015	5000	115	0,1240	0,0761	0,99952
9	traingdm	9	0,0015	5000	116	0,1260	0,0495	0,99952
10	traingdm	10	0,0015	5000	117	0,0570	0,0488	0,99978
11	traingdm	10	0,0023	5000	115	0,0671	0,0394	0,99974
12	traingdm	10	0,0023	5000	115	0,0481	0,0324	0,99982



13	traingdm	10	0,0024	316	7	Desestabilizou		
14	traingdm	11	0,0015	5000	131	0,0602	0,0528	0,99977
15	traingdm	12	0,0015	5000	119	0,1000	0,0873	0,99963
16	traingdm	13	0,0015	5000	116	0,0599	0,0577	0,99977
17	traingdm	14	0,0015	5000	114	0,0666	0,0465	0,99974
18	traingdm	15	0,0015	5000	115	0,0302	0,0376	0,99988
19	traingdm	15	0,0016	5000	116	0,0555	0,0333	0,99978
20	traingdm	15	0,0016	5000	117	0,0371	0,0378	0,99985
21	traingdm	15	0,0017	5000	6	Desestabilizou		
22	traingdm	16	0,0015	5000	116	0,0894	0,0598	0,99966
23	traingdm	16	0,0015	5000	116	0,0253	0,0248	0,99990
24	traingdm	16	0,0015	5000	113	0,0304	0,0335	0,99988
25	traingdm	16	0,0016	301	7	Desestabilizou		
26	traingdm	17	0,0015	5000	116	0,0584	0,0439	0,99978
27	traingdm	17	0,0015	5000	117	0,0511	0,0466	0,99981
28	traingdm	18	0,0015	5000	116	0,0283	0,0381	0,99989
<b>29</b>	<b>traingdm</b>	<b>18</b>	<b>0,0015</b>	<b>5000</b>	<b>118</b>	<b>0,0262</b>	<b>0,0335</b>	<b>0,99989</b>
30	traingdm	18	0,0015	5000	116	0,0360	0,0444	0,99987
31	traingdm	19	0,0015	5000	117	0,0427	0,0485	0,99984
32	traingdm	19	0,0015	5000	116	0,0467	0,0514	0,99982
33	traingdm	20	0,0015	5000	117	0,0331	0,0389	0,99987
34	traingdm	20	0,0015	5000	117	0,0388	0,0417	0,99986
35	traingdm	21	0,0015	5000	117	0,0342	0,0293	0,99986
36	traingdm	21	0,0015	5000	118	0,0462	0,0470	0,99983
37	traingdm	22	0,0015	5000	117	0,0273	0,0294	0,99989
38	traingdm	22	0,0015	5000	118	0,0357	0,0427	0,99986
39	traingdm	23	0,0015	5000	116	0,0299	0,0391	0,99988
40	traingdm	23	0,0015	6	1	Desestabilizou		
41	traingdm	23	0,0014	5000	116	0,0401	0,0406	0,99984
42	traingdm	24	0,0015	6	1	Desestabilizou		
43	traingdm	24	0,0014	5000	119	0,0385	0,0664	0,99985
44	traingdm	25	0,0014	11	1	Desestabilizou		
45	traingdm	25	0,0014	5000	112	0,0383	0,0394	0,99986

46	traingdm	25	0,0014	6	1	Desestabilizou		
47	traingdm	25	0,0013	5000	109	0,0399	0,0623	0,99983

A3. Parametros de treinamento e resultados para a simulação do banco de dados do fio de NiTi sob carregamento de 250 MPa

Quantidade de testes	Treinamento				Resultados			
	Algoritmo	Camada de Neurônios	Taxa de aprendizado	Número de iterações	Tempo (s)	Performance	Gradiente	Regressão Linear
1	traingda	1	0,05 - 1,0	23	1	36,4000	2,0300	0,84922
2	traingda	2	0,05 - 1,0	1000	22	2,3600	0,4220	0,99087
3	traingda	3	0,05 - 1,0	1000	21	0,6360	0,4310	0,99761
4	traingda	4	0,05 - 1,0	1000	21	0,5010	0,2990	0,99809
5	traingda	5	0,05 - 1,0	1000	22	0,2120	0,1140	0,99920
6	traingda	6	0,05 - 1,0	1000	22	0,1720	0,1390	0,99935
7	traingda	7	0,05 - 1,0	1000	22	0,2410	0,2050	0,99906
8	traingda	8	0,05 - 1,0	1000	24	0,1480	0,1720	0,99942
9	traingda	9	0,05 - 1,0	1000	22	0,1560	0,1680	0,99937
10	traingda	10	0,05 - 1,0	1000	21	0,0820	0,1280	0,99969
11	traingda	11	0,05 - 1,0	1000	22	0,1480	0,1830	0,99943
12	traingda	12	0,05 - 1,0	1000	22	0,1670	0,2860	0,99929
13	traingda	13	0,05 - 1,0	1000	22	0,1750	0,3170	0,99930
14	traingda	14	0,05 - 1,0	1000	23	0,1670	0,2310	0,99935
15	traingda	15	0,05 - 1,0	1000	22	0,0942	0,2350	0,99966
16	traingda	16	0,05 - 1,0	1000	22	0,1620	0,2280	0,99936
17	traingda	17	0,05 - 1,0	1000	23	0,1370	0,3300	0,99948
18	traingda	18	0,05 - 1,0	1000	23	0,1040	0,3340	0,99960
19	traingda	19	0,05 - 1,0	1000	22	0,1130	0,2530	0,99954
20	traingda	20	0,05 - 1,0	1000	22	0,0912	0,3260	0,99966
21	traingda	21	0,05 - 1,0	1000	22	0,2610	0,5730	0,99904
22	traingda	22	0,05 - 1,0	1000	22	0,1510	0,4690	0,99941
23	traingda	23	0,05 - 1,0	1000	22	0,0977	0,3020	0,99961

24	traingda	24	0,05 - 1,0	1000	22	0,1880	0,8220	0,99928
25	traingda	25	0,05 - 1,0	1000	22	0,4210	1,1200	0,99833

A4. Parametros de treinamento e resultados para a simulação do banco de dados do fio de NiTi sob carregamento de 250 MPa

Quantidade de testes	Treinamento				Resultados			
	Algoritmo	Camada de Neurônios	Taxa de aprendizado	Número de iterações	Tempo (s)	Performance	Gradiente	Regressão Linear
1	trainrp	1	-	33	1	38,6000	1,5400	0,84569
2	trainrp	2	-	30	1	2,7900	3,0300	0,99108
3	trainrp	3	-	45	2	1,6700	1,1900	0,99399
4	trainrp	4	-	103	3	1,5900	1,4300	0,99371
5	trainrp	4	-	25	1	2,4000	1,5900	0,99216
6	trainrp	5	-	144	4	0,1630	0,3740	0,99938
7	trainrp	5	-	72	2	0,1220	0,0847	0,99951
8	trainrp	5	-	88	2	0,1610	0,2720	0,99940
9	trainrp	5	-	135	4	1,0800	1,0900	0,99583
10	trainrp	6	-	65	2	0,2800	0,5420	0,99890
11	trainrp	7	-	38	1	1,3800	2,5700	0,99679
12	trainrp	8	-	50	2	1,3100	0,9970	0,99539
13	trainrp	9	-	80	2	0,2580	0,7060	0,99908
14	trainrp	10	-	38	1	0,3360	1,3800	0,99892
15	trainrp	11	-	72	2	0,7150	2,1200	0,99732
16	trainrp	12	-	68	2	0,2120	1,1300	0,99926
17	trainrp	13	-	81	2	0,2300	0,8480	0,99914
18	trainrp	14	-	90	3	0,3840	1,2500	0,99857
19	trainrp	15	-	224	6	0,1420	0,4180	0,99940
20	trainrp	16	-	57	2	1,0700	3,8300	0,99656
21	trainrp	17	-	90	3	0,7550	3,4500	0,99745
22	trainrp	18	-	195	5	0,2770	1,2600	0,99896

23	trainrp	19	-	107	3	0,3800	1,3200	0,99854
24	trainrp	20	-	74	2	0,3870	1,6800	0,99864
25	trainrp	21	-	190	5	0,6200	2,7200	0,99778
26	trainrp	22	-	70	2	1,0400	3,5100	0,99623
27	trainrp	23	-	55	2	1,2100	4,1400	0,99610
28	trainrp	24	-	96	3	0,9480	3,0600	0,99652
29	trainrp	25	-	105	3	0,7590	3,1500	0,99741

A5. Parametros de treinamento e resultados para a simulação do banco de dados do fio de NiTi sob carregamento de 250 MPa

Quantidade de testes	Treinamento				Resultados					
	Algoritmo	Camada de Neurônios	Taxa de aprendizado	Número de iterações	Tempo (s)	Performance	Gradiente	Regressão Linear treinamento	Regressão Linear Teste	
1	traincgf	1	-	9	1	38,4000	4,4600	0,78389	0,83284	
2	traincgf	2	-	46	2	2,0500	0,4160	0,22221	0,99128	
3	traincgf	3	-	11	1	16,3000	13,1000	0,06786	0,91879	
4	traincgf	4	-	53	3	0,7040	2,3600	0,37692	0,99753	
5	traincgf	5	-	21	2	0,2600	1,1000	0,40131	0,99907	
6	traincgf	6	-	32	2	0,1640	0,3510	0,05990	0,99938	
7	traincgf	7	-	31	2	0,2270	0,3400	0,52728	0,99878	
8	traincgf	8	-	31	2	0,2460	0,9540	0,69375	0,99898	
9	traincgf	9	-	48	4	0,1050	0,4850	0,01461	0,99940	
10	traincgf	10	-	56	3	0,0968	2,3300	0,60689	0,99955	
11	traincgf	11	-	93	4	0,0869	0,1950	0,66693	0,99941	
12	traincgf	12	-	35	2	0,2410	1,2200	0,06500	0,99906	
13	traincgf	13	-	117	6	0,0496	0,3620	0,59696	0,99975	
14	traincgf	13	-	85	4	0,0635	0,3600	0,34387	0,99953	
15	traincgf	13	-	56	3	0,0774	0,3920	0,05191	0,99949	
16	traincgf	13	-	39	2	0,2190	2,7800	0,00530	0,99912	
17	traincgf	14	-	37	2	0,2150	1,4900	0,34935	0,99861	
18	traincgf	14	-	28	2	0,3120	1,4500	0,59110	0,99777	
19	traincgf	14	-	26	2	0,2280	1,7900	0,76654	0,99868	

20	traincgf	15	-	132	6	0,0524	0,0793	0,25813	0,99961
21	traincgf	15	-	31	2	0,1920	2,0500	0,80114	0,99866
22	traincgf	15	-	28	2	0,2060	2,1000	0,38674	0,99742
23	traincgf	16	-	61	3	0,0785	0,1620	0,31950	0,99892
24	traincgf	16	-	41	2	0,2190	1,1500	0,45651	0,99202
25	traincgf	17	-	79	4	0,0767	0,1880	0,65902	0,99939
26	traincgf	17	-	55	3	0,0671	0,5120	0,73878	0,99954
27	traincgf	17	-	59	3	0,0619	0,3200	0,32173	0,99961
28	traincgf	17	-	74	4	0,0672	0,3030	0,20888	0,99956
29	traincgf	18	-	66	3	0,0397	0,6990	0,00401	0,99965
30	traincgf	18	-	42	2	0,0997	1,8900	0,34798	0,99913
31	traincgf	18	-	156	6	0,0173	0,0502	0,01502	0,99939
<b>32</b>	<b>traincgf</b>	<b>18</b>	<b>-</b>	<b>158</b>	<b>6</b>	<b>0,0210</b>	<b>0,0792</b>	<b>0,27171</b>	<b>0,99980</b>
33	traincgf	19	-	60	3	0,0681	0,4820	0,61012	0,99887
34	traincgf	19	-	88	4	0,0295	0,1260	0,69865	0,99967
35	traincgf	19	-	52	3	0,0693	0,4180	0,25259	0,99912
36	traincgf	19	-	69	3	0,0671	0,9140	0,53728	0,99261
37	traincgf	20	-	94	4	0,0269	0,1070	0,29260	0,99966
38	traincgf	20	-	100	4	0,0459	0,3590	0,07753	0,99813
39	traincgf	21	-	120	5	0,0453	0,8420	0,88456	0,99933
40	traincgf	22	-	62	3	0,1140	1,7900	0,45191	0,99867
41	traincgf	23	-	66	3	0,0470	0,2630	0,57448	0,99955
42	traincgf	24	-	150	6	0,0269	0,1800	0,79109	0,99954
43	traincgf	25	-	46	2	0,2350	1,9100	0,29443	0,99742

A6. Parametros de treinamento e resultados para a simulação do banco de dados do fio de NiTi sob carregamento de 250 MPa

Quantidade de testes	Treinamento				Resultados				
	Algoritmo	Camada escondida	Taxa de aprendizado	Número de iterações	Tempo (s)	Performance	Gradiente	Regressão Linear treinamento	Regressão Linear Teste
1	trainlm	1	-	88	5	37,3000	0,0000	0,85223	0,81553
2	trainlm	2	-	11	1	1,4800	0,0005	0,99426	0,99537
3	trainlm	3	-	27	2	1,4500	0,0018	0,99470	0,99553

4	trainlm	4	-	22	1	0,0969	0,0000	0,99961	0,99931
5	trainlm	5	-	45	2	0,0300	0,0179	0,99990	0,99964
6	trainlm	6	-	31	2	0,0828	0,0162	0,99969	0,99953
7	trainlm	7	-	11	1	0,1970	2,1000	0,99941	0,99917
8	trainlm	8	-	65	3	0,0380	0,0984	0,99986	0,99974
9	trainlm	9	-	11	1	0,0526	0,0605	0,99984	0,99962
10	trainlm	10	-	54	2	0,0201	0,0145	0,99993	0,99979
11	trainlm	10	-	9	1	0,0922	0,0780	0,99994	0,99992
12	trainlm	10	-	59	3	0,0045	0,0170	0,99998	0,99972
13	trainlm	10	-	42	2	0,0210	0,0243	0,99992	0,99993
14	trainlm	11	-	13	1	0,0319	0,2130	0,99989	0,99920
15	trainlm	11	-	11	1	0,0502	0,3480	0,99994	0,99955
16	trainlm	11	-	19	1	0,0312	0,2780	0,99989	0,99990
17	trainlm	11	-	19	1	0,0171	0,0766	0,99995	0,99985
18	trainlm	12	-	68	3	0,0118	0,0041	0,99995	0,99978
19	trainlm	12	-	61	3	0,0119	0,0151	0,99995	0,99979
20	trainlm	12	-	10	1	0,1010	0,4180	0,99976	0,99964
21	trainlm	12	-	27	2	0,0282	0,0601	0,99990	0,99995
22	trainlm	13	-	60	3	0,0085	0,0304	0,99997	0,99992
23	trainlm	13	-	13	1	0,0251	0,0174	0,99992	0,99985
24	trainlm	13	-	81	4	0,0024	0,0036	0,99999	0,99980
25	trainlm	13	-	11	1	0,0290	0,4900	0,99993	0,99983
26	trainlm	14	-	17	1	0,0198	0,0399	0,99993	0,99979
27	trainlm	14	-	18	1	0,0182	0,0409	0,99995	0,99996
28	trainlm	14	-	68	3	0,0159	0,0070	0,99994	0,99985
29	trainlm	14	-	21	1	0,0095	0,1210	0,99997	0,99991
30	trainlm	15	-	10	1	0,0193	0,0089	0,99994	0,99989
31	trainlm	15	-	16	1	0,0197	0,0662	0,99993	0,99994
32	trainlm	15	-	19	1	0,0184	0,1730	0,99993	0,99995
<b>33</b>	<b>trainlm</b>	<b>15</b>	<b>-</b>	<b>25</b>	<b>2</b>	<b>0,0083</b>	<b>0,0016</b>	<b>0,99997</b>	<b>0,99996</b>
34	trainlm	16	-	83	4	0,0033	0,0063	0,99999	0,99979
35	trainlm	16	-	25	2	0,0158	0,0115	0,99994	0,99996
36	trainlm	16	-	38	2	0,0129	0,0228	0,99995	0,99975

37	trainlm	16	-	10	1	0,0191	0,0928	0,99997	0,99991
38	trainlm	17	-	88	4	0,0070	0,1110	0,99997	0,99975
39	trainlm	17	-	34	2	0,0045	0,0060	0,99998	0,99993
40	trainlm	17	-	14	1	0,0185	0,1030	0,99996	0,99986
41	trainlm	17	-	8	1	0,1530	0,1090	0,99997	0,99924
42	trainlm	18	-	22	1	0,0075	0,0094	0,99997	0,99990
43	trainlm	18	-	17	1	0,0069	0,0105	0,99998	0,99992
44	trainlm	18	-	7	1	0,0729	0,4890	0,99996	0,99945
45	trainlm	18	-	9	1	0,0172	0,4670	0,99995	0,99991
46	trainlm	19	-	21	2	0,0098	0,0093	0,99996	0,99964
47	trainlm	19	-	15	1	0,0126	0,0115	0,99996	0,99991
48	trainlm	19	-	14	1	0,0177	0,7630	0,99995	0,99985
49	trainlm	19	-	18	1	0,0070	0,0030	0,99997	0,99970
50	trainlm	20	-	15	1	0,0028	0,0367	0,99999	0,99973
51	trainlm	20	-	15	1	0,0041	0,0526	0,99999	0,99964
52	trainlm	20	-	9	1	0,0672	0,0334	0,99996	0,99959
53	trainlm	20	-	17	1	0,0037	0,0224	0,99999	0,99955
54	trainlm	21	-	9	1	0,0692	0,1660	0,99997	0,99974
55	trainlm	21	-	24	2	0,0051	0,1430	0,99998	0,99984
56	trainlm	21	-	15	1	0,0044	0,0081	0,99998	0,99924
57	trainlm	21	-	13	1	0,0150	0,4090	0,99998	0,99977
58	trainlm	22	-	13	1	0,0024	0,0134	0,99999	0,99981
59	trainlm	22	-	9	1	0,0170	0,0402	0,99997	0,99982
60	trainlm	22	-	15	1	0,0101	0,3480	0,99998	0,99993
61	trainlm	22	-	10	1	0,0286	0,0182	0,99995	0,99970
62	trainlm	23	-	23	2	0,0071	0,0685	0,99997	0,99984
63	trainlm	23	-	7	1	0,2030	0,1510	0,99998	0,99729
64	trainlm	23	-	12	1	0,0129	0,1410	0,99998	0,99935
65	trainlm	23	-	19	1	0,0084	0,0068	0,99997	0,99993
66	trainlm	24	-	52	3	0,0038	0,0211	0,99999	0,99952
67	trainlm	24	-	46	2	0,0020	0,0010	0,99999	0,99775
68	trainlm	24	-	9	1	0,0422	0,1780	0,99997	0,99967
69	trainlm	24	-	15	1	0,0020	0,0197	0,99999	0,99957

70	trainlm	25	-	10	1	0,0088	0,1710	0,99999	0,99978
71	trainlm	25	-	13	3	0,0064	0,2230	0,99999	0,99974
72	trainlm	25	-	7	1	0,2940	0,0010	0,99997	0,99135
73	trainlm	25	-	9	1	0,0080	0,0370	0,99998	0,99984

## Apêndice B

B1. Parâmetros de treinamento e resultados para a simulação de um banco de dados do fio de NiTi

Quantidade de testes	Treinamento		Simulação
	Algoritmo	Camada de Neurônios	BD 200
1	trainlm	1	62,78
2	trainlm	2	60,92
3	trainlm	3	54,87
4	trainlm	4	59,56
5	trainlm	5	48,14
6	trainlm	6	36,55
7	trainlm	7	11,77
8	trainlm	8	41,16
9	trainlm	9	41,36
10	trainlm	10	28,67
11	trainlm	11	10,20
12	trainlm	12	1,87
13	trainlm	13	1,18
14	trainlm	14	1,02
15	trainlm	15	1,22
16	trainlm	16	0,88



17	trainlm	17	0,94
18	trainlm	18	0,78
19	trainlm	19	0,61
20	trainlm	20	0,64
21	trainlm	21	1,15
<b>22</b>	<b>trainlm</b>	<b>22</b>	<b>0,54</b>
23	trainlm	23	0,76
24	trainlm	24	0,71
25	trainlm	25	0,63

B2. Parâmetros de treinamento e resultados para a simulação de um banco de dados do fio de NiTi

Quantidade de testes	Treinamento		Simulação
	Algoritmo	Camada de Neurônios	BD 200
1	trainlm	1	55,02
2	trainlm	2	53,24
3	trainlm	3	45,73
4	trainlm	4	48,19
5	trainlm	5	37,82
6	trainlm	6	31,48
7	trainlm	7	15,40
8	trainlm	8	9,91
9	trainlm	9	10,62
10	trainlm	10	7,36
11	trainlm	11	1,22
12	trainlm	12	6,30
13	trainlm	13	1,05
14	trainlm	14	0,97
15	trainlm	15	0,89

16	trainlm	16	0,83
17	trainlm	17	0,80
18	trainlm	18	0,68
19	trainlm	19	0,67
20	trainlm	20	0,84
21	trainlm	21	0,61
22	trainlm	22	0,81
23	trainlm	23	0,55
<b>24</b>	<b>trainlm</b>	<b>24</b>	<b>0,46</b>
25	trainlm	25	0,63

### Apêndice C

C1. Parâmetros de treinamento e resultados para a simulação de um banco de dados do fio de NiTi a partir de outros dois (BCE)

Quantidade de testes	Treinamento Algoritmo	Camada de Neurônios	Simulação		
			BD 150	BD 250	BD 200
1	trainlm	1	18,34	26,71	22,39
<b>2</b>	<b>trainlm</b>	<b>2</b>	<b>9,50</b>	<b>8,08</b>	<b>3,98</b>
3	trainlm	3	2,57	3,18	7,04
4	trainlm	4	1,62	1,52	6,74
5	trainlm	5	1,83	2,62	13,00
6	trainlm	6	1,70	1,19	28,08
7	trainlm	7	1,68	0,73	61,03
8	trainlm	8	4,10	1,83	86,13
9	trainlm	9	0,95	1,29	89,76
10	trainlm	10	1,31	1,43	103,37

11	trainlm	11	1,06	1,68	66,22
12	trainlm	12	0,93	0,67	97,92
13	trainlm	13	3,09	2,12	41,41
14	trainlm	14	1,36	0,46	96,70
15	trainlm	15	0,56	0,65	45,88
16	trainlm	16	11,02	0,74	40,08
17	trainlm	17	1,20	1,19	94,14
18	trainlm	18	1,07	0,60	91,46
19	trainlm	19	1,38	0,96	80,17
20	trainlm	20	1,28	1,97	131,23
21	trainlm	21	0,83	1,94	110,26
22	trainlm	22	3,75	1,46	82,85
23	trainlm	23	0,78	4,25	104,55
24	trainlm	24	0,88	0,89	68,13
25	trainlm	25	1,54	1,22	97,92

C2. Parâmetros de treinamento e resultados para a simulação de um banco de dados do fio de NiTi a partir de outros dois (BCE)

Quantidade de testes	Treinamento		Simulação		
	Algoritmo	Camada de Neurônios	BD 100	BD 200	BD 150
1	trainlm	1	17,24	24,30	18,88
<b>2</b>	<b>trainlm</b>	<b>2</b>	<b>13,96</b>	<b>9,42</b>	<b>5,70</b>
3	trainlm	3	7,21	5,10	9,43
4	trainlm	4	2,28	1,95	7,38
5	trainlm	5	0,53	1,48	24,60
6	trainlm	6	2,08	3,96	31,54
7	trainlm	7	0,90	1,33	36,38
8	trainlm	8	0,55	1,32	73,88
9	trainlm	9	0,51	1,29	68,21

10	trainlm	10	0,49	0,88	178,88
11	trainlm	11	1,33	1,12	104,30
12	trainlm	12	1,13	1,18	84,98
13	trainlm	13	0,48	1,06	77,26
14	trainlm	14	0,44	0,67	98,64
15	trainlm	15	0,66	1,37	103,17
16	trainlm	16	0,47	1,96	124,47
17	trainlm	17	2,47	1,16	84,23
18	trainlm	18	1,38	2,61	51,30
19	trainlm	19	0,53	1,61	77,16
20	trainlm	20	0,47	1,46	106,92
21	trainlm	21	0,88	1,89	60,39
22	trainlm	22	3,26	0,54	104,29
23	trainlm	23	1,53	1,09	100,07
24	trainlm	24	1,08	0,74	110,04
25	trainlm	25	0,36	0,86	101,48

C3. Parâmetros de treinamento e resultados para a simulação de um banco de dados do fio de NiTi a partir de outros dois (BCE)

Quantidade de testes	Treinamento		Simulação		
	Algoritmo	Camada de Neurônios	BD 50	BD 150	BD 100
1	trainlm	1	31,89	30,13	37,01
2	trainlm	2	20,19	5,24	32,20
3	trainlm	3	8,26	10,72	29,15
4	trainlm	4	2,10	1,30	31,79
<b>5</b>	<b>trainlm</b>	<b>5</b>	<b>14,85</b>	<b>7,95</b>	<b>24,30</b>
6	trainlm	6	1,76	0,53	45,77
7	trainlm	7	1,42	1,09	55,74
8	trainlm	8	11,46	4,69	55,24

9	trainlm	9	0,97	0,85	38,00
10	trainlm	10	2,87	5,01	38,67
11	trainlm	11	1,33	0,97	71,70
12	trainlm	12	2,04	2,93	49,30
13	trainlm	13	0,71	0,87	111,09
14	trainlm	14	1,54	0,73	51,62
15	trainlm	15	1,66	1,25	125,16
16	trainlm	16	1,53	0,60	40,33
17	trainlm	17	3,27	0,76	127,92
18	trainlm	18	1,34	0,99	41,22
19	trainlm	19	1,54	0,54	53,83
20	trainlm	20	1,43	0,51	119,13
21	trainlm	21	1,12	1,16	72,14
22	trainlm	22	1,45	0,83	65,10
23	trainlm	23	4,29	6,06	76,79
24	trainlm	24	0,99	0,74	119,26
25	trainlm	25	0,76	1,14	66,97

## Apêndice D

D1. Parâmetros de treinamento e resultados para a simulação de um banco de dados do fio de NiTi a partir de outros dois (BCE)

Quantidade de testes	Treinamento Algoritmo	Simulação				
		1a Camada de Neurônios	2a Camada de Neurônios	BD 150	BD 250	BD 200
1	trainlm	1	2	25,18	25,63	25,26
2	trainlm	2	2	10,17	11,04	9,85

3	trainlm	3	2	4,14	3,67	36,94
4	trainlm	4	2	2,29	1,63	73,16
5	trainlm	5	2	1,57	1,08	46,45
6	trainlm	6	2	4,20	1,79	9,14
7	trainlm	7	2	0,78	0,94	92,28
8	trainlm	8	2	1,50	1,41	120,54
9	trainlm	9	2	25,54	26,57	34,48
10	trainlm	10	2	1,10	0,93	22,82
11	trainlm	1	3	28,95	26,49	27,26
<b>12</b>	<b>trainlm</b>	<b>2</b>	<b>3</b>	<b>8,94</b>	<b>8,63</b>	<b>4,02</b>
13	trainlm	3	3	4,24	2,88	4,68
14	trainlm	4	3	3,83	3,02	13,37
15	trainlm	5	3	1,15	1,14	20,42
16	trainlm	6	3	0,91	1,29	127,58
17	trainlm	7	3	6,22	1,41	16,78
18	trainlm	8	3	0,94	1,03	78,27
19	trainlm	9	3	1,65	0,97	70,24
20	trainlm	10	3	1,05	1,11	65,54
21	trainlm	1	4	36,00	31,11	38,81
22	trainlm	2	4	19,02	15,65	24,27
23	trainlm	3	4	2,58	3,05	6,75
24	trainlm	4	4	1,07	1,26	24,00
25	trainlm	5	4	1,41	1,23	27,36
26	trainlm	6	4	1,73	1,54	17,81
27	trainlm	7	4	1,21	1,93	87,61
28	trainlm	8	4	2,66	2,44	50,20
29	trainlm	9	4	0,97	1,06	46,25
30	trainlm	10	4	1,40	1,62	117,45
31	trainlm	1	5	19,70	25,74	22,70
32	trainlm	2	5	13,05	7,12	6,94
33	trainlm	3	5	3,75	3,11	6,93
34	trainlm	4	5	9,50	1,43	7,79
35	trainlm	5	5	1,07	1,54	14,00

36	trainlm	6	5	2,06	1,18	39,82
37	trainlm	7	5	1,60	1,49	47,71
38	trainlm	8	5	2,65	1,68	41,15
39	trainlm	9	5	1,58	1,09	69,00
40	trainlm	10	5	1,63	0,91	43,82
41	trainlm	1	6	18,36	26,44	22,67
42	trainlm	2	6	20,62	25,11	23,06
43	trainlm	3	6	2,58	3,89	73,64
44	trainlm	4	6	2,64	1,64	59,67
45	trainlm	5	6	1,11	1,68	28,49
46	trainlm	6	6	1,13	1,97	191,12
47	trainlm	7	6	1,08	0,82	10,96
48	trainlm	8	6	1,97	3,63	22,04
49	trainlm	9	6	1,25	1,00	22,58
50	trainlm	10	6	0,86	0,52	69,86
51	trainlm	1	7	24,13	26,88	25,32
52	trainlm	2	7	22,73	12,90	25,10
53	trainlm	3	7	36,17	28,21	34,85
54	trainlm	4	7	3,22	3,83	46,62
55	trainlm	5	7	1,24	1,73	35,77
56	trainlm	6	7	2,10	1,07	55,90
57	trainlm	7	7	0,94	4,77	163,52
58	trainlm	8	7	2,70	1,43	113,07
59	trainlm	9	7	1,43	1,44	34,23
60	trainlm	10	7	1,48	6,10	84,60
61	trainlm	1	8	30,88	37,58	38,72
62	trainlm	2	8	11,67	8,26	6,31
63	trainlm	3	8	2,97	2,67	8,51
64	trainlm	4	8	2,97	2,67	17,68
65	trainlm	5	8	1,05	1,06	16,85
66	trainlm	6	8	1,31	1,51	52,83
67	trainlm	7	8	3,78	1,22	10,23
68	trainlm	8	8	2,90	2,38	65,25

69	trainlm	9	8	1,09	0,83	120,05
70	trainlm	10	8	1,07	1,16	125,43

D2. Parâmetros de treinamento e resultados para a simulação de um banco de dados do fio de NiTi a partir de outros dois (BCE)

Quantidade de testes	Algoritmo	Treinamento		Simulação		
		1a Camada de Neurônios	2a Camada de Neurônios	BD 100	BD 200	BD 150
1	trainlm	1	2	17,76	23,52	17,71
2	trainlm	2	2	12,49	10,81	5,42
3	trainlm	3	2	7,17	5,16	119,66
4	trainlm	4	2	1,27	1,29	37,11
5	trainlm	5	2	1,32	2,20	5,29
6	trainlm	6	2	1,16	1,24	21,69
7	trainlm	7	2	0,81	1,09	63,84
8	trainlm	8	2	2,82	2,68	83,91
9	trainlm	9	2	1,18	1,30	18,19
10	trainlm	10	2	0,56	1,12	75,04
11	trainlm	1	3	17,11	23,89	18,33
12	trainlm	2	3	11,91	11,42	8,39
13	trainlm	3	3	6,53	7,26	6,89
14	trainlm	4	3	1,47	1,12	28,30
15	trainlm	5	3	0,75	1,40	5,05
16	trainlm	6	3	0,51	0,87	32,95
17	trainlm	7	3	1,23	1,77	24,89
18	trainlm	8	3	1,38	1,78	33,25



19	trainlm	9	3	3,38	2,90	55,76
20	trainlm	10	3	0,40	1,08	111,25
21	trainlm	1	4	18,79	23,23	18,05
22	trainlm	2	4	15,47	9,98	6,41
23	trainlm	3	4	9,34	3,45	10,75
24	trainlm	4	4	1,02	1,12	58,05
25	trainlm	5	4	0,77	1,20	25,83
26	trainlm	6	4	0,79	1,42	40,39
27	trainlm	7	4	0,48	1,34	68,75
28	trainlm	8	4	0,85	1,39	89,99
29	trainlm	9	4	0,71	1,38	48,56
30	trainlm	10	4	0,86	1,86	153,80
31	trainlm	1	5	16,55	25,43	19,92
<b>32</b>	<b>trainlm</b>	<b>2</b>	<b>5</b>	<b>12,77</b>	<b>9,88</b>	<b>4,02</b>
33	trainlm	3	5	7,15	4,85	7,54
34	trainlm	4	5	7,92	4,07	6,57
35	trainlm	5	5	2,26	2,10	75,03
36	trainlm	6	5	0,75	1,19	77,14
37	trainlm	7	5	18,31	5,87	90,93
38	trainlm	8	5	0,73	1,34	28,24
39	trainlm	9	5	1,35	2,51	193,08
40	trainlm	10	5	0,75	1,17	159,94
41	trainlm	1	6	33,16	29,80	29,91
42	trainlm	2	6	11,28	11,71	5,90
43	trainlm	3	6	6,75	4,14	10,02
44	trainlm	4	6	4,62	2,70	23,88
45	trainlm	5	6	1,44	1,31	50,37
46	trainlm	6	6	0,68	1,05	53,18
47	trainlm	7	6	0,94	1,56	25,16
48	trainlm	8	6	4,80	3,45	17,50
49	trainlm	9	6	0,49	1,28	351,94
50	trainlm	10	6	5,60	4,89	75,50
51	trainlm	1	7	16,49	24,00	18,02

52	trainlm	2	7	15,06	8,91	4,85
53	trainlm	3	7	9,34	3,25	6,82
54	trainlm	4	7	19,57	13,23	54,60
55	trainlm	5	7	1,26	1,32	21,42
56	trainlm	6	7	0,76	1,15	27,60
57	trainlm	7	7	0,61	1,04	36,31
58	trainlm	8	7	0,91	3,52	109,49
59	trainlm	9	7	1,48	1,07	78,04
60	trainlm	10	7	2,23	2,10	133,05
61	trainlm	1	8	19,15	23,33	18,41
62	trainlm	2	8	10,54	11,97	6,12
63	trainlm	3	8	9,29	4,13	9,53
64	trainlm	4	8	2,14	2,40	14,98
65	trainlm	5	8	0,94	1,19	24,74
66	trainlm	6	8	0,62	1,14	79,10
67	trainlm	7	8	0,99	3,06	124,53
68	trainlm	8	8	2,51	1,34	14,56
69	trainlm	9	8	0,63	1,55	149,49
70	trainlm	10	8	0,85	1,57	89,64

D3. Parâmetros de treinamento e resultados para a simulação de um banco de dados do fio de NiTi a partir de outros dois (BCE)

Quantidade de testes	Algoritmo	Treinamento		Simulação		
		1a	2a	BD 50	BD 150	BD 100
		Camada de Neurônios	Camada de Neurônios			
1	trainlm	1	2	34,28	28,31	33,14
2	trainlm	2	2	36,19	25,83	27,74
3	trainlm	3	2	17,20	4,59	15,89
4	trainlm	4	2	11,95	7,37	29,78

5	trainlm	5	2	1,46	1,54	37,45
6	trainlm	6	2	0,83	0,98	28,31
7	trainlm	7	2	2,83	2,26	68,61
8	trainlm	8	2	1,92	3,66	67,46
9	trainlm	9	2	0,92	0,91	75,14
10	trainlm	10	2	3,54	1,75	130,81
11	trainlm	1	3	31,84	35,42	35,49
12	trainlm	2	3	19,35	7,88	30,73
13	trainlm	3	3	12,37	4,88	17,39
14	trainlm	4	3	10,51	3,28	33,58
15	trainlm	5	3	2,07	3,93	19,36
16	trainlm	6	3	1,43	1,07	31,69
17	trainlm	7	3	3,90	2,28	76,92
18	trainlm	8	3	1,40	3,90	90,51
19	trainlm	9	3	1,00	1,37	27,63
20	trainlm	10	3	2,08	1,25	56,39
21	trainlm	1	4	32,15	29,48	34,61
22	trainlm	2	4	22,65	18,00	30,12
23	trainlm	3	4	13,59	3,87	29,97
24	trainlm	4	4	29,52	2,35	86,91
25	trainlm	5	4	9,05	6,57	43,38
26	trainlm	6	4	8,29	9,69	37,63
27	trainlm	7	4	1,52	0,78	40,09
28	trainlm	8	4	1,55	0,80	70,25
29	trainlm	9	4	0,90	0,74	66,42
30	trainlm	10	4	0,85	0,88	113,90
31	trainlm	1	5	30,93	35,41	34,49
32	trainlm	2	5	20,57	5,56	30,26
33	trainlm	3	5	11,73	6,13	30,42
<b>34</b>	<b>trainlm</b>	<b>4</b>	<b>5</b>	<b>6,14</b>	<b>2,94</b>	<b>13,85</b>
35	trainlm	5	5	7,02	5,17	95,95
36	trainlm	6	5	2,56	1,07	22,93
37	trainlm	7	5	1,95	0,79	62,03

38	trainlm	8	5	1,84	1,35	159,21
39	trainlm	9	5	0,98	0,66	44,10
40	trainlm	10	5	1,62	0,97	192,28
41	trainlm	1	6	33,39	29,36	34,74
42	trainlm	2	6	20,78	19,16	19,90
43	trainlm	3	6	10,43	5,87	16,53
44	trainlm	4	6	12,22	7,47	54,76
45	trainlm	5	6	4,31	3,42	39,35
46	trainlm	6	6	2,75	1,33	59,52
47	trainlm	7	6	1,61	1,27	114,60
48	trainlm	8	6	16,57	6,91	136,99
49	trainlm	9	6	0,93	0,87	100,16
50	trainlm	10	6	0,96	0,77	71,41
51	trainlm	1	7	33,11	35,13	34,17
52	trainlm	2	7	32,38	29,72	41,18
53	trainlm	3	7	30,15	28,01	44,21
54	trainlm	4	7	10,92	6,41	35,65
55	trainlm	5	7	2,37	1,66	67,96
56	trainlm	6	7	2,03	1,99	77,79
57	trainlm	7	7	1,23	0,86	95,28
58	trainlm	8	7	1,23	2,30	36,03
59	trainlm	9	7	1,37	1,37	150,71
60	trainlm	10	7	1,30	1,15	122,94
61	trainlm	1	8	32,34	35,48	34,56
62	trainlm	2	8	16,97	35,27	42,14
63	trainlm	3	8	11,96	5,95	31,48
64	trainlm	4	8	39,06	30,58	45,43
65	trainlm	5	8	1,77	1,04	63,25
66	trainlm	6	8	2,32	1,37	65,31
67	trainlm	7	8	12,81	4,50	43,28
68	trainlm	8	8	1,01	0,98	149,02
69	trainlm	9	8	6,47	4,73	101,00
70	trainlm	10	8	1,47	2,54	56,81

## Apêndice E

E1. Parâmetros de treinamento e resultados para a simulação de um banco de dados do fio de NiTi a partir de outros dois (BCT)

Quantidade de testes	Treinamento		Simulação		
	Algoritmo	Camada de Neurônios	BD 150	BD 250	BD 200
1	trainlm	1	23,50	24,32	26,52
2	trainlm	2	8,10	6,46	8,14
<b>3</b>	<b>trainlm</b>	<b>3</b>	<b>4,28</b>	<b>3,73</b>	<b>8,13</b>
4	trainlm	4	1,93	2,60	10,99
5	trainlm	5	1,98	1,60	52,05
6	trainlm	6	2,43	2,34	17,40
7	trainlm	7	1,86	1,52	68,88
8	trainlm	8	1,84	1,27	69,21
9	trainlm	9	2,06	2,15	49,45
10	trainlm	10	1,53	1,28	74,22
11	trainlm	11	1,94	1,39	57,16
12	trainlm	12	1,68	1,67	40,31
13	trainlm	13	1,28	1,28	70,19
14	trainlm	14	1,65	1,25	116,89
15	trainlm	15	1,78	1,24	156,42
16	trainlm	16	1,68	1,20	44,45
17	trainlm	17	1,25	1,27	131,82
18	trainlm	18	1,60	1,31	129,42
19	trainlm	19	1,84	1,41	121,16
20	trainlm	20	1,61	1,25	105,29
21	trainlm	21	1,90	1,44	101,49
22	trainlm	22	1,52	1,11	112,38
23	trainlm	23	1,58	1,33	153,50

24	trainlm	24	1,77	1,28	137,36
25	trainlm	25	0,79	0,78	143,30

E2. Parâmetros de treinamento e resultados para a simulação de um banco de dados do fio de NiTi a partir de outros dois (BCT)

Quantidade de testes	Treinamento		Simulação		
	Algoritmo	Camada de Neurônios	BD 100	BD 200	BD 150
1	trainlm	1	28,93	26,74	26,25
2	trainlm	2	29,09	26,76	26,81
3	trainlm	3	6,48	4,18	17,26
<b>4</b>	<b>trainlm</b>	<b>4</b>	<b>2,90</b>	<b>2,09</b>	<b>13,19</b>
5	trainlm	5	2,55	2,18	35,24
6	trainlm	6	3,21	2,63	64,88
7	trainlm	7	2,26	2,09	65,59
8	trainlm	8	2,27	1,67	67,95
9	trainlm	9	2,47	1,54	80,11
10	trainlm	10	2,22	1,42	64,02
11	trainlm	11	0,99	1,12	85,95
12	trainlm	12	2,19	1,65	75,30
13	trainlm	13	1,92	1,68	52,16
14	trainlm	14	1,50	1,75	73,09
15	trainlm	15	1,68	1,45	141,59
16	trainlm	16	1,34	1,18	73,39
17	trainlm	17	1,78	1,37	76,95
18	trainlm	18	1,63	1,38	156,29
19	trainlm	19	1,42	1,14	96,66
20	trainlm	20	1,06	0,97	64,38
21	trainlm	21	1,17	1,18	130,16
22	trainlm	22	1,45	1,48	67,62

23	trainlm	23	1,68	1,36	102,90
24	trainlm	24	1,80	1,69	148,37
25	trainlm	25	1,62	1,57	95,80

E3. Parâmetros de treinamento e resultados para a simulação de um banco de dados do fio de NiTi a partir de outros dois (BCT)

Quantidade de testes	Treinamento		Simulação		
	Algoritmo	Camada de Neurônios	BD 50	BD 150	BD 100
1	trainlm	1	39,33	25,80	29,83
2	trainlm	2	23,91	23,33	37,63
3	trainlm	3	8,81	7,06	30,21
<b>4</b>	<b>trainlm</b>	<b>4</b>	<b>8,85</b>	<b>3,71</b>	<b>28,81</b>
5	trainlm	5	2,56	1,82	46,95
6	trainlm	6	1,57	1,65	44,10
7	trainlm	7	3,34	1,99	132,14
8	trainlm	8	2,31	1,89	58,56
9	trainlm	9	1,06	1,61	43,81
10	trainlm	10	1,40	1,73	105,96
11	trainlm	11	1,73	1,82	107,12
12	trainlm	12	1,19	1,78	101,39
13	trainlm	13	1,65	1,67	160,95
14	trainlm	14	0,96	1,49	112,41
15	trainlm	15	1,83	1,60	100,56
16	trainlm	16	0,45	1,55	130,89
17	trainlm	17	0,98	1,42	185,05
18	trainlm	18	1,77	1,63	188,94
19	trainlm	19	3,13	2,28	197,34
20	trainlm	20	0,72	0,38	139,35
21	trainlm	21	1,86	1,48	155,77

22	trainlm	22	0,78	1,47	188,12
23	trainlm	23	0,88	0,72	266,76
24	trainlm	24	1,01	0,81	189,22
25	trainlm	25	1,20	1,14	55,05

## Apêndice F

F1. Parâmetros de treinamento e resultados para a simulação de um banco de dados do fio de NiTi a partir de outros dois (BCT)

Quantidade de testes	Algoritmo	Treinamento		Simulação		
		1a Camada de Neurônios	2a Camada de Neurônios	BD 150	BD 250	BD 200
1	trainlm	1	2	23,44	23,78	26,63
2	trainlm	2	2	9,67	9,52	12,04
3	trainlm	3	2	4,19	3,75	11,74
4	trainlm	4	2	3,78	3,05	8,15
<b>5</b>	<b>trainlm</b>	<b>5</b>	<b>2</b>	<b>2,67</b>	<b>1,80</b>	<b>6,82</b>
6	trainlm	6	2	2,35	2,04	30,09
7	trainlm	7	2	1,87	1,68	61,64
8	trainlm	8	2	1,65	1,12	48,00
9	trainlm	9	2	1,74	1,41	63,67
10	trainlm	10	2	1,68	1,34	37,94
11	trainlm	1	3	24,12	23,47	27,34
12	trainlm	2	3	25,56	17,60	29,16
13	trainlm	3	3	4,10	3,71	8,60
14	trainlm	4	3	2,33	2,23	36,71
15	trainlm	5	3	1,97	1,88	42,77
16	trainlm	6	3	1,98	1,72	18,46



17	trainlm	7	3	1,76	1,68	58,57
18	trainlm	8	3	1,75	1,26	46,39
19	trainlm	9	3	1,80	1,22	35,64
20	trainlm	10	3	1,53	1,23	31,21
21	trainlm	1	4	53,87	51,19	61,85
22	trainlm	2	4	23,31	19,82	36,18
23	trainlm	3	4	4,12	3,65	8,73
24	trainlm	4	4	3,84	3,02	36,41
25	trainlm	5	4	2,57	2,01	11,37
26	trainlm	6	4	1,91	1,50	73,47
27	trainlm	7	4	1,96	1,34	51,78
28	trainlm	8	4	3,44	2,23	35,58
29	trainlm	9	4	1,44	1,30	69,85
30	trainlm	10	4	1,61	1,25	259,43
31	trainlm	1	5	23,75	23,59	26,77
32	trainlm	2	5	21,22	24,43	26,55
33	trainlm	3	5	4,66	3,60	8,37
34	trainlm	4	5	3,86	3,46	10,38
35	trainlm	5	5	1,93	1,72	9,57
36	trainlm	6	5	1,63	1,59	48,83
37	trainlm	7	5	1,95	1,51	40,56
38	trainlm	8	5	1,37	1,38	111,74
39	trainlm	9	5	0,95	1,19	36,42
40	trainlm	10	5	1,97	1,51	71,68
41	trainlm	1	6	23,37	23,84	23,84
42	trainlm	2	6	8,31	6,25	7,98
43	trainlm	3	6	3,82	4,08	8,19
44	trainlm	4	6	4,59	3,68	50,92
45	trainlm	5	6	1,48	2,13	59,15
46	trainlm	6	6	3,56	2,90	102,21
47	trainlm	7	6	2,40	1,62	55,64
48	trainlm	8	6	2,43	1,86	55,86
49	trainlm	9	6	6,92	2,33	198,27

50	trainlm	10	6	1,93	1,61	64,94
51	trainlm	1	7	23,96	23,53	27,10
52	trainlm	2	7	8,09	6,46	8,32
53	trainlm	3	7	4,17	3,76	12,18
54	trainlm	4	7	4,03	3,37	18,63
55	trainlm	5	7	1,59	1,74	28,35
56	trainlm	6	7	1,87	1,68	62,96
57	trainlm	7	7	1,99	1,45	53,39
58	trainlm	8	7	1,64	1,28	70,40
59	trainlm	9	7	1,45	1,30	69,79
60	trainlm	10	7	1,71	1,52	49,51
61	trainlm	1	8	23,27	24,22	26,47
62	trainlm	2	8	8,09	6,46	8,32
63	trainlm	3	8	4,17	3,76	12,18
64	trainlm	4	8	4,03	3,37	18,63
65	trainlm	5	8	1,59	1,74	28,35
66	trainlm	6	8	1,74	1,46	60,75
67	trainlm	7	8	1,99	1,45	53,39
68	trainlm	8	8	1,66	1,48	65,71
69	trainlm	9	8	1,79	1,40	37,41
70	trainlm	10	8	2,90	2,50	106,40

F2. Parâmetros de treinamento e resultados para a simulação de um banco de dados do fio de NiTi a partir de outros dois (BCT)

Quantidade de testes	Treinamento		Simulação			
	Algoritmo	1a	2a	BD 100	BD 200	BD 150
		Camada de Neurônios	Camada de Neurônios			
1	trainlm	1	2	28,94	26,82	26,55
2	trainlm	2	2	15,46	8,21	13,49

3	trainlm	3	2	23,44	25,88	34,59
4	trainlm	4	2	3,41	7,69	113,24
5	trainlm	5	2	3,22	2,12	12,12
6	trainlm	6	2	1,95	1,76	31,19
7	trainlm	7	2	2,64	1,50	41,26
8	trainlm	8	2	2,02	1,82	26,33
9	trainlm	9	2	1,23	1,47	213,01
10	trainlm	10	2	1,59	1,47	74,44
11	trainlm	1	3	62,76	56,25	65,58
12	trainlm	2	3	28,69	22,17	32,82
13	trainlm	3	3	34,27	17,26	42,39
14	trainlm	4	3	8,15	3,99	32,74
15	trainlm	5	3	1,69	1,48	76,88
16	trainlm	6	3	2,55	1,92	23,69
17	trainlm	7	3	1,55	1,71	69,41
18	trainlm	8	3	1,32	1,20	51,20
19	trainlm	9	3	2,63	1,81	57,14
20	trainlm	10	3	1,98	1,82	186,29
21	trainlm	1	4	62,37	56,29	56,72
22	trainlm	2	4	13,95	9,41	13,53
23	trainlm	3	4	7,22	4,89	55,59
24	trainlm	4	4	7,37	4,83	16,68
25	trainlm	5	4	2,84	2,06	41,90
26	trainlm	6	4	1,99	1,78	77,55
27	trainlm	7	4	3,03	2,70	27,98
28	trainlm	8	4	1,56	1,01	53,60
29	trainlm	9	4	2,68	1,83	88,25
30	trainlm	10	4	1,54	1,10	219,91
31	trainlm	1	5	29,38	26,53	26,25
32	trainlm	2	5	14,22	9,43	13,70
33	trainlm	3	5	21,04	19,89	46,54
<b>34</b>	<b>trainlm</b>	<b>4</b>	<b>5</b>	<b>8,80</b>	<b>6,02</b>	<b>11,02</b>
35	trainlm	5	5	1,70	1,90	32,50

36	trainlm	6	5	1,28	1,29	17,91
37	trainlm	7	5	1,78	1,71	42,72
38	trainlm	8	5	2,28	1,46	96,19
39	trainlm	9	5	2,70	1,78	243,18
40	trainlm	10	5	1,10	1,67	69,59
41	trainlm	1	6	62,34	56,41	67,26
42	trainlm	2	6	13,89	10,46	14,47
43	trainlm	3	6	8,46	11,23	62,65
44	trainlm	4	6	6,71	4,99	46,71
45	trainlm	5	6	1,74	1,95	63,44
46	trainlm	6	6	1,99	1,77	31,69
47	trainlm	7	6	2,66	1,52	62,07
48	trainlm	8	6	3,10	2,58	74,18
49	trainlm	9	6	1,48	1,30	110,12
50	trainlm	10	6	2,26	1,54	118,66
51	trainlm	1	7	62,40	56,25	62,20
52	trainlm	2	7	15,13	8,53	13,27
53	trainlm	3	7	17,49	26,30	406,49
54	trainlm	4	7	8,81	3,74	16,97
55	trainlm	5	7	1,96	1,74	44,93
56	trainlm	6	7	1,60	1,75	34,28
57	trainlm	7	7	2,51	1,80	93,73
58	trainlm	8	7	1,39	1,48	94,98
59	trainlm	9	7	1,32	1,83	90,67
60	trainlm	10	7	2,54	1,71	111,83
61	trainlm	1	8	29,37	26,53	26,07
62	trainlm	2	8	15,20	8,75	13,93
63	trainlm	3	8	11,57	9,80	18,49
64	trainlm	4	8	7,50	4,58	72,07
65	trainlm	5	8	3,08	2,08	38,54
66	trainlm	6	8	2,17	1,77	13,74
67	trainlm	7	8	2,49	1,71	95,42
68	trainlm	8	8	1,50	1,78	18,34

69	trainlm	9	8	1,83	2,15	159,06
70	trainlm	10	8	1,94	1,52	22,47

F3. Parâmetros de treinamento e resultados para a simulação de um banco de dados do fio de NiTi a partir de outros dois (BCT)

Quantidade de testes	Algoritmo	Treinamento		Simulação		
		1a Camada de Neurônios	2a Camada de Neurônios	BD 50	BD 150	BD 100
1	trainlm	1	2	34,29	28,22	28,25
2	trainlm	2	2	21,19	8,22	18,85
3	trainlm	3	2	14,41	3,60	19,29
4	trainlm	4	2	8,08	3,34	30,67
5	trainlm	5	2	2,81	1,89	139,40
6	trainlm	6	2	3,00	1,95	51,44
7	trainlm	7	2	2,50	1,47	94,24
8	trainlm	8	2	2,57	1,60	63,96
9	trainlm	9	2	0,93	1,32	74,19
10	trainlm	10	2	1,68	1,73	33,27
11	trainlm	1	3	40,45	25,73	29,53
12	trainlm	2	3	8,58	53,86	77,31
13	trainlm	3	3	18,29	7,97	148,46
14	trainlm	4	3	11,23	2,66	43,45
15	trainlm	5	3	2,14	1,82	35,56
16	trainlm	6	3	2,46	1,75	66,35
17	trainlm	7	3	2,03	1,61	142,67
18	trainlm	8	3	2,00	1,74	69,84
19	trainlm	9	3	1,90	0,90	91,57
20	trainlm	10	3	0,68	1,54	51,08
21	trainlm	1	4	38,92	25,89	29,40

22	trainlm	2	4	19,90	8,44	18,75
23	trainlm	3	4	12,59	4,51	20,38
24	trainlm	4	4	10,62	2,31	40,78
25	trainlm	5	4	7,80	2,94	60,69
26	trainlm	6	4	2,65	1,69	55,85
27	trainlm	7	4	4,84	2,47	42,08
28	trainlm	8	4	1,15	1,49	35,12
29	trainlm	9	4	1,18	1,38	163,76
30	trainlm	10	4	0,89	1,26	65,17
31	trainlm	1	5	35,12	26,93	29,50
<b>32</b>	<b>trainlm</b>	<b>2</b>	<b>5</b>	<b>19,93</b>	<b>8,41</b>	<b>18,52</b>
33	trainlm	3	5	13,37	2,98	19,52
34	trainlm	4	5	7,61	2,72	34,88
35	trainlm	5	5	3,13	1,90	49,95
36	trainlm	6	5	2,71	1,86	66,46
37	trainlm	7	5	2,63	1,45	157,10
38	trainlm	8	5	1,26	1,75	58,46
39	trainlm	9	5	1,21	1,84	37,30
40	trainlm	10	5	7,82	5,35	103,97
41	trainlm	1	6	40,73	25,70	29,74
42	trainlm	2	6	21,17	8,16	19,03
43	trainlm	3	6	22,09	8,85	37,37
44	trainlm	4	6	17,49	4,33	92,43
45	trainlm	5	6	7,35	3,49	39,08
46	trainlm	6	6	1,19	1,81	23,73
47	trainlm	7	6	1,89	1,60	107,49
48	trainlm	8	6	1,61	1,77	100,05
49	trainlm	9	6	1,34	1,66	84,19
50	trainlm	10	6	1,48	0,77	32,08
51	trainlm	1	7	38,78	25,94	29,64
52	trainlm	2	7	29,32	18,46	40,86
53	trainlm	3	7	20,67	4,26	87,08
54	trainlm	4	7	8,63	4,32	46,11

55	trainlm	5	7	2,86	2,20	61,81
56	trainlm	6	7	1,55	1,91	38,30
57	trainlm	7	7	2,15	1,88	45,33
58	trainlm	8	7	1,59	1,85	112,14
59	trainlm	9	7	2,34	1,84	39,56
60	trainlm	10	7	1,55	1,51	268,22
61	trainlm	1	8	39,42	25,71	29,81
62	trainlm	2	8	33,37	22,41	134,69
63	trainlm	3	8	13,16	4,15	19,07
64	trainlm	4	8	9,33	2,34	25,59
65	trainlm	5	8	4,82	2,23	53,38
66	trainlm	6	8	3,09	1,86	67,79
67	trainlm	7	8	2,16	1,81	152,09
68	trainlm	8	8	1,30	1,77	98,53
69	trainlm	9	8	1,39	1,22	51,91
70	trainlm	10	8	1,40	0,98	114,01

## ANEXOS

### Anexo A

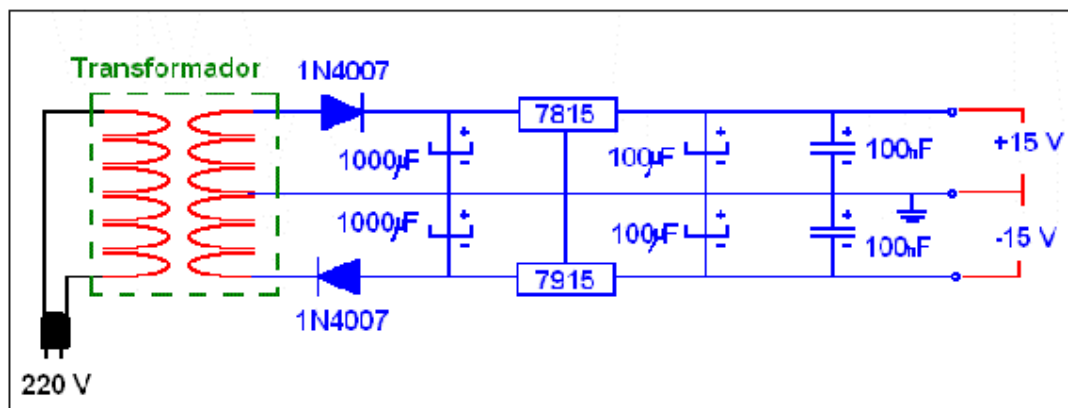


Figura A1. Esquema elétrico da fonte de tensão simétrica ( $\pm 15V$ ) (Viana, 2008).




Figura A2. Esquema elétrico do circuito amplificador de corrente (Viana, 2008).