

Adaptação do Modelo de Preisach para Histereses Assimétricas: Aplicação ao Dióxido de Vanádio

José Adolfo da Silva Sena

Dissertação de Mestrado submetida ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal da Paraíba - Campus II como parte dos requisitos necessários para obtenção do grau de Mestre em Ciências no Domínio da Engenharia Elétrica.

Área de Concentração: Processamento da Informação

Gurdip Singh Deep, Dr.

Orientador

Raimundo Carlos Silvério Freire, Dr.

Orientador

Campina Grande, Paraíba, Brasil

© José Adolfo da Silva Sena, Março de 2001



S474a
2001

Sena, José Adolfo da Silva
Adaptação do modelo de Preisach para histereses
assimétricas: aplicação ao dióxido de vanádio. / José
Adolfo da Silva Sena – Campina Grande: UFPb, 2001.
71p.

Dissertação (Mestrado) UFPb. CCT
Inclui bibliografia

1. Modelos para histereses – Engenharia Elétrica
2. Resistência Elétrica 3. Temperatura 4. Estimação de
Parâmetros I. Título

CDU: 621.315.59

JOSÉ ADOLFO DA SILVA SENA

Dissertação Aprovada em 15.03.2001



PROF. GURDIP SINGH DEEP, Ph.D., UFPB

Orientador



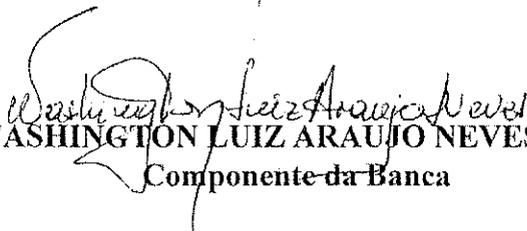
PROF. RAIMUNDO CARLOS SILVÉRIO FREIRE, Dr., UFPB

Orientador



PROF. ANTONIO MARCUS NOGUEIRA LIMA, Dr., UFPB

Componente da Banca



PROF. WASHINGTON LUIZ ARAUJO NEVES, Ph.D., UFPB

Componente da Banca

CAMPINA GRANDE - PB

Março - 2001

Dedicatória

Dedico este trabalho primeiramente a Deus, que nunca me abandonou e a Nossa Senhora de Nazaré, mãe de Jesus Cristo (o mestre dos mestres).

Em segundo lugar dedico à minha mãe que foi a grande responsável por tudo que eu sou hoje, lavando roupa e cozinhando para fora, vendendo pasteis, etc. ela é um exemplo de uma brasileira pobre, mas com visão de futuro e uma enorme força de vontade, como a grande maioria das mães brasileiras. Dedico também ao meu pai que, na medida do possível, tentou me dar as condições necessárias para me desenvolver.

Em terceiro lugar dedico ao povo brasileiro que pagou pela minha formação a peso de suor e sangue, que não têm oportunidade de entrar em uma universidade, mas que se tivessem oportunidades de educação e de exercer plenamente sua cidadania tornariam o Brasil uma das maiores nações da terra.

Agradecimentos

Agradeço aos professores Gurdip S. Deep e R. C. S. Freire pela incansável orientação e Luiz A. L. Almeida pela colaboração importantíssima, sem as quais não seria possível realizar este trabalho.

Aos meus amigos Márcio A. Moscoso, Lúcio M. Souza e Rômulo Pires pela convivência e a todos os meus amigos e amigas, de dentro e de fora da universidade, que tornaram estes dois anos uma experiência importante na minha vida.

Também agradeço ao CNPq, à CAPES ou a quem de direito que tenha proporcionado o suporte financeiro para viabilizar a realização deste trabalho.

Resumo

Os modelos para histereses existentes pressupõe que as curvas de histerese apresentem algumas características bem definidas o que limita a aplicação destes modelos. O uso destes modelos para descrever histereses que fogem a estas características, só pode ser feita através de algumas adaptações. Este trabalho concentra-se no estudo de um destes modelos de histerese, o modelo de Preisach, e propõe algumas adaptações ao modelo afim de que ele possa ser usado na representação de histereses assimétricas.

Abstract

The models for hysteresis presuppose that the hysteresis curves present some characteristics what it limits the application of these models. The use of these models to describe hysteresis that do not has the these characteristics, it can only be done through some adaptations. This work concentrates on the study of one of these hysteresis models, the model of Preisach, and it proposes some adaptations to the model so that he can be used in the representation of asymmetric histereses.

Conteúdo

Introdução geral	1
1 Introdução	3
2 O modelo de Preisach	6
2.1 Introdução	6
2.2 Origem do modelo	6
2.3 O triângulo de Preisach	9
2.3.1 Definição do triângulo de Preisach	9
2.3.2 Divisão do triângulo de Preisach	10
2.4 Propriedades do modelo de Preisach	11
2.5 O modelo de Preisach para o VO_2	13
2.5.1 Alterações propostas	13
2.6 Interpretação geométrica para o VO_2	14
2.7 Procedimento de Mayergoyz para determinação experimental de $\mu(T_\alpha, T_\beta)$	18
2.8 Conclusão	20
3 Identificação de uma histerese simétrica	22
3.1 Introdução	22
3.2 Identificação de uma histerese simétrica	23
3.3 Identificação do modelo de Preisach de uma histerese simétrica	23
3.3.1 Introdução	23
3.3.2 Identificação individual	24
3.3.3 Identificação conjunta	30
3.4 Observações sobre o universo de busca	31
3.5 Conclusão	32

4	Modelo para histereses assimétricas	33
4.1	Introdução	33
4.2	Determinação da histerese ideal	34
4.2.1	Escolha da histerese ideal	34
4.2.2	Função de distribuição gaussiana	34
4.2.3	Função gaussiana como função de distribuição	35
4.2.4	Interpretação geométrica	36
4.2.5	Curvas decrescentes de primeira ordem	39
4.2.6	Implementação numérica	41
4.3	Uso de redes neuronais no mapeamento de histereses	43
4.3.1	Estrutura do modelo	43
4.3.2	Treinamento da rede neuronal	44
4.3.3	Resultados obtidos	46
4.4	Conclusão	48
5	Conclusão	49
5.1	Conclusões	49
5.1.1	As dificuldades de aplicação	49
5.1.2	Limitação do modelo à histereses simétricas	50
5.2	Proposta de novos trabalhos	50
A	Introdução aos algoritmos genéticos e redes neuronais	52
A.1	Algoritmos genéticos	52
A.1.1	Definição de algoritmos genéticos	52
A.1.2	O Algoritmo	53
A.2	Redes neuronais	57
A.2.1	Introdução	57
A.2.2	Descrição	58
A.2.3	Neurônios	58
A.2.4	Camadas	59
A.2.5	Observação	59
B	Toolbox para histereses no Matlab	61
B.1	Introdução	61
B.2	Identificação de histereses	62
B.2.1	Introdução	62

B.2.2	Identificação individual	62
B.2.3	Identificação conjunta	63
B.3	Simulação das histereses	64
B.4	Conclusão	65
B.4.1	Aplicação desta toolbox	65
B.4.2	Códigos fontes	65
	Bibliografia	70

Lista de Símbolos e Abreviaturas

a, b, k	Parâmetros da função de distribuição gaussiana
$d(x, y)$	Função de distribuição gaussiana
erf	Função de erro $\text{erf}(x) = \frac{2}{\sqrt{\pi}} \int_0^x \exp(-t^2) dt$
FOD	First Order Descendent (curva decrescente de primeira ordem)
FOA	First Order Ascendent (curva ascendente de primeira ordem)
$f_{\alpha\beta}(T_\alpha, T_\beta)$	Função que representa as curvas decrescentes de primeira ordem.
$f_{\alpha\beta}(T_\alpha, T_\beta, \theta)$	Representação paramétrica das curvas decrescentes de primeira ordem.
$f(t)$	Histerese simétrica
f_{k-1}	Valor assumido na saída do modelo no instante da reversão na excitação
$F(\alpha, \beta)$	Incremento na histerese devido a curva decrescente de primeira ordem.
H	Campo magnético.
h_i, l_i, g_i, o_i	Parâmetros de uma curva decrescente de primeira ordem.
$h(T_\alpha^i), l(T_\alpha^i), g(T_\alpha^i), o(T_\alpha^i)$	Funções dos parâmetros das FODs com a temperatura de reversão
$J_{ind}^i(\theta_i)$	Função de custo para a identificação individual.
$J(\theta)$	Função de custo
$J_{conj}(\theta)$	Função custo para a identificação conjunta.
p_1, \dots, p_{16}	Parâmetros da função que representam as FODs.
S	Triângulo de Preisach
S_{+1}	Área onde os operadores elementares estão no estado +1.
S_{-1}	Área onde os operadores elementares estão no estado -1.
S_1	Área onde os operadores elementares estão no estado 1.
S_0	Área onde os operadores elementares estão no estado 0.
T	Temperatura.
T_{k-1}	Temperatura de reversão.
T_α^i	Temperatura de reversão onde inicia uma FOD.
T_α	Temperatura decrescente.
T_β	Temperatura crescente.
α, β	Limiares de disparo. θ
$\mu(T_\alpha, T_\beta)$	Função de distribuição do modelo de Preisach.
$\hat{\cdot}$	operador histerese elementar

Lista de Tabelas

A.1 Componentes do algoritmo genético	54
---	----

Lista de Figuras

1.1	Característica RxT do óxido de vanádio	3
1.2	Histerese do VO_2 mapeada por uma função logarítmica $\Phi = \log(R)$	4
2.1	Ímãs elementares submetidos a um campo magnético $H(t)$	7
2.2	Ciclo de histerese elementar	8
2.3	Definição do modelo de Preisach como um somatório de histereses elementares	8
2.4	Triângulo de Preisach	10
2.5	Divisão do triângulo de Preisach quando a excitação está monotonicamente crescendo.	11
2.6	Divisão do triângulo de Preisach quando a excitação está monotonicamente decrescendo.	12
2.7	Divisão do triângulo de Preisach quando a intensidade da excitação está aumentando até $H_{\alpha'}$ e em seguida decresce	12
2.8	Histerese elementar adaptado ao caso da histerese térmica do VO_2	14
2.9	Triângulo de Preisach adaptado ao caso da histerese térmica do VO_2	15
2.10	Divisão do triângulo de Preisach quando a excitação está decrescendo	15
2.11	Divisão do triângulo de Preisach quando a excitação está crescendo	16
2.12	Divisão do triângulo de Preisach quando a excitação é reduzida de T_{β_0} para T_1 e aumentada de T_1 para T_2	17
2.13	Curva de transição de primeira ordem decrescente (FOD)	18
2.14	Triângulo de Preisach quando a excitação varia de T_{β_0} até $T_{\alpha'}$	19
2.15	Divisão do triângulo de Preisach resultante da variação monotonicamente decrescente de $T(t) = T_{\alpha'}$ até $T(t) = T_{\beta'}$	20
3.1	Histerese simétrica	24
3.2	Histerese simétrica	25
3.3	Curvas descendentes de primeira ordem	25

3.4	Resultados da identificação de cada uma das curvas decrescentes de primeira ordem, em contínuo o estimado e em círculos o experimental	27
3.5	Variação do parâmetro h_i com T_α^i	28
3.6	Variação do parâmetro l_i com T_α^i	28
3.7	Variação do parâmetro g_i com T_α^i	29
3.8	Variação do parâmetro o_i com T_α^i	29
3.9	Resposta do modelo a uma excitação senoidal	31
4.1	Gráfico da função gaussiana	35
4.2	Superfície da função de distribuição usada na histerese ideal	36
4.3	Triângulo de Preisach para o VO_2	37
4.4	Excitação decrescendo de 1 para $T(t)$	37
4.5	Excitação decrescendo partindo do estado de saturação inferior para 0	38
4.6	Excitação decrescendo de 0 para $T(t)$	39
4.7	Excitação crescendo partindo de do estado de saturação superior	40
4.8	Ciclo externo da histerese descrita por uma função de distribuição Gaussiana	40
4.9	Configuração do triângulo correspondente a uma FOD	41
4.10	Modelo para histerese não simétrica	43
4.11	Modelo modificado para que a rede neuronal trabalhe com valores normalizados entre -1 e 1	44
4.12	Identificação do modelo de histerese qualquer	44
4.13	Curvas usadas no treinamento da rede neuronal	45
4.14	Histerese assimétrica obtida experimentalmente	45
4.15	Evolução do erro médio quadrático	46
4.16	Resultado apresentado pelo modelo. Em pontilhado os dados experimentais, em contínuo o estimado	47
4.17	Comparação entre os ciclos internos gerados pelo modelo e os obtidos em experimentos. Em pontilhado, dados experimentais, em contínuo, estimado pelo modelo	47
A.1	Exemplo de mutação binária	56
A.2	rede neuronal feed-forward	58
A.3	Neurônio comum	59
A.4	rede neuronal com neurônios de polarização e uma camada escondida	60

Introdução geral

A equipe de pesquisa do grupo de Instrumentação Eletrônica do Departamento de Engenharia Elétrica da Universidade da Paraíba tem trabalhado com pesquisa de circuitos, baseados em sensores termoresistivos, para medição de diversas grandezas físicas usando o princípio da equivalência elétrica.

Recentemente, alguns sensores que apresentam transição de fase têm chamado atenção da comunidade científica. Alguns destes sensores apresentam um coeficiente de variação de sua resistência elétrica com a temperatura muito grande. Dois tipos de sensores têm sido objeto de estudo: supercondutores e sensores com filmes finos de VO_2 . Estas variações estão relacionadas com uma transição na estrutura cristalina destes materiais.

Os supercondutores têm a grande desvantagem de que as propriedades de interesse, para uso como sensor, se manifestam apenas em temperaturas criogênicas. Os sensores de VO_2 apresentam sua transição de fase em temperaturas entre 35° e 65° , o que traz vantagens em termos de implementação prática, mas apresentam uma curva de histerese em sua característica $R \times T$. Filmes finos de VO_2 vêm sendo estudados no nosso laboratório com o objetivo de desenvolver modelos matemáticos para a sua representação.

Experimentos feitos com filmes de VO_2 em uma câmara de temperatura controlada, permitiu a obtenção de dados para caracterizá-lo. Os dados obtidos com estes experimentos foram coerentes com os dados apresentados na literatura, mostrando uma histerese com características peculiares em sua região de transição. A característica altamente assimétrica da sua curva de histerese dificulta sua representação direta através dos modelos tradicionais de histerese. Recentemente foi aplicado o modelo de Preisach para descrever a histerese térmica no VO_2 , para isso foi usado um artifício matemático que reduz as assimetrias da histerese [1]. O modelo resultante se mostrou incapaz de descrever com precisão o comportamento da histerese em toda faixa de variação de temperatura. Isto em grande parte é devido à característica de histerese assimétrica do VO_2 .

O modelo de Preisach vem sendo empregado para descrever o fenômeno de histerese em diversos materiais. Entretanto, somente histereses simétricas são representáveis por este modelo

[9]. Não somente o VO_2 mas também outros materiais apresentam histerese com característica assimétrica, sendo isto, portanto, uma restrição à utilização do modelo de Preisach para estes casos [16]. Visando superar esta limitação, este trabalho propõe o uso de uma função de mapeamento que transforme uma histerese simétrica em uma histerese assimétrica obtida experimentalmente. Neste trabalho, foi utilizada como função de mapeamento uma rede neuronal do tipo perceptron em multicamada [12]. Entretanto, qualquer outra função pode ser utilizada, como por exemplo, exponenciais, séries de exponenciais, séries de senos (série de Fourier), etc.

Capítulo 1

Introdução

A característica Resistência-Temperatura ($R - T$) do VO_2 é mostrada na figura 1.1. Esta curva, está relacionada com a variação das características físicas do material em função da temperatura. Em temperaturas abaixo de 35°C o material se comporta como um semicondutor, acima de 65°C como um metal, e entre 35°C e 65°C está na região de transição semicondutor-metal.

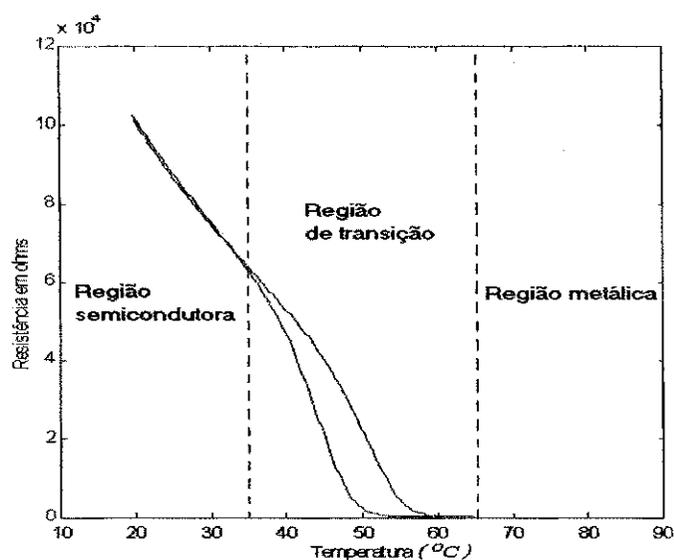


Figura 1.1: Característica $R \times T$ do óxido de vanádio

A característica $R - T$ do VO_2 é uma histerese, então o grupo de instrumentação eletrônica iniciou um estudo sobre modelos de histerese. Neste estudo, foi verificada a existência de um grande número de dispositivos com histerese sendo estudados por diferentes grupos de pesquisa. Alguns destes dispositivos também possuem histerese assimétrica. Apesar das restrições de simetria do modelo de Preisach, e as consequentes limitações, este modelo ainda vem sendo

utilizado como uma ferramenta geral para modelagem de histerese.

O grupo de instrumentação eletrônica fez uma primeira tentativa para obter um modelo para a histerese do VO_2 usando o modelo de Preisach mediante o uso de um artifício matemático [1]. Este artifício ameniza algumas características assimétricas do VO_2 . O artifício consistiu em aplicar uma função logarítmica aos dados experimentais e obter uma histerese menos assimétrica em relação ao ponto central da curva de histerese. Com isso a curva de histerese da figura 1.1, foi transformada na curva histerese na figura 1.2.

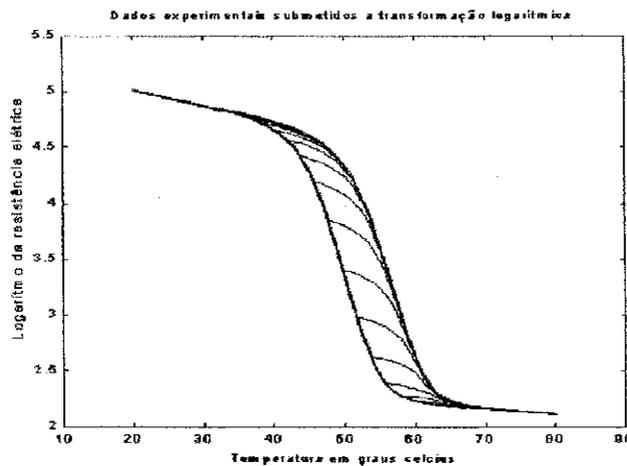


Figura 1.2: Histerese do VO_2 mapeada por uma função logarítmica $\Phi = \log(R)$

Além de não representar a histerese do VO_2 corretamente, a identificação do modelo de Preisach é uma tarefa bastante complexa e ainda não resolvida completamente.

Se utilizando a transformação logarítmica foi possível amenizar as características assimétricas da histerese do VO_2 , porque não propor uma função genérica que possa transformar uma histerese simétrica em uma histerese assimétrica? Uma histerese simétrica pode ser simulada numericamente pelo modelo de Preisach, portanto, as condições de representação estão satisfeitas [9]. De posse desta histerese simétrica, a função de transformação genérica pode mapeá-la em uma curva de histerese assimétrica experimental.

Este trabalho propõe o uso de uma função de mapeamento bidimensional que mapeia uma histerese simétrica conveniente, gerada pelo modelo de Preisach, em uma histerese experimental qualquer. Para chegar a este objetivo é necessário:

- Estudo da adaptação do modelo de Preisach para o VO_2
 - Estudo do modelo de Preisach e sua o procedimento de identificação de Mayergoyz
 - Estimação dos parâmetros da expressão das FODs através de algoritmos genéticos

- Identificar as limitações e dificuldades do procedimento de identificação de Mayergoyz
- Desenvolvimento do modelo de Preisach para histereses assimétricas
 - Estabelecer as condições de simetria e definir uma função de distribuição capaz de gerar a histerese simétrica ideal. Definir critérios para a escolha desta função
 - Definir a função de mapeamento necessária para o caso do VO_2 (estudo de caso deste trabalho). Definir critérios para determinar a forma desta função, (neste trabalho é usada uma rede neuronal) e então determinar a forma da função de mapeamento.
 - Treinamento da rede neuronal, usando os dados experimentais.

Capítulo 2

O modelo de Preisach

2.1 Introdução

Neste capítulo será apresentado o modelo de Preisach, suas propriedades e limitações.

2.2 Origem do modelo

O modelo de Preisach foi formulado em 1935 para representar o comportamento de materiais ferromagnéticos. Este modelo é baseado em algumas hipóteses físicas sobre o comportamento dos materiais ferromagnéticos. Pode-se considerar que o modelo de Preisach foi o primeiro modelo físico para o fenômeno de histerese. Este modelo é, sobretudo, um modelo estritamente intuitivo cujo carácter matemático genérico foi ressaltado por Krasnoselskii [8].

O modelo se baseia na hipótese de que os materiais ferromagnéticos são constituídos por uma grande quantidade de ímãs elementares que são orientados por um campo magnético externo, e que se mantêm com uma certa orientação remanescente mesmo que o campo seja retirado. Na figura 2.1, é ilustrado esta interpretação.

Cada um destes *ímãs* elementares apresenta uma histerese *elementar* (figura. 2.2). Os valores α e β representam os valores limites onde os ímãs elementares assumem os estados +1 ou -1. Quando o campo magnético $H(t)$ supera o limiar α , a histerese elementar assume o estado +1 e quando for inferior ao valor β então ela assume o estado -1. Quando o campo magnético estiver entre α e β , então o estado do ímã vai depender de sua história. Cada *ímã* elementar possui seus próprios valores limiares α e β , isto levou Krasnoselskii a propor um operador $\hat{\gamma}_{\alpha\beta}$ que representa cada ímã elementar, que quando submetido a um campo magnético $H(t)$ assume os estados +1 ou -1. Desta forma, pode-se definir o operador de Krasnoselskii como:

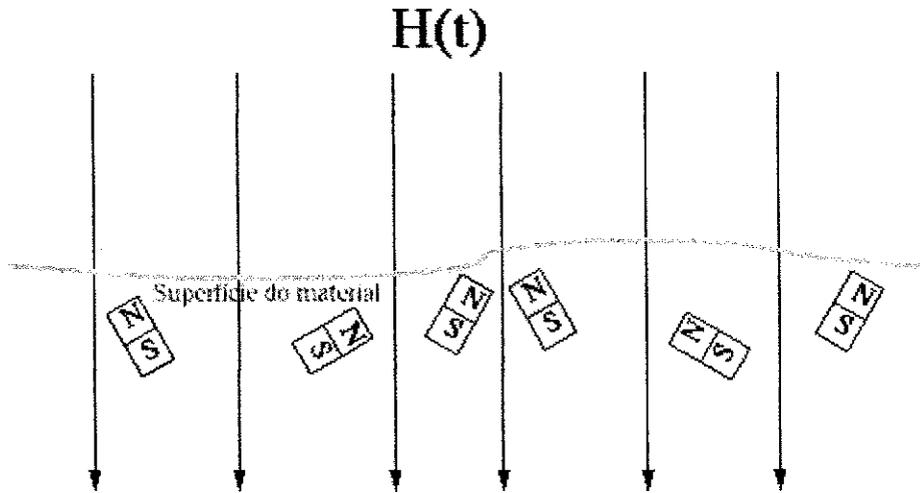


Figura 2.1: Ímãs elementares submetidos a um campo magnético $H(t)$

$$\begin{aligned} \hat{\gamma}_{\alpha\beta}H(t) &= +1, H(t) > \alpha \\ \hat{\gamma}_{\alpha\beta}H(t) &= -1, H(t) < \beta \\ \hat{\gamma}_{\alpha\beta}H(t) &= ?, \beta < H(t) < \alpha \end{aligned} \tag{2.1}$$

Cada ímã elementar está relacionado a uma probabilidade em particular de estar nos estados +1 ou -1, de forma que o número de ímãs elementares no estado +1 ou -1 deve ser descrito por uma função de distribuição $\mu(\alpha, \beta)$. Esta função é chamada de função de distribuição de Preisach e o problema de determinação dessa função é o objetivo das técnicas de identificação para este modelo.

A curva de histerese dos materiais ferromagnéticos (ou outro material com histerese) é definida como a composição de cada um dos ímãs elementares ponderados através de pesos definidos pela função de distribuição de Preisach, como ilustrado na da figura 2.3.

O número de operadores elementares é muito grande e possuem dimensões infinitesimais, então esta composição de ímãs elementares é representada por uma integral dupla em uma área S , como apresentada na equação (2.2).

$$B(t) = \iint_S \mu(H_\alpha, H_\beta) \hat{\gamma}_{\alpha\beta} T(t) dH_\alpha dH_\beta \tag{2.2}$$

Quando a excitação aplicada ao dispositivo estiver fora de S , a histerese estará em um estado saturado, para que isto ocorra, a função de distribuição deve ser nula fora desta área. As variáveis H_α e H_β correspondem ao campo crescente ou decrescente, respectivamente.

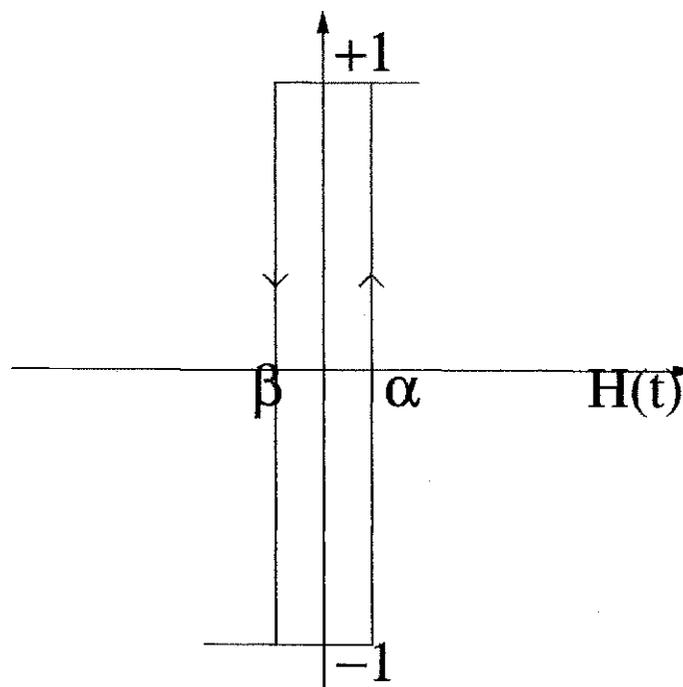


Figura 2.2: Ciclo de histerese elementar

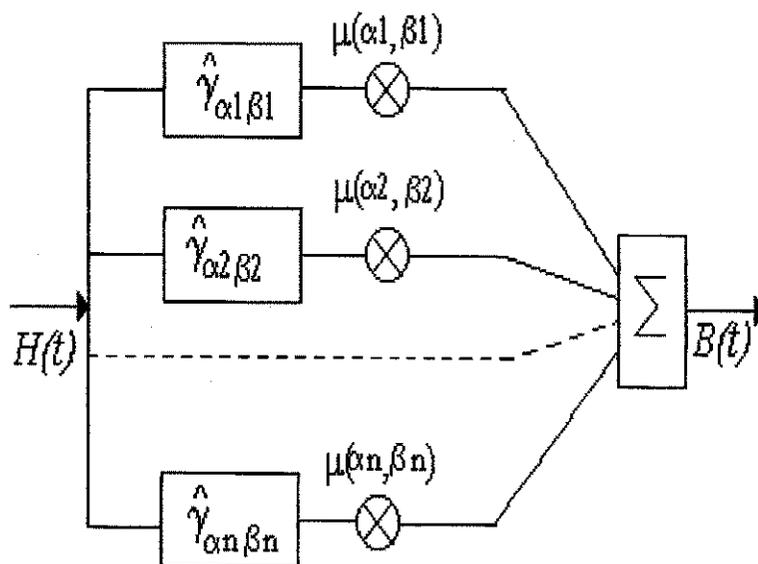


Figura 2.3: Definição do modelo de Preisach como um somatório de histereses elementares

O uso do operador $\hat{\gamma}_{\alpha\beta}$ torna a equação (2.2) genérica, podendo ser usada para representar os mais diversos fenômenos de histerese que obedecem a algumas propriedades básicas. O modelo de Preisach, após a interpretação de Krasnoselskii, tornou-se uma ferramenta matemática e não mais um modelo para um determinado fenômeno físico em particular.

A obtenção da função de distribuição é o objetivo dos métodos de identificação deste modelo, o que têm gerado um grande número de publicações, em periódicos de Física e Engenharia, entre os quais [3] [13] [14] e [17].

A área S onde a integração é feita têm a forma de um triângulo e é chamada de *triângulo de Preisach*. O triângulo de Preisach têm a forma de um triângulo reto e possibilita uma interpretação geométrica que facilita bastante o entendimento sobre o funcionamento do modelo.

2.3 O triângulo de Preisach

2.3.1 Definição do triângulo de Preisach

O triângulo de Preisach delimita a área onde a integração dupla do modelo é feita. Este triângulo facilita bastante a compreensão sobre o funcionamento do modelo e suas propriedades.

O triângulo de Preisach pode ser representado como na figura 2.4. O eixo de redução do campo é o eixo H_β e o eixo H_α é o eixo de aumento do campo. A evolução da excitação na entrada do dispositivo (campo magnético) vai dividir o triângulo de Preisach S em duas áreas: uma área onde os ímãs elementares estão no estado +1, área S_{+1} , e uma outra área onde os ímãs estão no estado -1, S_{-1} . Com uma excitação (campo magnético) crescendo, um número maior de ímãs elementares estão no estado +1, isto faz com que a região S_{+1} do triângulo de Preisach aumente e, conseqüentemente, a região S_{-1} diminua. Com uma excitação decrescendo, um número maior de ímãs elementares estão no estado -1, neste caso a região S_{-1} vai aumentar.

Pode-se, desta forma, desmembrar a equação (2.2) em duas parcelas: uma em que os ímãs elementares estão no estado +1 ($\hat{\gamma}_{\alpha\beta}H(t) = +1$) e outra em que os ímãs elementares estão no estado -1 ($\hat{\gamma}_{\alpha\beta}H(t) = -1$), como demonstrado através da equação (2.3).

$$B(t) = \iint_{S_{+1}} \mu(H_\alpha, H_\beta) dH_\alpha dH_\beta - \iint_{S_{-1}} \mu(H_\alpha, H_\beta) dH_\alpha dH_\beta \quad (2.3)$$

A linha que divide o triângulo nestas duas regiões será representada por $L(t)$. A linha $L(t)$ sempre será constituída de segmentos de retas horizontais e verticais sucessivos, tendo, portanto, a forma de uma escada, e a intersecção de cada um destes segmentos constitui um vértice. Estes vértices definem o mecanismo de memória do modelo.

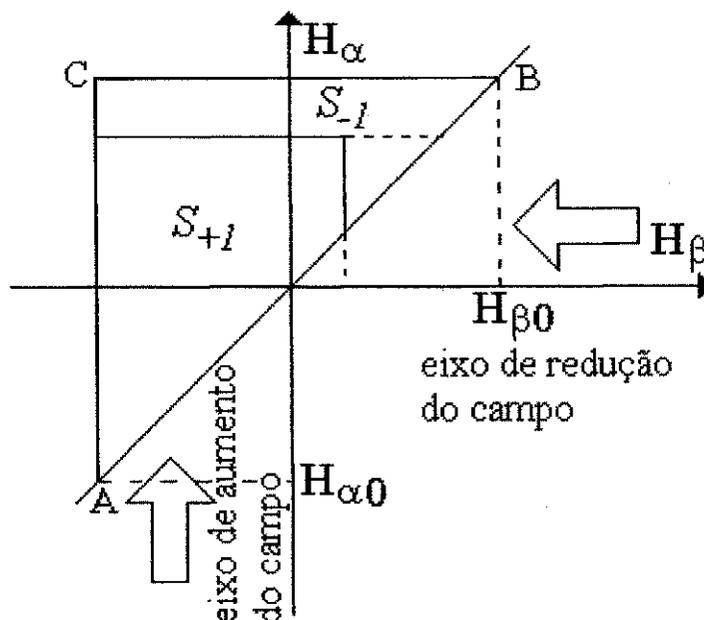


Figura 2.4: Triângulo de Preisach

2.3.2 Divisão do triângulo de Preisach

A maneira como a excitação evolui determina a forma como o triângulo de Preisach vai ser dividido. Como foi explicado anteriormente, quando a excitação está monotonicamente crescendo, o número de ímãs elementares em estado +1 vai tornando-se cada vez maior e a quantidade de ímãs elementares em estado -1 é cada vez menor e quando a excitação está monotonicamente decrescendo ocorre o inverso. Com estas considerações pode-se estabelecer as regras de formação de $L(t)$.

Excitação monotonicamente crescente

Quando a excitação está monotonicamente crescendo (campo aumentando), um número cada vez maior de ímãs elementares vão ao estado +1, ou seja, a área S_{+1} está crescendo enquanto que a área S_{-1} está decrescendo. Geometricamente, isto pode ser interpretado como o deslocamento para cima de uma reta horizontal que divide o triângulo nas duas regiões, S_{+1} e S_{-1} . Esta reta é definida como $L(t) = H_\alpha = H(t)$, como pode ser visto na figura 2.5.

Excitação monotonicamente decrescente

Quando a excitação está monotonicamente decrescendo (campo diminuindo), um número cada vez maior de ímãs elementares vão ao estado -1, ou seja, a área S_{-1} está crescendo enquanto que a área S_{+1} está decrescendo. Geometricamente, isto pode ser interpretado como

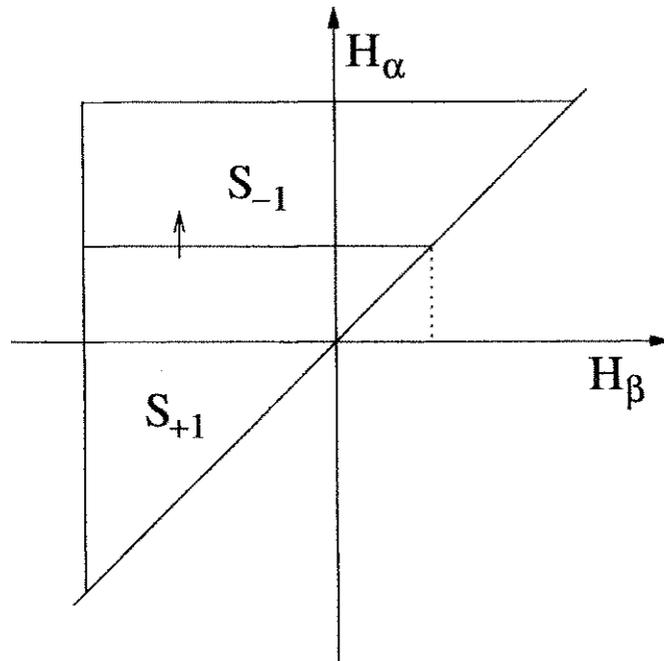


Figura 2.5: Divisão do triângulo de Preisach quando a excitação está monotonicamente crescendo.

o deslocamento para a esquerda de uma reta vertical que divide o triângulo nas duas regiões, S_{+1} e S_{-1} . Esta reta é definida como $L(t) = H_{\beta} = T(t)$, como pode ser visto na figura 2.6.

Excitação com reversão

Supondo que a excitação esteja crescendo até um determinado valor H_{α} ; e em seguida ocorra uma reversão e a excitação passe a ser monotonicamente decrescente de forma que $H_{\beta} = H(t)$, então pode-se verificar que o triângulo de Preisach fica dividido como demonstrado através da figura 2.7.

2.4 Propriedades do modelo de Preisach

O modelo de Preisach possui algumas propriedades que condicionam sua aplicação a determinados tipos de histereses. Estas propriedades em conjunto constituem o chamado teorema da representação [9].

- **Propriedade da eliminação.** "Cada valor mínimo da excitação $H(t)$ remove os vértices de $L(t)$ cuja coordenada H_{β} está acima deste mínimo e cada valor máximo de $H(t)$ elimina o vértice de $L(t)$ cuja coordenada T_{α} está abaixo deste máximo [9]".

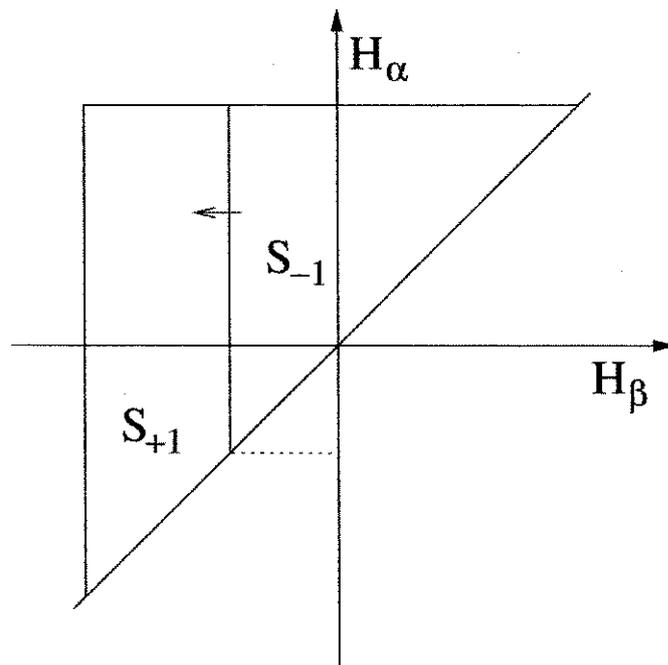


Figura 2.6: Divisão do triângulo de Preisach quando a excitação está monotonicamente decrescendo.

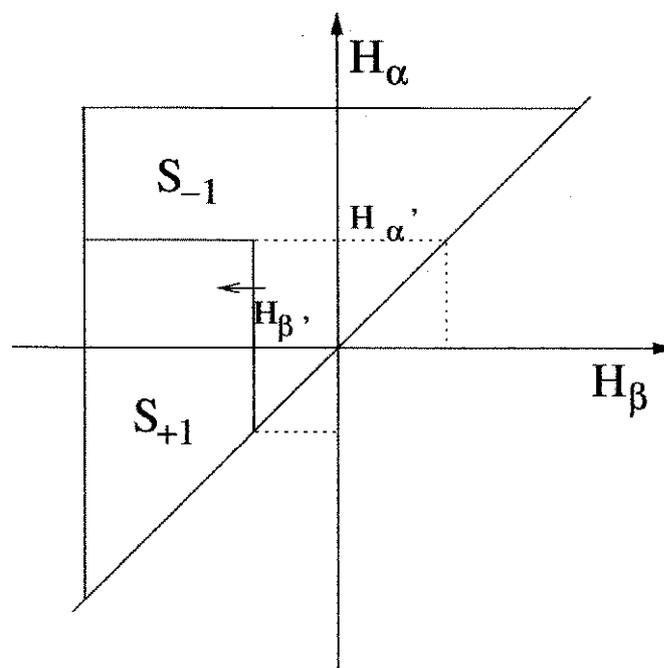


Figura 2.7: Divisão do triângulo de Preisach quando a intensidade da excitação está aumentando até H_α' e em seguida decresce

Esta propriedade é responsável pelo surgimento dos ciclos internos em uma histerese.

- **Propriedade da congruência.** “*Todos os ciclos internos formados através de uma mesma variação de excitação de ΔH para mais e para menos alternadamente são congruentes e estão deslocados verticalmente [9]*”.

Esta propriedade têm uma consequencia muito importante: ela define que uma histerese deve ser simétrica com relação ao seu centro para poder ser representável pelo modelo de Preisach. Esta condição de simetria pode ser expressa matematicamente pela equação (2.4).

$$\mu(H_\alpha, H_\beta) = \mu(-H_\beta, -H_\alpha) \quad (2.4)$$

- **Teorema da representação.** “*Uma histerese é representável pelo modelo de Preisach se e somente se satisfazer as propriedades da eliminação e da congruência [9]*”.

O teorema da representação é demonstrado em [9]. O teorema da representação estabelece os casos em que modelo de Preisach pode ser aplicado.

2.5 O modelo de Preisach para o VO_2

2.5.1 Alterações propostas

A formulação apresentada por Mayergoyz é destinada a histereses centradas na origem e com inclinação sempre positiva. A histerese apresentada pelo VO_2 não é centrada na origem e sua inclinação é sempre negativa, então como primeira tentativa de aplicar o modelo de Preisach ao VO_2 foi apresentado em [1], um operador elementar diferente e uma interpretação para S também diferente do modelo de Preisach original foram propostos.

A histerese elementar usada para estas modificações, é mostrada na fig. 2.8. Nesta figura, nota-se que a histerese não assume valores negativos e a trajetória percorrida pela excitação é invertida com relação à histerese elementar anterior.

Nesta adaptação, a excitação da entrada passa a ser a temperatura, o eixo de crescimento (aquecimento) passa a ser o eixo T_β e o eixo de decrescimento (resfriamento) passa a ser o eixo T_α . O triângulo de Preisach passa a ser como mostrado na figura 2.9.

Pode-se reescrever a equação (2.2), trocando a variável de excitação de campo magnético para temperatura, então a integral de Preisach passa a ser dada pela equação (2.5).

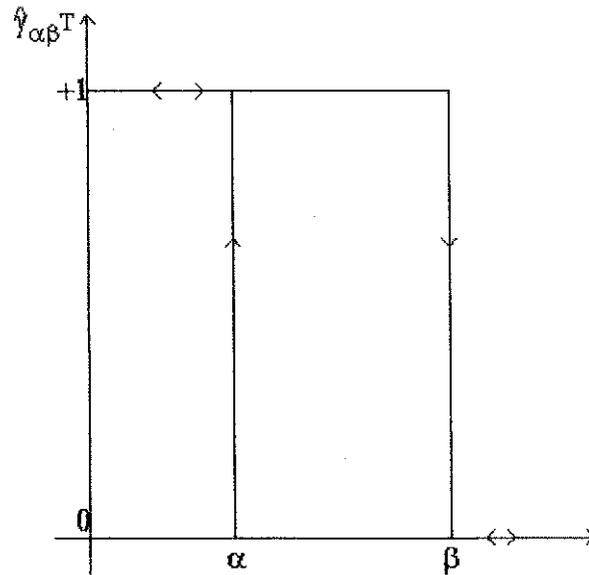


Figura 2.8: Histerese elemental adaptado ao caso da histerese térmica do VO_2

$$f(t) = \hat{\Gamma}T(t) = \iint_S \mu(T_\alpha, T_\beta) \hat{\gamma}_{\alpha\beta} T(t) dT_\alpha dT_\beta \quad (2.5)$$

Onde $T(t)$ é a temperatura que vai excitar o dispositivo, T_α é a temperatura quando decrescente e T_β a temperatura quando crescente.

2.6 Interpretação geométrica para o VO_2

O triângulo de Preisach usado neste trabalho, permite que o sentido da variação da curva de histerese seja invertida com relação a curva de histerese de materiais ferromagnéticos e que esta curva esteja centrada em locais diferentes da origem. Apesar de ter sido desenvolvido para o VO_2 , este triângulo pode ser aplicado em muitas outras situações onde a curva de histerese possui estas características.

O eixo T_α corresponde à variação decrescente da excitação aplicada na entrada, enquanto que o eixo T_β corresponde ao eixo da excitação crescente.

Quando a excitação aplicada na entrada do dispositivo está monotonicamente decrescendo, um segmento de reta horizontal, que vem se deslocando sobre o eixo T_α de cima para baixo, vai dividir o triângulo da figura 2.9 como mostrado na figura 2.10, esta reta é definida pela expressão $T_\alpha = T(t)$, onde $T(t)$ é a excitação (temperatura). Quando a excitação está monotonicamente crescendo, um segmento de reta vertical, que vem se deslocando sobre o eixo T_β , vai dividir o

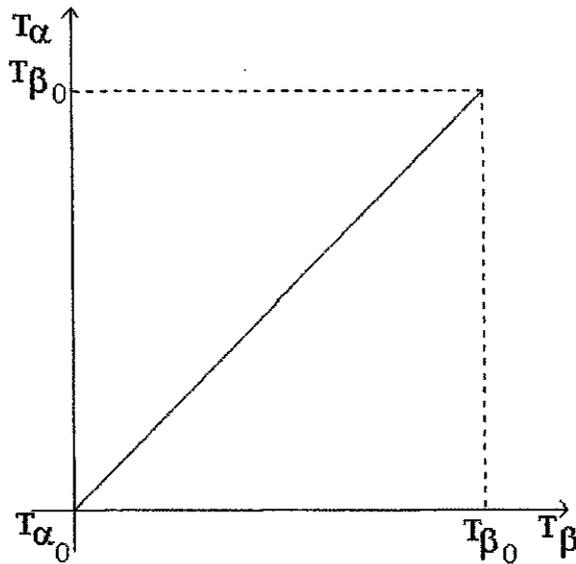


Figura 2.9: Triângulo de Preisach adaptado ao caso da histerese térmica do VO_2

triângulo da figura 2.9 como mostrado através da figura 2.11, esta reta é definida pela expressão $T_\beta = T(t)$, onde $T(t)$ é a excitação. Cada um destes segmentos de retas horizontais e/ou verticais, que sempre serão consecutivas, constituirá a interface $L(t)$ que dividirá o triângulo de Preisach e duas regiões: uma em que $\hat{\gamma}_{\alpha\beta}T(t) = 1$, região S_1 , e outra em que $\hat{\gamma}_{\alpha\beta}T(t) = 0$, região S_0 .

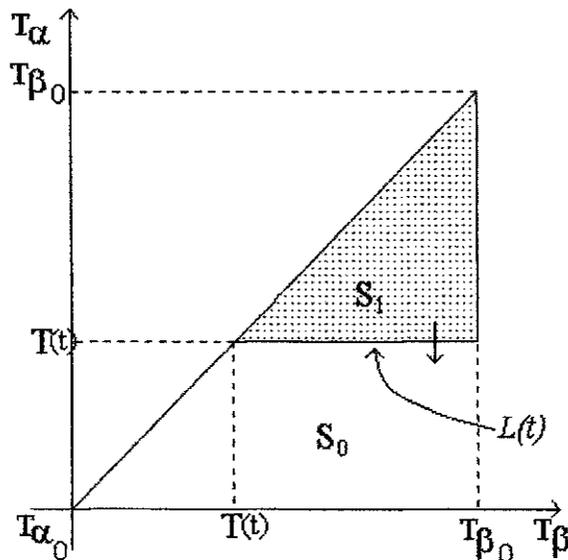


Figura 2.10: Divisão do triângulo de Preisach quando a excitação está decrescendo

Supondo agora que as variações descritas anteriormente sejam consecutivas, primeiramente a excitação vai decrescendo de T_{β_0} até chegar ao valor T_1 então o triângulo fica dividido de forma

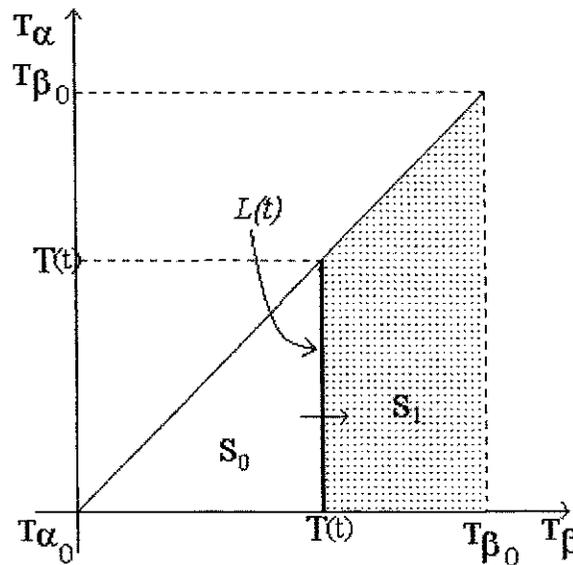


Figura 2.11: Divisão do triângulo de Preisach quando a excitação está crescendo

semelhante ao apresentado através da figura 2.10, no entanto a reta estaciona em $T_\alpha = T_1$. Agora suponha que a excitação reverta, então a excitação vai crescendo de T_1 até T_2 então o triângulo fica dividido de forma semelhante ao apresentado através da figura 2.11 no entanto a reta estaciona em $T_\beta = T_2$ e parte de T_1 . Agora a interface $L(t)$ que divide o triângulo de Preisach torna-se como apresentado através da figura 2.12, onde deve-se notar onde a região S_1 e S_0 estão localizadas, outra observação importante é que a interface $L(t)$ é constituída de um segmento horizontal e outro vertical e o ponto de junção dos dois segmentos formam o vértice (T_1, T_2) . Este vértice caracteriza uma informação que será memorizada até que ela seja eliminada pela propriedade da eliminação. Pode-se concluir, então, que quando a excitação está decrescendo, $L(t)$ termina em um segmento de reta horizontal. Quando a excitação aplicada na entrada está crescendo, $L(t)$ termina em um segmento de reta vertical.

Com as explicações dadas até aqui, algumas conclusões com relação à interpretação geométrica do modelo de Preisach podem ser formuladas:

1. *Toda excitação monotonicamente decrescente finaliza $L(t)$ horizontalmente;*
2. *Toda excitação monotonicamente crescente finaliza $L(t)$ verticalmente;*
3. *Um vértice em $L(t)$ é formado quando ocorre uma reversão na excitação (temperatura, neste caso);*
4. *Cada vértice formado constitui uma informação memorizada pela histerese e que será eliminada, ou não, conforme a propriedade da eliminação.*

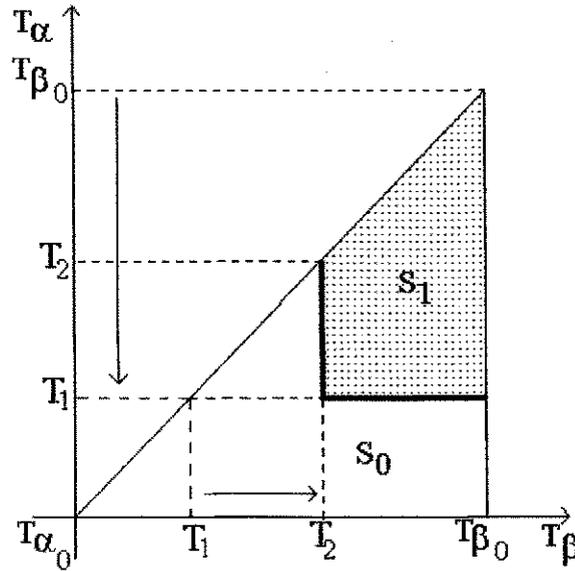


Figura 2.12: Divisão do triângulo de Preisach quando a excitação é reduzida de T_{β_0} para T_1 e aumentada de T_1 para T_2

5. A interface $L(t)$ divide o triângulo de Preisach em duas regiões, que correspondem a analogia ao relê da histerese elementar para baixo, em $S_0(t)$ onde $T(t) < T_\alpha$, e para cima, em $S_1(t)$ onde $T(t) > T_\beta$. Desta forma, para qualquer instante de tempo, pode-se dividir a integral da equação (2.5) em duas integrais sobre as áreas $S_1(t)$ e $S_0(t)$, definidas através da interface $L(t)$, como apresentado através da equação (2.6).

$$f(t) = \hat{\Gamma}T(t) = \iint_{S_1(t)} \mu(T_\alpha, T_\beta) \hat{\gamma}_{\alpha\beta} T(t) d\alpha d\beta + \iint_{S_0(t)} \mu(T_\alpha, T_\beta) \hat{\gamma}_{\alpha\beta} T(t) d\alpha d\beta \quad (2.6)$$

Uma vez que:

$$\hat{\gamma}_{\alpha\beta} T(t) = 1, \text{ se } (T_\alpha, T_\beta) \in S_1(t) \quad (2.7)$$

$$\hat{\gamma}_{\alpha\beta} T(t) = 0, \text{ se } (T_\alpha, T_\beta) \in S_0(t) \quad (2.8)$$

Substituindo as equações (2.7) e (2.8) na equação (2.6) obtém-se:

$$f(t) = \hat{\Gamma}T(t) = \iint_{S_1(t)} \mu(T_\alpha, T_\beta) dT_\alpha dT_\beta \quad (2.9)$$

O mecanismo de memória no modelo de Preisach está relacionado à forma de $L(t)$, assim para os mesmos valores de excitação aplicada na entrada podem corresponder a diferentes valores da grandeza medida no dispositivo, dependendo de como a excitação evoluiu.

2.7 Procedimento de Mayergoyz para determinação experimental de $\mu(T_\alpha, T_\beta)$

O uso do procedimento de Mayergoyz para a determinação experimental do modelo de Preisach possui muitas dificuldades. Este procedimento exige que se obtenha, experimentalmente, famílias de curvas e estas mesmas curvas sejam utilizadas na simulação do modelo através de técnicas de interpolação [9].

As curvas necessárias para a determinação de $\mu(T_\alpha, T_\beta)$ são chamadas de curvas decrescentes de primeira ordem, ou usando siglas em inglês, FODs. Para obter uma FOD, faz-se com que o dispositivo atinja seu estado de saturação inferior, que para o caso em estudo, corresponde a uma temperatura superior a $T_{\beta 0}$. Em seguida, a temperatura é reduzida até um valor $T_{\alpha'}$ e logo em seguida começa a ser aumentada para valores $T_{\beta'} = T(t)$, $T_{\beta 0} \leq T(t) \leq T_{\alpha 0}$, como mostrado na figura 2.13. A curva delimitada pelos pontos $(T_{\alpha'}, f_{\alpha'})$ e $(T_{\beta'}, f_{\alpha'\beta'})$ é a curva decrescente de primeira ordem.

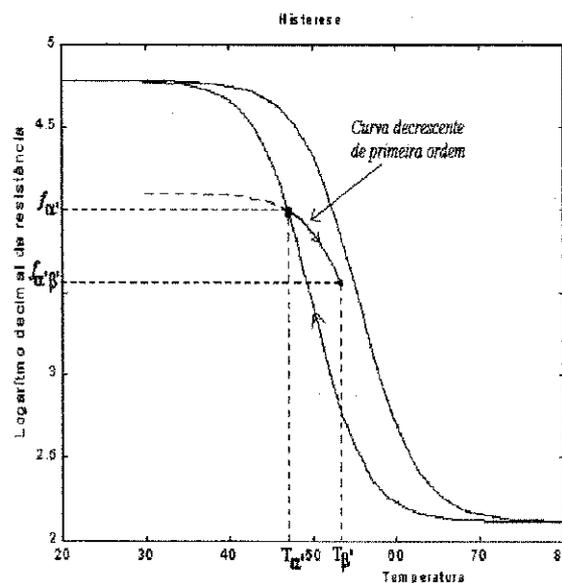


Figura 2.13: Curva de transição de primeira ordem decrescente (FOD)

Pode-se definir uma expressão para uma FOD como mostrado na equação (2.10).

$$F(T_{\alpha'}, T_{\beta'}) = f_{\alpha'} - f_{\alpha'\beta'} \quad (2.10)$$

No triângulo de Preisach, quando a excitação é reduzida até $T_{\alpha'}$, a interface $L(t)$ assume a forma mostrada através da figura 2.14. Agora, quando a excitação reverte e começa a aumentar de forma que $T_{\beta'} = T(t)$, a interface $L(t)$ no triângulo de Preisach torna-se como mostrado na figura 2.15.

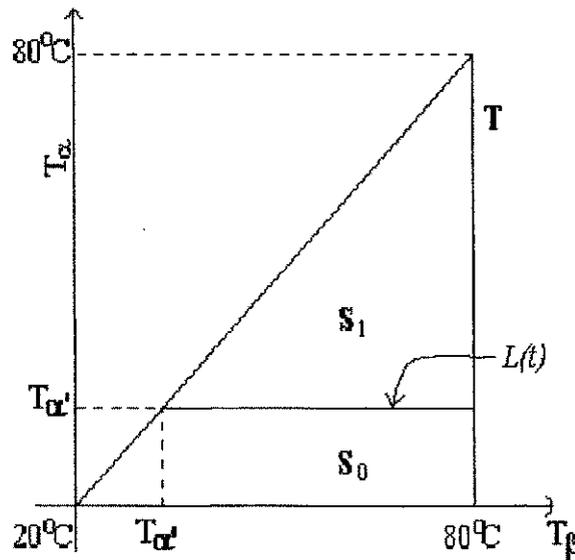


Figura 2.14: Triângulo de Preisach quando a excitação varia de T_{β_0} até $T_{\alpha'}$

Comparando a figura 2.15 com a figura 2.14, observa-se que o triângulo $T(T_{\alpha'}, T_{\beta'})$ é somado à área $S_0(t)$ e subtraído de $S_1(t)$. Usando este fato, pode-se usar a equação (2.9) e obter (2.14).

$$f(t) = \widehat{\Gamma}T(t) = \iint_{S_1(t)} \mu(T_{\alpha}, T_{\beta}) dT_{\alpha} dT_{\beta} \quad (2.11)$$

$$f_{\alpha'} = \iint_{S_1(t)} \mu(T_{\alpha}, T_{\beta}) dT_{\alpha} dT_{\beta} \quad (2.12)$$

$$f_{\alpha'\beta'} = \iint_{S_1(t)} \mu(T_{\alpha}, T_{\beta}) dT_{\alpha} dT_{\beta} - \iint_{T(\alpha', \beta')} \mu(T_{\alpha}, T_{\beta}) dT_{\alpha} dT_{\beta} \quad (2.13)$$

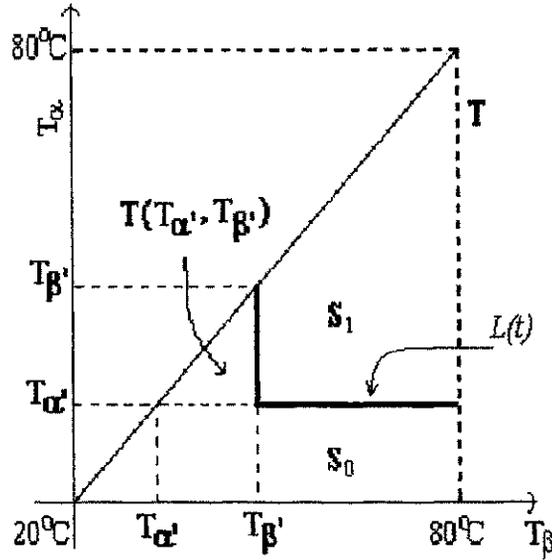


Figura 2.15: Divisão do triângulo de Preisach resultante da variação monotonicamente decrescente de $T(t) = T_{\alpha'}$ até $T(t) = T_{\beta'}$

$$f_{\alpha'} - f_{\alpha'\beta'} = \iint_{T(\alpha',\beta')} \mu(T_{\alpha}, T_{\beta}) dT_{\alpha} dT_{\beta} \quad (2.14)$$

$$f_{\alpha'\beta'} = f_{\alpha'\beta'}(T_{\alpha}, T_{\beta}) = f_{\alpha'} - \iint_{T(\alpha',\beta')} \mu(T_{\alpha}, T_{\beta}) dT_{\alpha} dT_{\beta} \quad (2.15)$$

A equação (2.15) pode ser reescrita para obter a equação (2.16):

$$f_{\alpha'\beta'}(T_{\alpha}, T_{\beta}) = f_{\alpha'} - \iint_{T(\alpha',\beta')} \mu(T_{\alpha}, T_{\beta}) dT_{\alpha} dT_{\beta} = f_{\alpha'} - \frac{1}{2} \int_{T_{\alpha'}}^{T_{\beta'}} \left[\int_{T_{\alpha'}}^{T_{\beta'}} \mu(T_{\alpha}, T_{\beta}) dT_{\alpha} \right] dT_{\beta} \quad (2.16)$$

Derivando duas vezes em função de $T_{\alpha'}$ e $T_{\beta'}$, obtêm-se a equação (2.17):

$$\mu(T_{\alpha'}, T_{\beta'}) = -\frac{1}{2} \frac{\partial^2 f_{\alpha'\beta'}(T_{\alpha}, T_{\beta})}{\partial T_{\alpha'} \partial T_{\beta'}} \quad (2.17)$$

2.8 Conclusão

Este capítulo têm por finalidade expor os princípios do modelo de Preisach e suas principais características. É um modelo cuja formulação matemática é complexa e apresenta muitas

dificuldades para que seja aplicado. Pode-se notar pela equação (2.17) que pode-se determinar a função de distribuição a partir das FODs, esta técnica foi apresentada originalmente por Mayergoyz. Outra utilidade para o conceito de FODs é a implementação numérica do modelo. O procedimento de Mayergoyz utilizava os próprios dados experimentais para, através de interpolação, implementar numericamente o modelo, neste trabalho, diferentemente do trabalho de Mayergoyz, é obtido uma expressão paramétrica para as FODs tornando o procedimento de identificação um procedimento de estimação paramétrica.

No próximo capítulo será apresentada a aplicação do modelo em uma curva de histerese obtida experimentalmente e as dificuldades envolvidas, assim como algumas contribuições a respeito da forma geral da equação que representa as FODs.

Capítulo 3

Identificação de uma histerese simétrica

3.1 Introdução

No capítulo anterior foi apresentado o modelo de Preisach. Foi mostrado que para uma curva de histerese ser representável pelo modelo de Preisach ela deve satisfazer ao teorema da representação. Foi visto também que a identificação do modelo é feita baseada nas curvas decrescentes de primeira ordem (FODs) e que a implementação numérica do modelo é feita em termos destas curvas.

Mayergoyz propõe o uso de interpolação dos próprios dados experimentais para que o modelo seja simulado. Neste trabalho será apresentado um método um pouco diferente: uma equação paramétrica para as FODs será encontrada e usada na simulação do modelo. O procedimento mostrado neste capítulo é baseado no procedimento proposto em [1].

O objetivo deste capítulo é mostrar as dificuldades envolvidas na identificação do modelo de Preisach através do procedimento proposto por Mayergoyz. Basicamente, o procedimento seguido neste capítulo consistiu em identificar, através de algoritmos genéticos, cada uma das curvas decrescentes de primeira ordem separadamente e em seguida, todas as curvas em conjunto. Também é proposto uma forma geral para as FODs que facilite um pouco este procedimento.

Para este trabalho, a norma quadrática foi suficiente para a determinação dos parâmetros do modelo de Preisach, esta norma será chamada de função de custo (trata-se de uma norma quadrática). A função de custo têm a forma geral dada pela equação (3.1).

$$J(\hat{\theta}) = \sum_{j=1}^M [z_j - m_j(\hat{\theta})]^2 \quad (3.1)$$

onde z_j são os dados experimentais, $m_j(\hat{\theta})$ é uma função conhecida e $\hat{\theta}$ é o conjunto de parâmetros que se deseja determinar. O algoritmo genético vai minimizar J para obter $\hat{\theta} = \hat{\theta}_0$.

O uso dos algoritmos genéticos se justifica pela necessidade de encontrar parâmetros de funções altamente não lineares (em termos de seus parâmetros) e com superfícies de erro com muitos mínimos locais. Uma introdução aos algoritmos genéticos é dado no apêndice A.

3.2 Identificação de uma histerese simétrica

Para descrever as FODs, uma superfície do tipo $f_{\alpha'\beta'}(T_\alpha, T_\beta, \theta)$ deve ser proposta, na qual o vetor de parâmetros $\theta = [\theta_1 \ \theta_2 \ \dots \ \theta_N]^T$ possibilita o ajuste da função proposta aos dados experimentais obtidos em laboratório, através da determinação dos valores numéricos destes parâmetros. Uma vez que esta superfície está determinada, através dos parâmetros estimados $\hat{\theta}$, a função de distribuição pode ser obtida [9] como

$$\mu(T_\alpha, T_\beta) = -\frac{1}{2} \frac{\partial^2 f_{\alpha'\beta'}(T_\alpha, T_\beta, \hat{\theta})}{\partial T_\alpha \partial T_\beta} \quad (3.2)$$

No procedimento descrito acima, foram utilizadas as FODs para determinar $\mu(T_\alpha, T_\beta)$. Pela simetria, tem-se que $\mu(T_\alpha, T_\beta) = \mu(\frac{T_{\alpha_0} + T_{\beta_0}}{2} - T_\beta, \frac{T_{\alpha_0} + T_{\beta_0}}{2} - T_\alpha)$, implicando que $f_{\alpha'\beta'}(T_\alpha, T_\beta, \theta)$ deve possuir este mesmo tipo de simetria.

A determinação dos parâmetros θ é um problema de otimização. Cada FOD representa uma função com a mesma forma geral mas com diferentes valores para seus parâmetros.

3.3 Identificação do modelo de Preisach de uma histerese simétrica

3.3.1 Introdução

A técnica de identificação usada neste trabalho é melhor apresentada através de um exemplo. Este exemplo foi obtido a partir da simetrização da histerese do VO_2 . Nas baixas temperaturas, o comportamento do dióxido de vanádio é de um termistor (semicondutora), isto sugere que pode-se obter uma histerese simétrica a partir da curva de histerese do VO_2 através da divisão dos dados experimentais por uma expressão do tipo Ae^{-kT} .

Nesta secção é mostrado como o procedimento de identificação de Mayergoz foi implementado principalmente para demonstrar as dificuldades a ele associadas. Na figura 3.2, é mostrada a curva de histerese que é usada como exemplo.

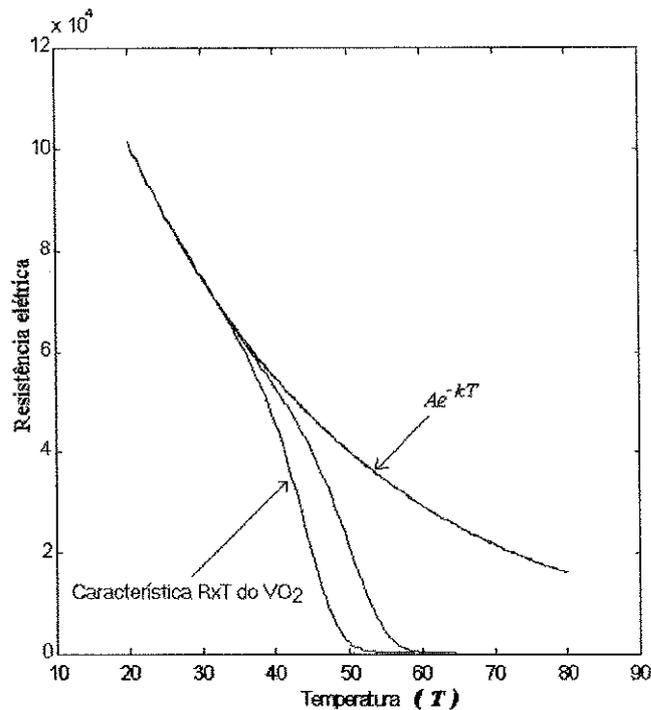


Figura 3.1: Histerese simétrica

Esta histerese simetrizada é usada neste trabalho apenas com o intuito de obter uma histerese para ser usada como exemplo de aplicação da técnica de identificação de Mayergoyz e não como técnica de identificação da histerese do VO₂.

Neste capítulo será apresentado uma extensão ao procedimento de Mayergoyz, será obtida uma expressão analítica para representar as FODs e desta forma, estabelecer uma forma paramétrica para o modelo de Preisach.

3.3.2 Identificação individual

As curvas decrescentes de primeira ordem

A identificação é feita em duas etapas. A primeira consiste em fazer a identificação individualmente para cada FOD e, desta forma, obter as formas das expressões para cada parâmetro. Conhecendo como os parâmetros de cada FOD variam com o valor de reversão da entrada (T_{α}^i), pode-se montar uma função de custo que identifique as FODs em conjunto (pode-se chamar de identificação conjunta).

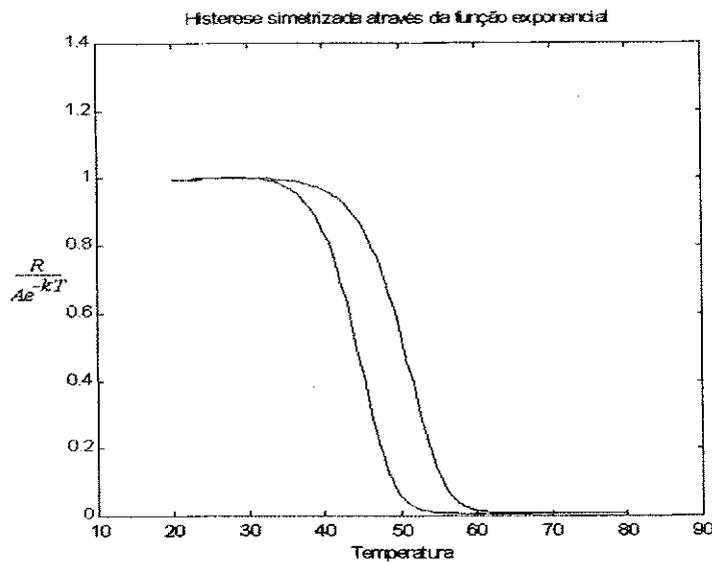


Figura 3.2: Histerese simétrica

Procedimento de identificação e resultados

A figura 3.3 mostra a família de curvas que serão identificadas.

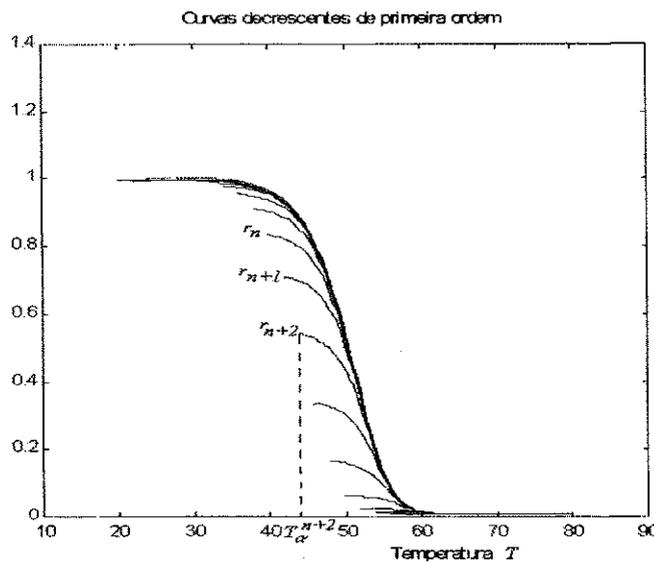


Figura 3.3: Curvas decrescentes de primeira ordem

Será tomado uma expressão da forma dada pela equação (3.3), para cada uma das i FODs obtidas experimentalmente e para o processo de identificação serão necessárias N FODs ($1 \leq i \leq N$). A temperatura onde inicia cada uma das i FODs é representada por T_{α}^i que corresponde à temperatura de reversão. Após a reversão, a temperatura vai aumentando, então para cada

FOD i , a temperatura de aquecimento no triângulo de Preisach corresponde a $T_\beta^i = T^i(t)$ e $T_\alpha^i \leq T^i(t) \leq T_{\beta 0}$. Cada FOD i possui M^i amostras. Cada uma das amostras de uma FOD i será representada pelo símbolo r_j^i onde j é a amostra corrente e $1 \leq j \leq M^i$. Observando cada uma das i FODs na figura 3.3, pode-se considerar que todas elas podem ser representadas por uma equação do tipo:

$$f_{\alpha\beta'}(T_\alpha^i, T_\beta^i) = h_i \tanh [l_i (T_\beta^i + g_i)] + o_i, T_\alpha^i \leq T_\beta^i(t) \leq T_{\beta 0} \quad (3.3)$$

Onde $\theta_i = [h_i \ l_i \ g_i \ o_i]^t$ são os parâmetros que devem ser determinados para cada uma das i FODs. Para cada FOD i existe um T_α^i e um θ_i , então deve existir uma função que estabeleça uma relação entre eles, ou seja, deseja-se encontrar uma conjunto de funções tais que:

$$\theta_i = \begin{bmatrix} h_i = h(T_\alpha^i) \\ l_i = l(T_\alpha^i) \\ g_i = g(T_\alpha^i) \\ o_i = o(T_\alpha^i) \end{bmatrix}$$

Para determinar os valores de θ_i para cada FOD, é utilizada uma função de custo da forma:

$$J_{ind}^i(\theta_i) = \sum_{j=1}^{M^i} \{r_j^i - h_i \tanh [l_i (T_\beta^i + g_i)] + o_i\}^2 \quad (3.4)$$

Minimizando $J_{ind}^i(\theta_i)$ (através de algoritmos genéticos) na equação (3.4), obtém-se os parâmetros de cada curva FOD. A idéia do procedimento usado neste trabalho consiste em encontrar os parâmetros para cada uma das i FODs e tentar estabelecer uma função que descreva como varia cada um destes parâmetros com a temperatura onde inicia cada uma das FODs (T_α^i). Para determinar a regra com que variam os parâmetros de cada FOD com a temperatura de reversão, da tentativa e erro até encontrar curvas para os parâmetros que correspondam a alguma função conhecida de T_α^i .

A determinação dos parâmetros presentes na equação (3.3) de tal forma que a variação de cada um deles com T_α^i seja uma função matemática conhecida, é uma tarefa extremamente trabalhosa e sujeita a falhas. A causa do problema é a possibilidade de existir vários valores para θ_i igualmente bons, dependendo do domínio estabelecido para a variação de cada um dos parâmetros (universo de busca), tornando difícil estabelecer uma regra para a variação com T_α^i de cada um destes parâmetros presentes na equação (3.3).

Após um número muito grande de tentativas, obteve-se o resultado da identificação de cada uma das FODs, usando a função de custo dada na equação (3.4), e cujos resultados são ilustrados na figura 3.4. Nas figuras 3.5, 3.6, 3.7 e 3.8 são mostradas as curvas correspondentes à variação dos parâmetros h_i , l_i , g_i e o_i com T_α^i , respectivamente, onde pode-se notar que cada um destes parâmetros segue funções matemáticas bem definidas.

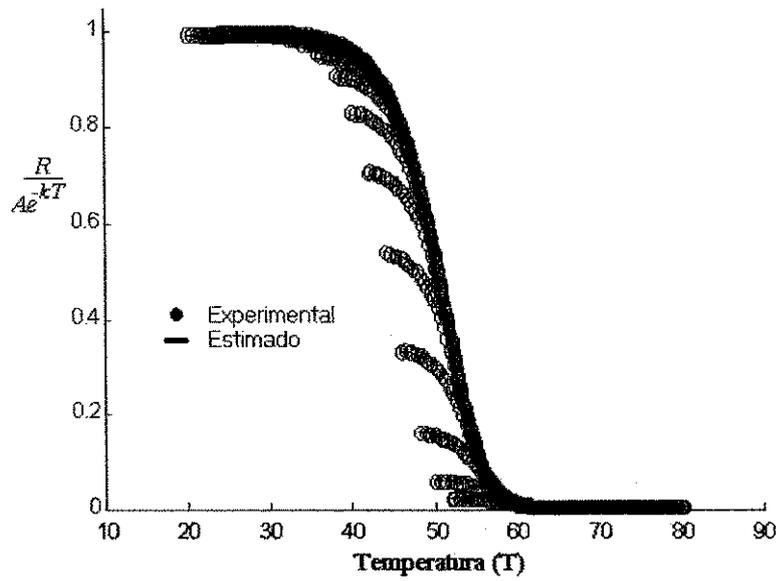


Figura 3.4: Resultados da identificação de cada uma das curvas decrescentes de primeira ordem, em contínuo o estimado e em círculos o experimental

Todos os parâmetros podem ser aproximados por funções tangente hiperbólicas, dadas pelas equações (3.5), (3.6), (3.7) e (3.8).

$$h_i = h(T_\alpha^i) = p_1 \tanh[p_2(T_\alpha^i + p_3)] + p_4 \quad (3.5)$$

$$l_i = l(T_\alpha^i) = p_5 \tanh[p_6(T_\alpha^i + p_7)] + p_8 \quad (3.6)$$

$$g_i = g(T_\alpha^i) = p_9 \tanh[p_{10}(T_\alpha^i + p_{11})] + p_{12} \quad (3.7)$$

$$o_i = o(T_\alpha^i) = p_{13} \tanh[p_{14}(T_\alpha^i + p_{15})] + p_{16} \quad (3.8)$$

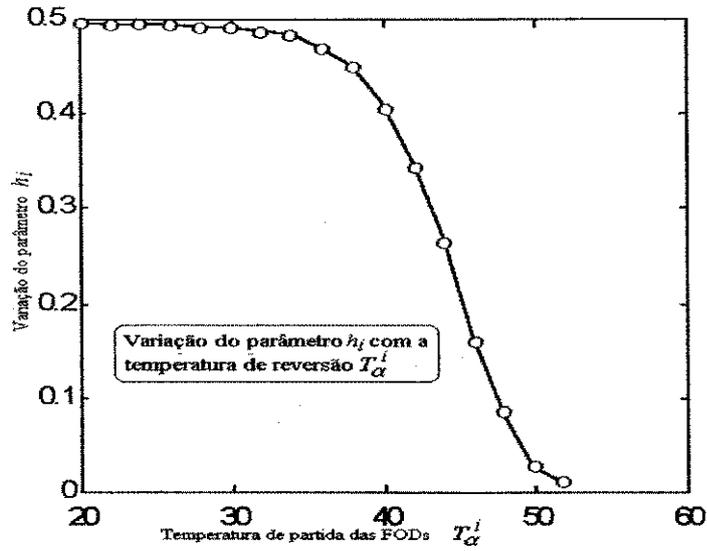


Figura 3.5: Variação do parâmetro h_i com T_α^i

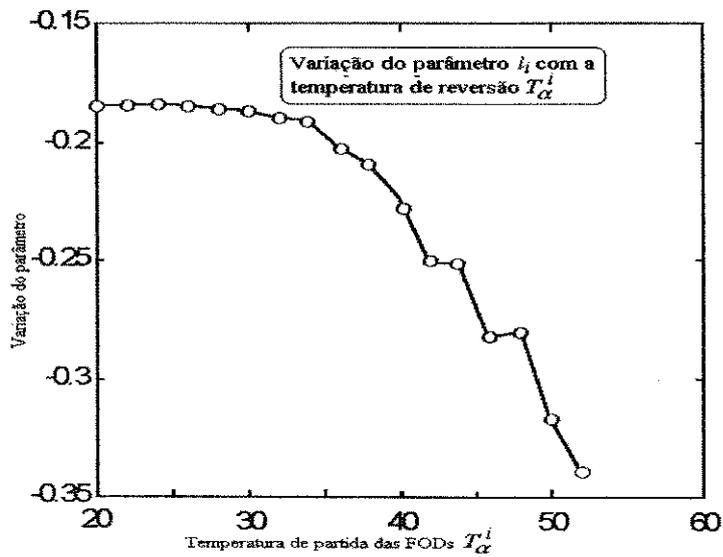


Figura 3.6: Variação do parâmetro l_i com T_α^i

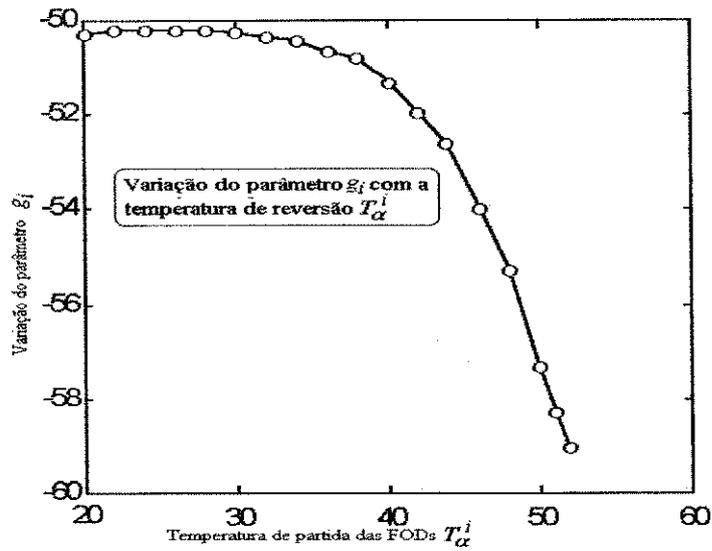


Figura 3.7: Variação do parâmetro g_i com T_α^i

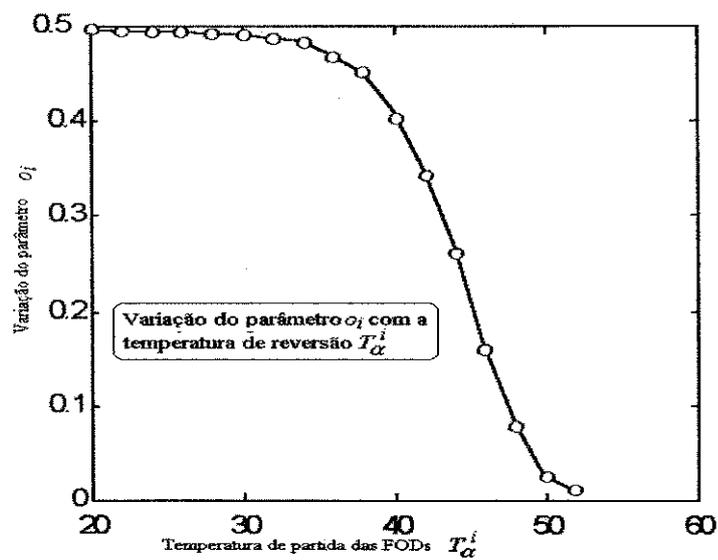


Figura 3.8: Variação do parâmetro o_i com T_α^i

3.3.3 Identificação conjunta

As equações (3.5), (3.6), (3.7), (3.8) e (3.3) constituem a expressão geral para as FODs. O número de parâmetros é grande, cerca de dezesseis.

A função de custo deverá incluir todas as funções necessárias a implementação do modelo.

Para fazer a identificação conjunta, a função de erro deve ser composta por dois somatórios aninhados. Uma para computar o erro de cada uma das FODs e outra para somar estes erros individuais para computar o erro conjunto. A função de erro conjunta é dada pela equação:

$$J_{global}(\theta) = \sum_{i=1}^N \sum_{j=1}^{M^i} \{r_j^i - h(T_\alpha^i) \tanh \{l(T_\alpha^i) [T_j^i + g(T_\alpha^i)]\} + o_i\}^2 \quad (3.9)$$

Onde $h(T_\alpha^i)$, $l(T_\alpha^i)$, $g(T_\alpha^i)$ e $o(T_\alpha^i)$ são dados pelas equações (3.5), (3.6), (3.7) e (3.8). Onde r_j^i e T_j^i são os dados experimentais correspondentes a amostra j da FOD i .

Com o uso da identificação em conjunto de todas as funções que implementam o modelo, ao mesmo tempo que diminui o tempo para a identificação (já que é praticamente automática) introduz um problema de solução bastante difícil: determinar a grau de liberdade em torno do qual a solução é encontrada. O problema é bastante difícil quando a identificação está sendo feita partindo com poucas informações. Um procedimento que pode ser recomendado é escolher uma faixa de variação relativamente grande e, a partir de tentativa e erro, ir diminuindo a faixa de variação. Quando foi feita a identificação em separado de cada função previamente, pode-se usar o resultado obtido como ponto de partida para a identificação conjunta.

Durante a identificação desta histerese e da histerese identificada em [15] usando este procedimento, um problema sério ocorria: algumas soluções encontradas não conseguiam satisfazer à propriedade da congruência, porque eram funções não simétricas.

Para resolver este problema, mais algumas restrições são necessárias para que a solução encontrada represente uma função simétrica e possa ser usado na implementação numérica do modelo. Um exemplo de restrição, e que pode ser constatado pelas curvas nas figuras 3.5 e 3.8, é fazer com que $h(T_\alpha^i)$ e $o(T_\alpha^i)$ sejam iguais.

O melhor resultado conseguido através do uso de algoritmos genéticos possui as seguintes equações:

$$h(T_\alpha^i) = 0.25 \tanh [-0.225 (T_\alpha^i - 45)] + 0.25 \quad (3.10)$$

$$o(T_\alpha^i) = 0.25 \tanh [-0.225 (T_\alpha^i - 45)] + 0.25 \quad (3.11)$$

$$l(T_\alpha^i) = -0.21 \tag{3.12}$$

$$g(T_\alpha^i) = -48.8 \tanh [0.11 (T_\alpha^i - 62.7)] - 99.0 \tag{3.13}$$

Aplicando uma excitação senoidal amortecida obteve-se o resultado mostrado na figura 3.9.

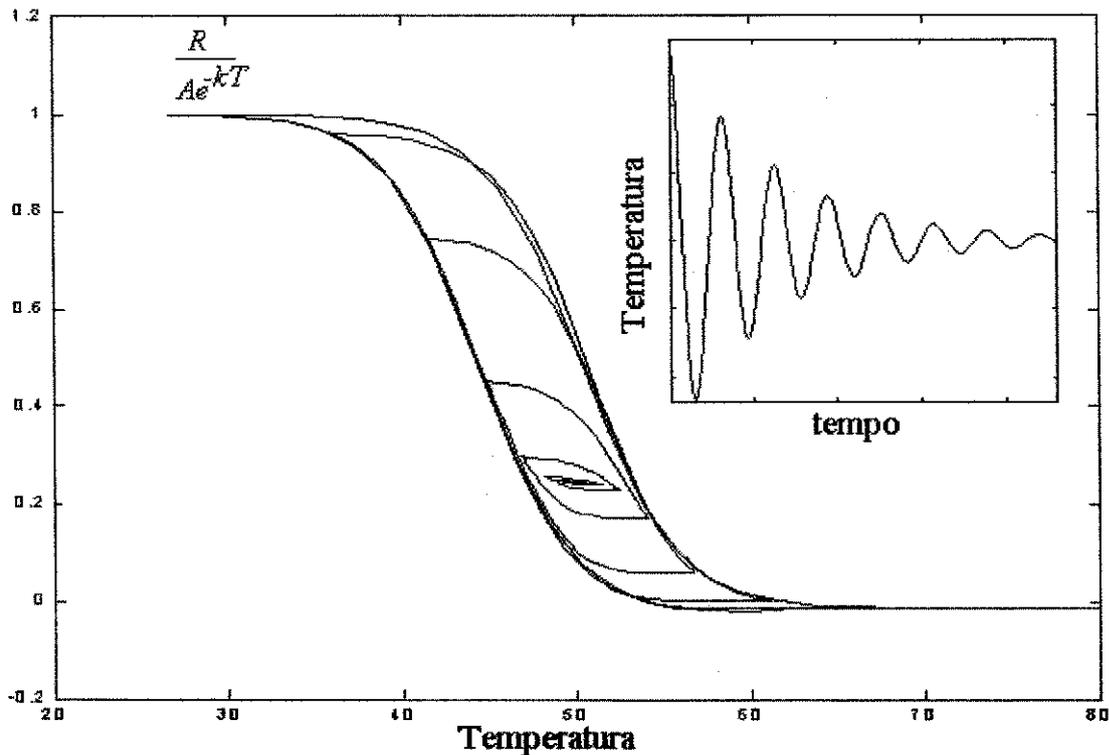


Figura 3.9: Resposta do modelo a uma excitação senoidal

3.4 Observações sobre o universo de busca

O algoritmo genético é efetivamente um algoritmo de busca. Na aplicação de otimização, o universo de busca do algoritmo é a faixa de variação dada a cada um dos parâmetros a serem determinados.

É de grande importância, a determinação correta do universo de busca do algoritmo. Para a aplicação dada neste capítulo, a universo de busca consiste em uma faixa de variação possível para os parâmetros do modelo de Preisach.

Na identificação conjunta, o problema do universo de busca é mais evidente. Algumas considerações pode ser feitas para facilitar a determinação deste universo.

1. O procedimento de identificação de Mayergoyz, assume que as FODs são suficientes para que o modelo seja determinado. Isto é válido para histereses simétricas e, portanto, $f_{\alpha\beta'}(T_\alpha^i, T_\beta^i)$ deve obrigatoriamente ser simétrica.
2. Uma possível relação entre os parâmetros p_1 até p_4 devem levar a uma curva cuja amplitude deve estar em torno da metade da amplitude do ciclo externo da histerese. Estes parâmetros possuem uma relação bem visível. Para o caso do VO_2 , pode-se notar pelas curvas 3.5 e 3.8 são praticamente idênticas, portanto pode-se fazer que $p_1 = p_{13}$, $p_2 = p_{14}$, $p_3 = p_{15}$ e $p_4 = p_{16}$ para o caso específico da histerese apresentada aqui. Os resultados apresentados pelas equações (3.10), (3.11), (3.12) e (3.13) sugerem algumas simplificações.

3.5 Conclusão

A identificação do modelo de Preisach foi feita através dos programas desenvolvidos em linguagem C++ usando a biblioteca GALib [10]. Neste capítulo foi demonstrado as dificuldades relacionadas ao uso do procedimento de Mayergoyz. Mesmo com o uso de algoritmos genéticos, a identificação do modelo ainda é difícil e com um custo computacional bastante alto.

As dificuldades associadas aos métodos de otimização tornam o procedimento descrito neste capítulo muito trabalhoso e sujeito a muitos erros.

Será visto mais adiante neste trabalho, que se for possível estabelecer uma função de distribuição $\mu(T_\alpha, T_\beta)$ a priori e estabelecer uma função de mapeamento para que os dados experimentais sejam representados, então não é necessário o uso das FODs para a identificação da histerese e os problemas conceituais a elas relacionadas são contornados, então o procedimento de identificação se resumiria em determinar esta função de mapeamento. O conceito de FODs é muito útil na implementação numérica do modelo, pois permitem que um método de solução numérica alternativo, para a integral de Preisach, seja desenvolvido.

Capítulo 4

Modelo para histereses assimétricas

4.1 Introdução

No capítulo anterior foi apresentado a técnica de identificação do modelo de Preisach para histereses que satisfazem ao teorema da representação, proposta por Mayergoyz. Foram mostrados através de um exemplo, os problemas relacionados com este procedimento, principalmente relacionado às falsas soluções devido a uma escolha inadequada do domínio de busca do algoritmo de otimização ou devido a presença de um mínimo local¹.

Neste capítulo será apresentado um modelo alternativo para histereses que consiste em uma parte com memória representada por uma "histerese ideal" seguido de uma função de mapeamento bidimensional que constitui o componente "sem memória" do modelo. Este modelo dispensa o uso de FODs e a definição de novos operadores. A característica principal do modelo é a sua capacidade de representar histereses assimétricas.

A forma desta função de mapeamento pode ser um problema de solução bastante complicada, mas para tornar a obtenção desta função uma tarefa quase automática, foi usada uma *rede neuronal* como função de mapeamento.

¹Os algoritmos genéticos foram escolhidos por serem algoritmos de convergência global e não existe a necessidade do conhecimento da derivada da função de erro, mas em algumas situações extremas, ele fica preso em mínimos locais quando estes mínimos são relativamente próximos do mínimo global.

4.2 Determinação da histerese ideal

4.2.1 Escolha da histerese ideal

A escolha de uma histerese consiste em determinar uma função de distribuição $\mu(T_\alpha, T_\beta)$ que atenda a algumas propriedades:

1. A função deve ser diferente de zero somente nos limites da triângulo de Preisach, ou seja, esta função somente deve ser diferente de zero se sua excitação $T(t)$ estiver entre $T_{\alpha 0}$ e $T_{\beta 0}$, fora destes limites ela deve ser aproximadamente nula.

$$\lim_{T_\alpha \rightarrow T_{\alpha 0}, T_\beta \rightarrow T_{\beta 0}} \mu(T_\alpha, T_\beta) = 0 \quad (4.1)$$

2. Esta função deve ser simétrica em torno de $\frac{T_{\alpha 0} + T_{\beta 0}}{2}$, ou seja, ela deve satisfazer a propriedade:

$$\mu(T_\alpha, T_\beta) = \mu\left(\frac{T_{\alpha 0} + T_{\beta 0}}{2} - T_\beta, \frac{T_{\alpha 0} + T_{\beta 0}}{2} - T_\alpha\right) \quad (4.2)$$

Qualquer função que satisfaz às condições expressas pelas equações (4.1) e (4.2) pode ser usada como função de distribuição do modelo de Preisach.

Uma histerese escolhida a priori para ser mapeada através de redes neuronais, para representar dados experimentais, é chamada neste trabalho de “*histerese ideal*”. Para tornar mais eficiente o treinamento da rede neuronal, os dados devem passar por uma normalização prévia.

4.2.2 Função de distribuição gaussiana

Um exemplo de função que satisfaz as propriedades apresentadas no item anterior é a função de distribuição gaussiana. A forma geral de uma função gaussiana é dada pela equação (4.3).

$$d(x, y) = \exp(-kx^2 - ky^2) \quad (4.3)$$

Na figura 4.1, pode-se observar que acima de um dado valor de x e de y , a função $d(x, y)$ é aproximadamente nula (ela tende a ser nula). Sua simetria em torno da origem do plano xy pode ser demonstrada usando a condição expressa pela equação (4.2).

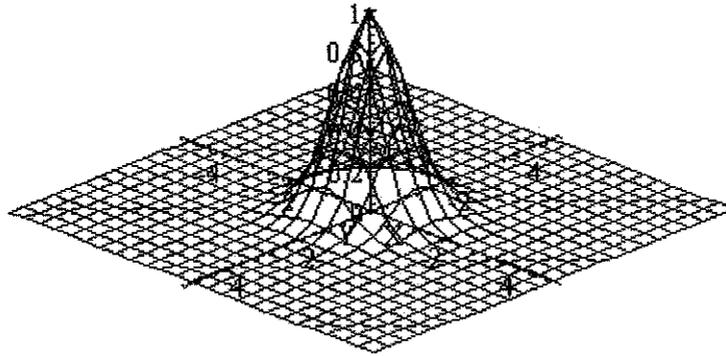


Figura 4.1: Gráfico da função gaussiana

Para demonstrar a simetria da função Gaussiana, pode-se fazer a substituição de x por $-y$ e y por $-x$:

$$d(-y, -x) = \exp(-k(-y)^2 - k(-x)^2) \quad (4.4)$$

$$d(-y, -x) = \exp(-ky^2 - kx^2) = d(x, y) \quad (4.5)$$

Para mudar o centro no plano xy , em torno do qual a gaussiana é simétrica, em uma coordenada (a, b) , a expressão para a gaussiana torna-se como mostrado na equação (4.6):

$$d(x, y) = \exp[-k(x - a)^2 - k(y - b)^2] \quad (4.6)$$

4.2.3 Função gaussiana como função de distribuição

A função gaussiana pode tomar a forma geral dada pela equação (4.7).

$$\mu(T_\alpha, T_\beta) = \exp \left[-k \left(T_\alpha - \frac{T_{\beta 0} + T_{\alpha 0}}{2} \right)^2 - k \left(T_\beta - \frac{T_{\beta 0} + T_{\alpha 0}}{2} \right)^2 \right] \quad (4.7)$$

O coeficiente k deve ser escolhido de acordo com a largura da histerese e para garantir que a função de distribuição será nula quando a excitação for maior que $T_{\beta 0}$ ou menor que $T_{\alpha 0}$. A figura 4.2 mostra uma superfície que representa uma função de distribuição com $T_{\beta 0} = 1$ e $T_{\alpha 0} = 0$ e $k = 50$.

Para tornar o treinamento da rede neuronal mais eficiente, deve-se normalizar a função de distribuição de forma que a histerese por ela definida, quando estiver na saturação superior,

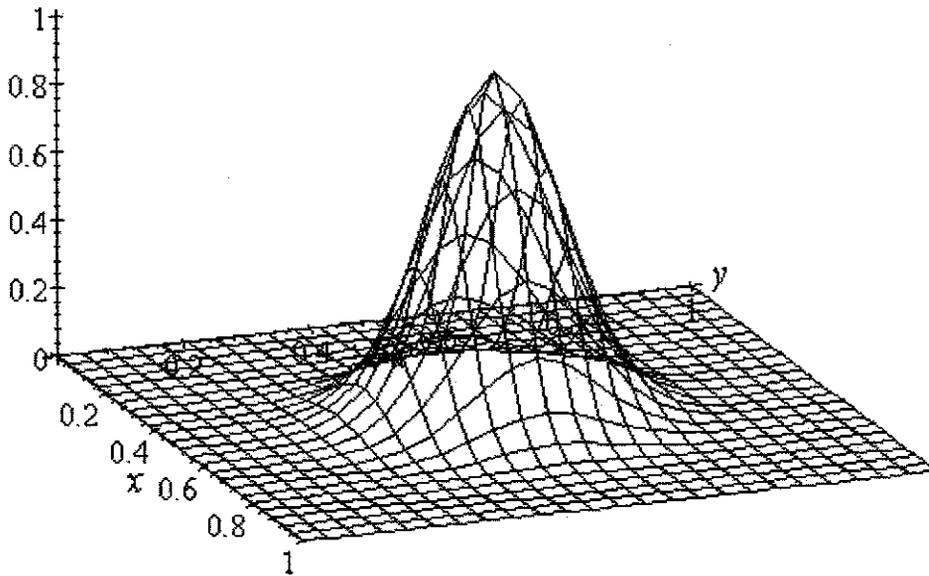


Figura 4.2: Superfície da função de distribuição usada na histerese ideal

assuma um valor unitário. Para isso é preciso determinar o valor de saturação da histerese com uma função de distribuição dada pela equação (4.7), e usar este valor para normalizar a função de distribuição que será usada para implementar a histerese ideal.

A curva de histerese estará na região de saturação superior quando a região S_1 ocupar todo o triângulo da figura 4.3, portanto, para calcular o valor de saturação da histerese, a integral de Preisach deve ser calculada no triângulo \overline{ABC} , que é numericamente igual à metade do cálculo desta integral feita no quadrado \overline{ABCD} , desta forma, a saturação superior desta histerese é:

$$f_{sat+} = \frac{1}{2} \int_0^1 \left\{ \int_0^1 \left\{ \exp \left[-k \left(T_\alpha - \frac{1}{2} \right)^2 - k \left(T_\beta - \frac{1}{2} \right)^2 \right] \right\} dT_\alpha \right\} dT_\beta = \frac{1}{2} \operatorname{erf}^2 \left(\frac{1}{2} \sqrt{k} \right) \frac{\pi}{k}$$

Uma vez que se deseja que a saturação superior da histerese seja 1, então a função de distribuição que se necessita será dada por:

$$\mu(T_\alpha, T_\beta) = 2k \frac{\exp \left[-k \left(T_\alpha - \frac{1}{2} \right)^2 - k \left(T_\beta - \frac{1}{2} \right)^2 \right]}{\operatorname{erf}^2 \left(\frac{1}{2} \sqrt{k} \right) \pi} \quad (4.8)$$

4.2.4 Interpretação geométrica

Supondo que a excitação $T(t)$ esteja diminuindo, então a divisão do triângulo de Preisach torna-se como indicado pela figura 4.4.

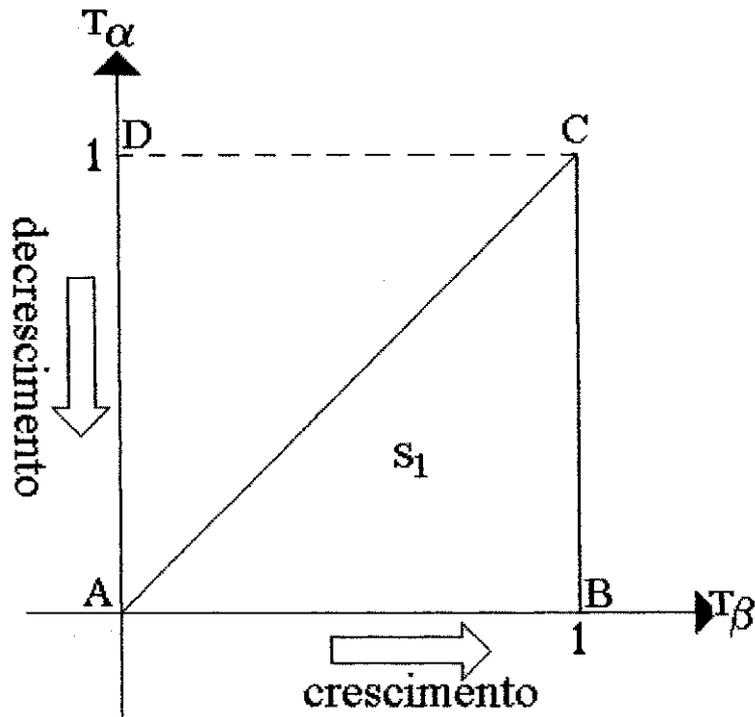


Figura 4.3: Triângulo de Preisach para o VO_2

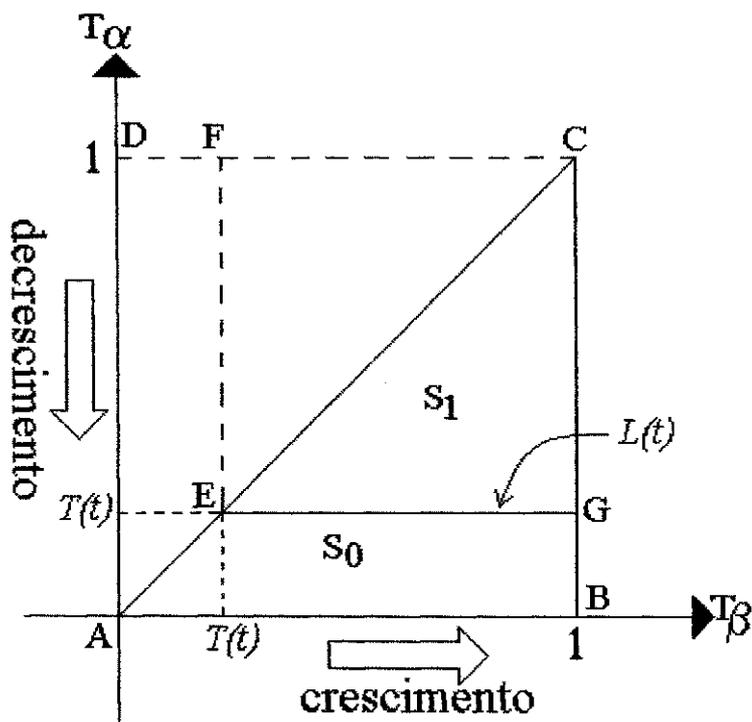


Figura 4.4: Excitação decrescendo de 1 para $T(t)$

A excitação aplicada ao dispositivo vai fazer com que a grandeza calculada pelo modelo percorra uma trajetória que corresponde a integração sobre a área S_1 que corresponde a metade da área do quadrado descrito por \overline{EFCG} na figura 4.4. Resolvendo esta integral para $T(t)$ obtêm-se a equação (4.9) cuja curva correspondente é mostrada na figura 4.5.

$$f(t) = \frac{1}{2} \int_{T(t)}^1 \left\{ \int_{T(t)}^1 \left\{ 2k \frac{\exp \left[-k \left(T_\alpha - \frac{1}{2} \right)^2 - k \left(T_\beta - \frac{1}{2} \right)^2 \right]}{\text{erf}^2 \left(\frac{1}{2} \sqrt{k} \right) \pi} \right\} dT_\alpha \right\} dT_\beta$$

$$f(t) = \frac{1}{4} \frac{\left[\text{erf} \left(\frac{1}{2} \sqrt{k} \right) - \text{erf} \left(T(t) \sqrt{k} - \frac{1}{2} \sqrt{k} \right) \right]^2}{\text{erf}^2 \left(\frac{1}{2} \sqrt{k} \right)} \quad (4.9)$$

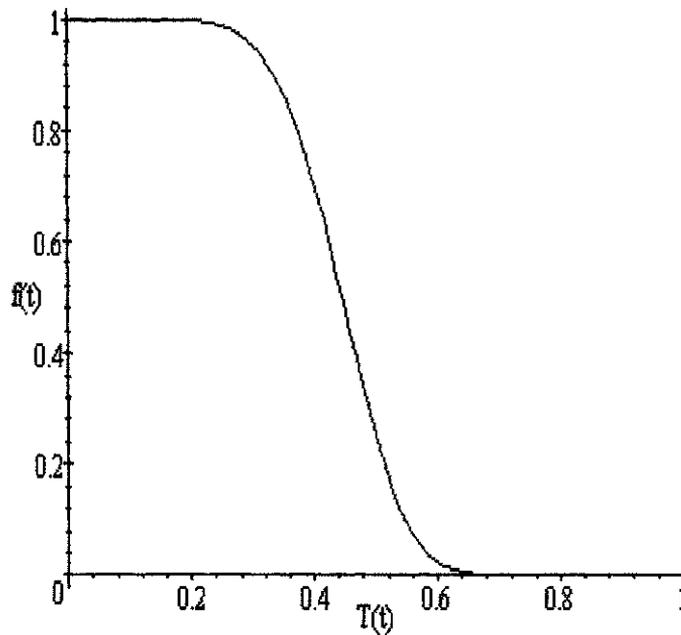


Figura 4.5: Excitação decrescendo partindo do estado de saturação inferior para 0

Considerando agora que a excitação $T(t)$ atinja o valor nulo e sofra uma reversão e começa a crescer, o triângulo de Preisach torna-se como indicado na figura 4.6.

Através da figura 4.6, observa-se que a área onde a integração será feita corresponde a diferença entre o valor de saturação (que corresponde a integração sobre todo o triângulo de Preisach) e a área do triângulo \overline{ABC} , desta forma, a curva que será descrita pela equação (4.10), e é mostrada na figura 4.7.

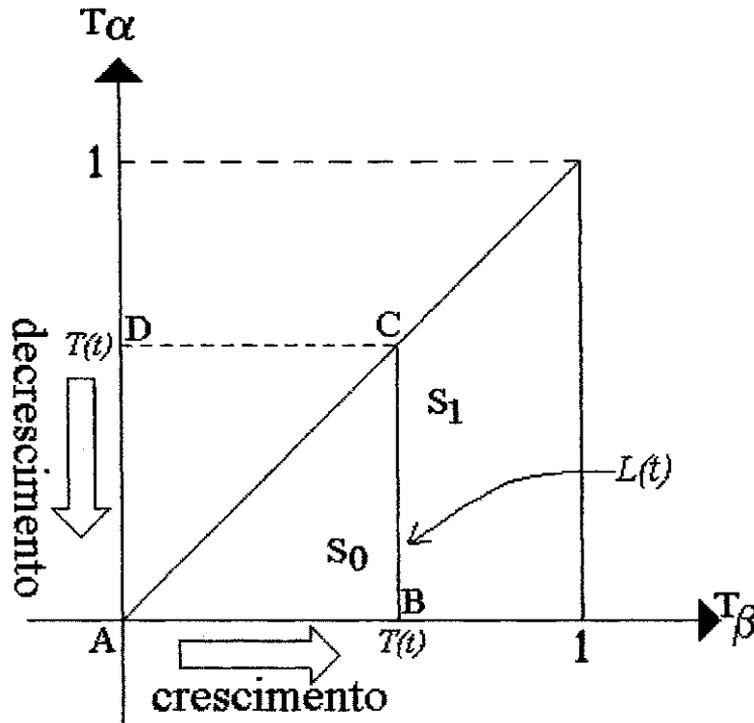


Figura 4.6: Excitação decrescendo de 0 para $T(t)$

$$f(t) = 1 - \frac{1}{2} \int_0^{T(t)} \left\{ \int_0^{T(t)} \left\{ 2k \frac{\exp \left[-k \left(T_\alpha - \frac{1}{2} \right)^2 - k \left(T_\beta - \frac{1}{2} \right)^2 \right]}{\operatorname{erf}^2 \left(\frac{1}{2} \sqrt{k} \right) \pi} \right\} dT_\alpha \right\} dT_\beta$$

$$f(t) = 1 - \frac{1}{4} \frac{\left[\operatorname{erf} \left(T(t) \sqrt{k} - \frac{1}{2} \sqrt{k} \right) + \operatorname{erf} \left(\frac{1}{2} \sqrt{k} \right) \right]^2}{\operatorname{erf}^2 \left(\frac{1}{2} \sqrt{k} \right)} \quad (4.10)$$

Na figura 4.8, são mostradas as duas curvas correspondentes às equações 4.9 e 4.10, respectivamente, que vão formar o ciclo externo da histerese.

4.2.5 Curvas decrescentes de primeira ordem

A figura 4.9, define a área no triângulo de Preisach quando a excitação diminui do estado de saturação superior de 1 até T_α e em seguida vai aumentando de T_β até atingir a saturação inferior 1. A curva decrescente de primeira ordem é obtida através da solução da integral de Preisach na área S_1 ($f(T_\alpha, T_\beta)$).

Observando a figura 4.9, pode-se determinar que uma expressão para a FOD desta histerese, corresponde a área S_1 é dada por:

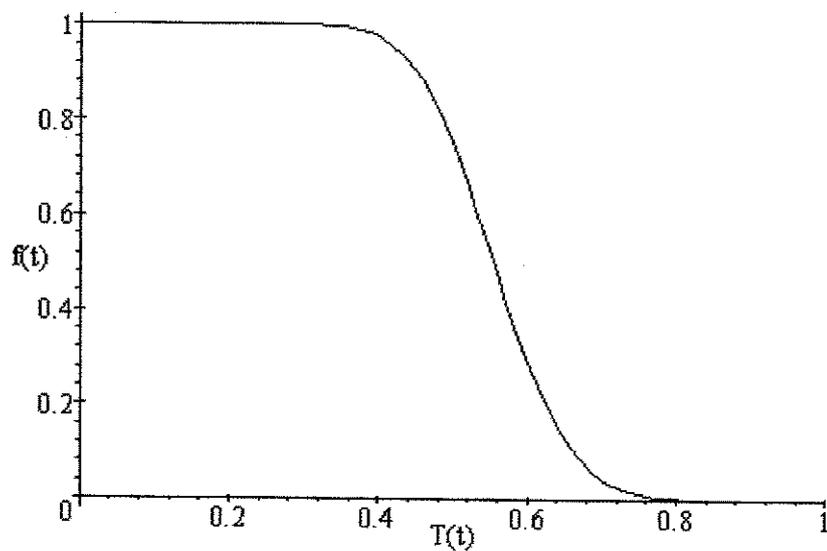


Figura 4.7: Excitação crescendo partindo de do estado de saturação superior

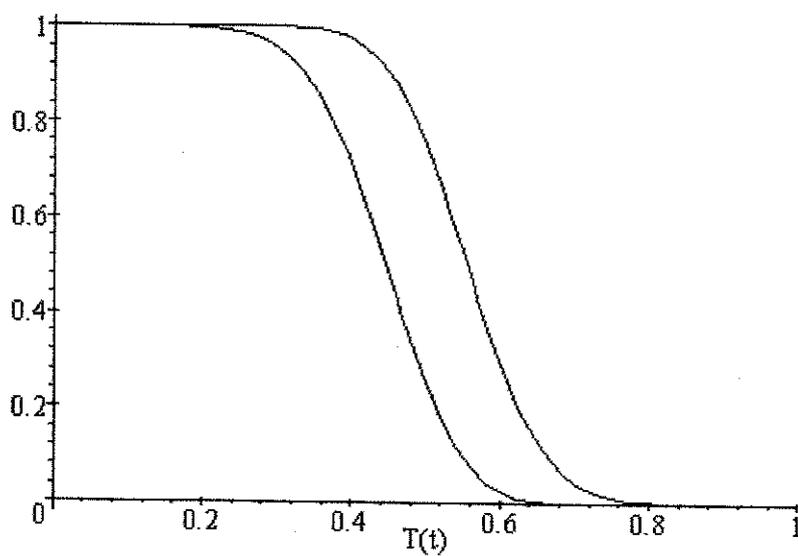


Figura 4.8: Ciclo externo da histerese descrita por uma função de distribuição Gaussiana

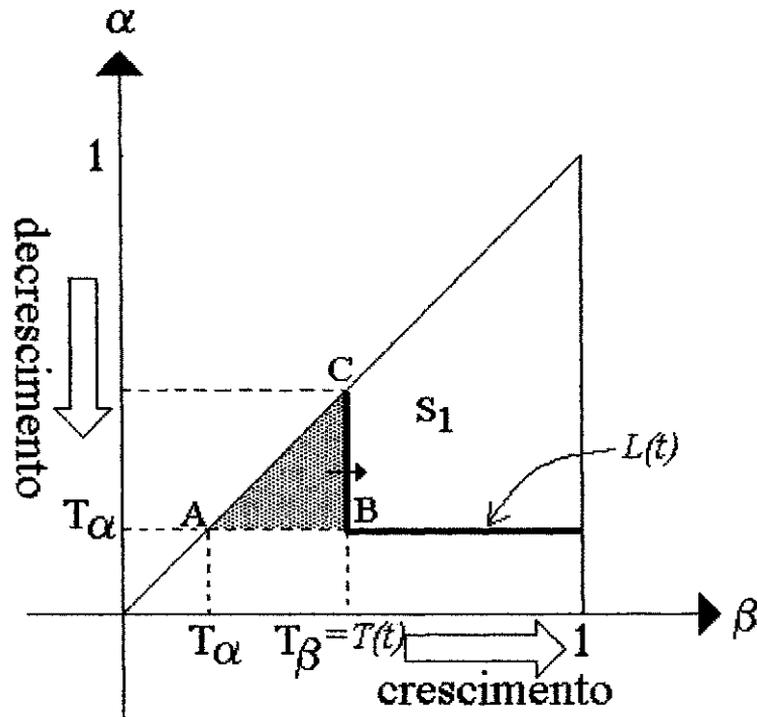


Figura 4.9: Configuração do triângulo correspondente a uma FOD

$$f_{\alpha'\beta'}(T_\alpha, T_\beta) = \frac{1}{2} \int_{T_\alpha}^1 \int_{T_\alpha}^1 \mu(\alpha, \beta) d\alpha d\beta - \frac{1}{2} \int_{T_\alpha}^{T_\beta} \int_{T_\alpha}^{T_\beta} \mu(\alpha, \beta) d\alpha d\beta \quad (4.11)$$

$$f_{\alpha'\beta'}(T_\alpha, T_\beta) = \frac{1}{2} \int_{T_\alpha}^1 \left\{ \int_{T_\alpha}^1 \left\{ 2k \frac{\exp[-k(\alpha-\frac{1}{2})^2 - k(\beta-\frac{1}{2})^2]}{\text{erf}^2(\frac{1}{2}\sqrt{k})\pi} \right\} d\alpha \right\} d\beta - \frac{1}{2} \int_{T_\alpha}^{T_\beta} \left\{ \int_{T_\alpha}^{T_\beta} \left\{ 2k \frac{\exp[-k(\alpha-\frac{1}{2})^2 - k(\beta-\frac{1}{2})^2]}{\text{erf}^2(\frac{1}{2}\sqrt{k})\pi} \right\} d\alpha \right\} d\beta$$

$$f_{\alpha'\beta'}(T_\alpha, T_\beta) = \frac{\frac{1}{4} \left[-\text{erf}(\frac{1}{2}\sqrt{k}) + \text{erf}(T_\alpha\sqrt{k} - \frac{1}{2}\sqrt{k}) \right]^2}{\text{erf}^2(\frac{1}{2}\sqrt{k})} - \frac{\frac{1}{4} \left[-\text{erf}(T_\beta\sqrt{k} - \frac{1}{2}\sqrt{k}) + \text{erf}(T_\alpha\sqrt{k} - \frac{1}{2}\sqrt{k}) \right]^2}{\text{erf}^2(\frac{1}{2}\sqrt{k})} \quad (4.12)$$

A equação (4.12), implementa as FODs da histerese ideal. Com esta equação, pode-se implementar numericamente o modelo de Preisach.

4.2.6 Implementação numérica

Variação no número de operadores elementares

O triângulo sombreado mostrado na figura 4.9, é responsável por incrementar ou decrementar o número de operadores elementares no estado 1, e que corresponde a integral:

$$F(T_\alpha, T_\beta) = \frac{1}{2} \int_{T_\alpha}^{T_\beta} \int_{T_\alpha}^{T_\beta} \mu(\alpha, \beta) d\alpha d\beta \quad (4.13)$$

Supondo agora que se disponha de $f_{\alpha'\beta'}(T_\alpha, T_\beta)$, então a área sobreada corresponde a:

$$F(T_\alpha, T_\beta) = \frac{1}{2} \int_{T_\alpha}^{T_\beta} \int_{T_\alpha}^{T_\beta} \mu(\alpha, \beta) d\alpha d\beta = \frac{1}{2} \int_{T_\alpha}^1 \int_{T_\alpha}^1 \mu(\alpha, \beta) d\alpha d\beta - f_{\alpha'\beta'}(T_\alpha, T_\beta) \quad (4.14)$$

Pode-se demonstrar que:

$$\frac{1}{2} \int_{T_\alpha}^1 \int_{T_\alpha}^1 \mu(\alpha, \beta) d\alpha d\beta = f_{\alpha'\beta'}(T_\alpha, T_\alpha) \quad (4.15)$$

Portando, a equação que representa o incremento (quando a excitação está monotonicamente decrescente) ou decremento (quando a excitação está monotonicamente crescente), é dada pela expressão (4.16).

$$F(T_\alpha, T_\beta) = f_{\alpha'\beta'}(T_\alpha, T_\alpha) - f_{\alpha'\beta'}(T_\alpha, T_\beta) \quad (4.16)$$

Pode-se agora definir as equações que implementam o modelo de Preisach.

Excitação decrescente

Quando a excitação está decrescendo, o número de operadores elementares é acrescido de $F(T_\alpha, T_\beta)$, então a equação que implementa o modelo será dada por:

$$f(t) = f_{k-1} + F(T_\alpha, T_\beta) = f_{k-1} + f_{\alpha'\beta'}(T_\alpha, T_\alpha) - f_{\alpha'\beta'}(T_\alpha, T_\beta) \quad (4.17)$$

onde

- O valor de saída do modelo no instante de reversão é f_{k-1} ;
- Valor da excitação no instante da reversão: $T_\beta = T_{k-1}$;
- Valor da excitação atual: $T_\alpha = T(t)$.

Pode-se agora colocar a equação em função dos valores da excitação e da saída do modelo:

$$f[T(t)] = f_{k-1} + f_{\alpha'\beta'}[T(t), T(t)] - f_{\alpha'\beta'}[T(t), T_{k-1}] \quad (4.18)$$

Excitação crescente

Quando a excitação está crescendo, o número de operadores elementares é diminuído de $F(T_\alpha, T_\beta)$, então a equação que implementa o modelo será dada por:

$$f [T (t)] = f_{k-1} - F (T_\alpha, T_\beta) = f_{k-1} - f_{\alpha' \beta'} (T_\alpha, T_\alpha) + f_{\alpha' \beta'} (T_\alpha, T_\beta) \quad (4.19)$$

onde

- O valor de saída do modelo no instante de reversão é f_{k-1} ;
- Valor da excitação no instante da reversão: $T_\alpha = T_{k-1}$;
- Valor da excitação atual: $T_\beta = T (t)$.

$$f [T (t)] = f_{k-1} - f_{\alpha' \beta'} (T_{k-1}, T_{k-1}) + f_{\alpha' \beta'} [T_{k-1}, T (t)] \quad (4.20)$$

4.3 Uso de redes neuronais no mapeamento de histereses

4.3.1 Estrutura do modelo

A rede neuronal juntamente com o modelo de uma histerese simétrica vai constituir um modelo para uma histerese assimétrica obtida experimentalmente.

A configuração do modelo é ilustrado na figura 4.10. A partir da figura nota-se que a rede neuronal possui duas entradas: a variável dependente vinda do modelo da histerese simétrica e a variável independente e possui uma única saída onde é obtido a grandeza medida.

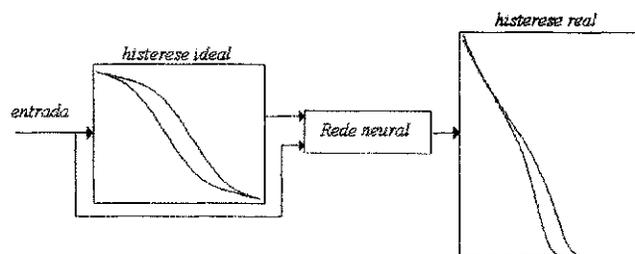


Figura 4.10: Modelo para histerese não simétrica

4.3.2 Treinamento da rede neuronal

A rede neuronal usada neste trabalho usa como função de ativação uma signoide. Para que a rede neuronal tenha um aprendizado mais rápido, o módulo da saída da histerese ideal não pode ultrapassar o valor unitário, assim como os dados experimentais e a variável independente. Portanto, antes da obtenção da rede neuronal de mapeamento é necessário que os dados experimentais sejam normalizados e o modelo resultante deve sofrer uma pequena alteração com relação ao modelo original mostrado na figura 4.10. Através da fig. 4.11, é mostrado como é o modelo.

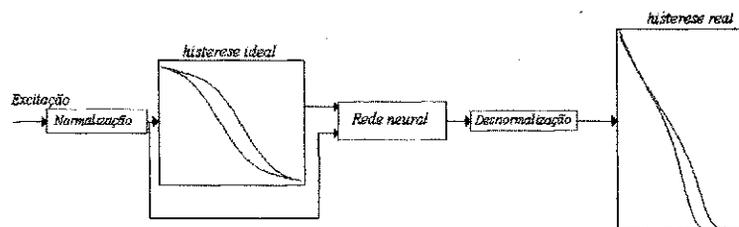


Figura 4.11: Modelo modificado para que a rede neuronal trabalhe com valores normalizados entre -1 e 1

A identificação é feita como demonstrado pelo diagrama da fig. 4.12.

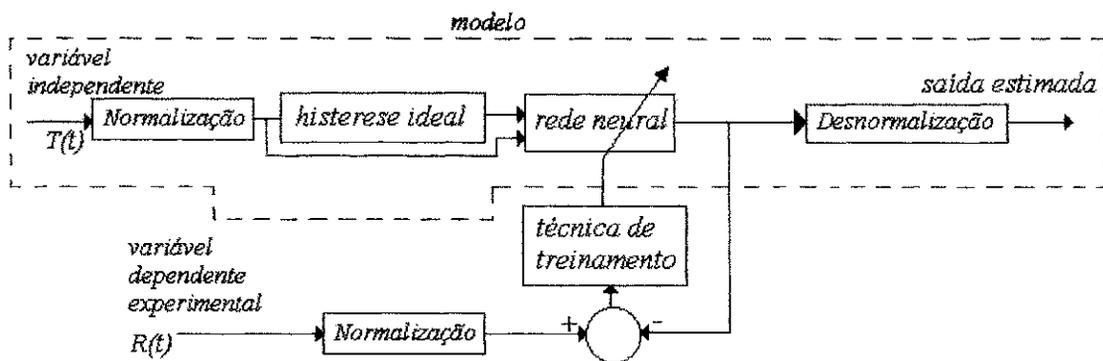


Figura 4.12: Identificação do modelo de histerese qualquer

O treinamento da rede neuronal deve ser feita de tal forma que ela generalize todas as características das histereses, assim pode-se colocar nos padrões de treinamento os laços internos, ciclo maior, ciclos menores, etc. para que a função de mapeamento represente todas as características peculiares de uma dada histerese.

Os resultados apresentados neste trabalho referem-se ao uso das FODs como padrão de treinamento, mas, mesmo usando apenas FODs, os resultados foram bons, ver a fig. 4.13.

A histerese experimental que se deseja modelar é mostrada na da fig. 4.14.

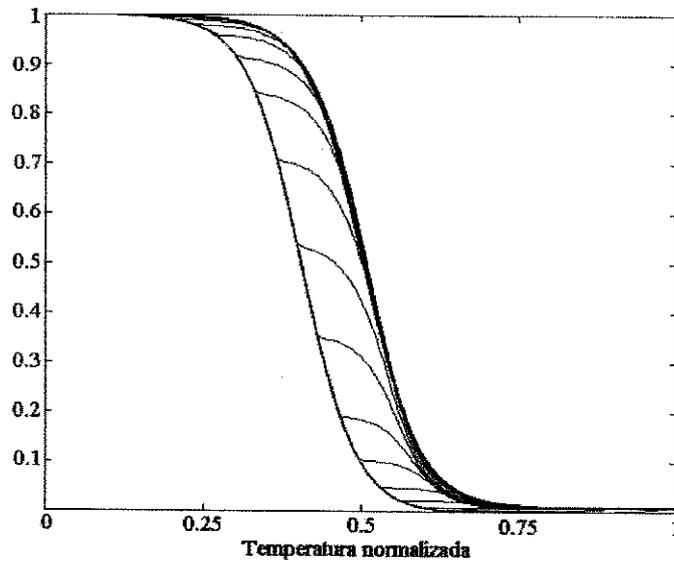


Figura 4.13: Curvas usadas no treinamento da rede neural

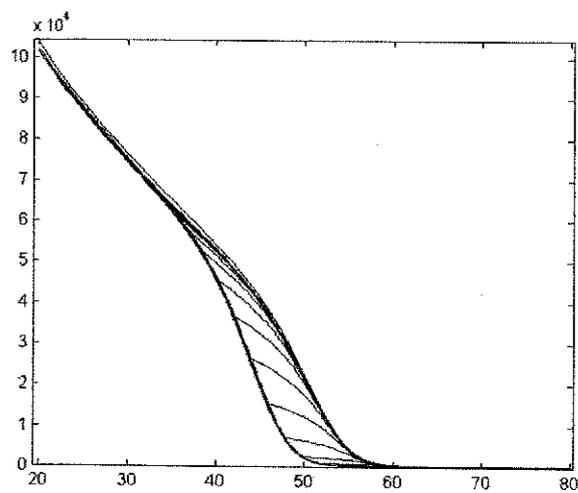


Figura 4.14: Histerese assimétrica obtida experimentalmente

4.3.3 Resultados obtidos

O treinamento da rede neuronal é um processamento bastante exigente dos recursos computacionais disponíveis. Um tempo para o treinamento típico é de vinte quatro horas. Através do gráfico na figura 4.15, é mostrado a evolução do erro quadrático para as primeiras épocas de treinamento, quando o treinamento estava sendo feito usando a toolbox de redes neurais do Matlab 5.0.

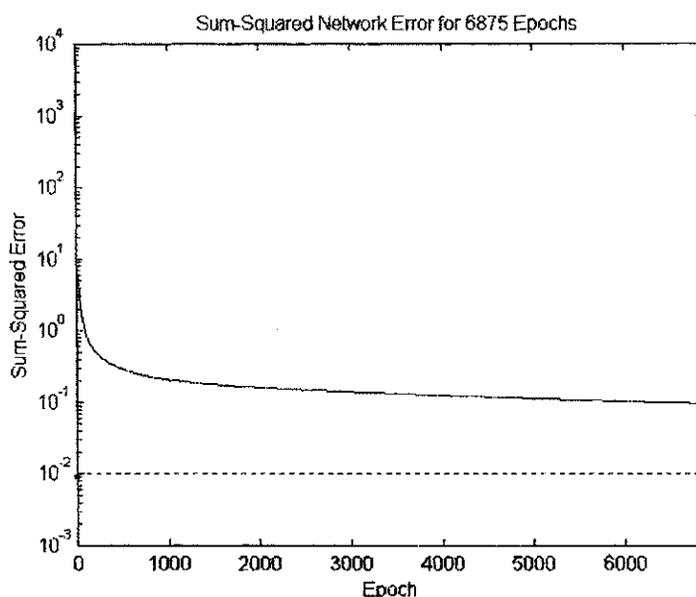


Figura 4.15: Evolução do erro médio quadrático

Esta curva corresponde a uma rede feedforward com 10 neurônios nas suas duas camadas escondidas e um neurônio na sua camada de saída (2+10+10+1), foi empregado uma taxa de aprendizado $\eta = 0,0008$.

Através da figura 4.16, é mostrado uma comparação entre os dados experimentais e o estimado pelo modelo, onde pode-se notar que existe ainda uma pequena discrepância nas baixas temperaturas e que as FOAs ainda não concordam perfeitamente, mas estes problemas podem ser eliminados com mais tempo de treinamento.

Para constatar que o modelo realmente consegue representar a histerese experimental, outro experimento foi feito. Este experimento consiste em verificar se os ciclos internos do modelo correspondem ao experimental.

Pode-se notar pela figura 4.17, os ciclos internos do modelo ainda ficaram distantes dos experimentais. Este resultado sugere que deve ser feito treinamento da rede incluindo laços internos. Como pode-se ver, o modelo obtido foi razoavelmente bem sucedido e já pode ser usado na simulação de situações práticas.

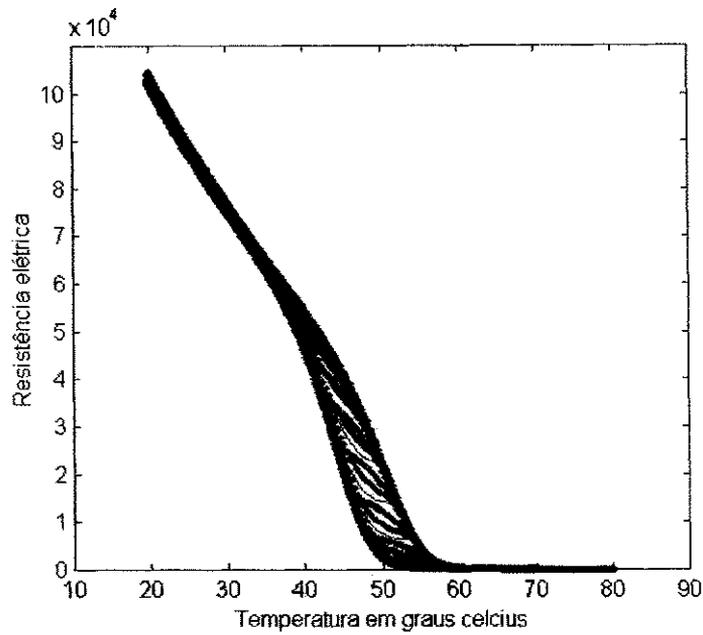


Figura 4.16: Resultado apresentado pelo modelo. Em pontilhado os dados experimentais, em contínuo o estimado

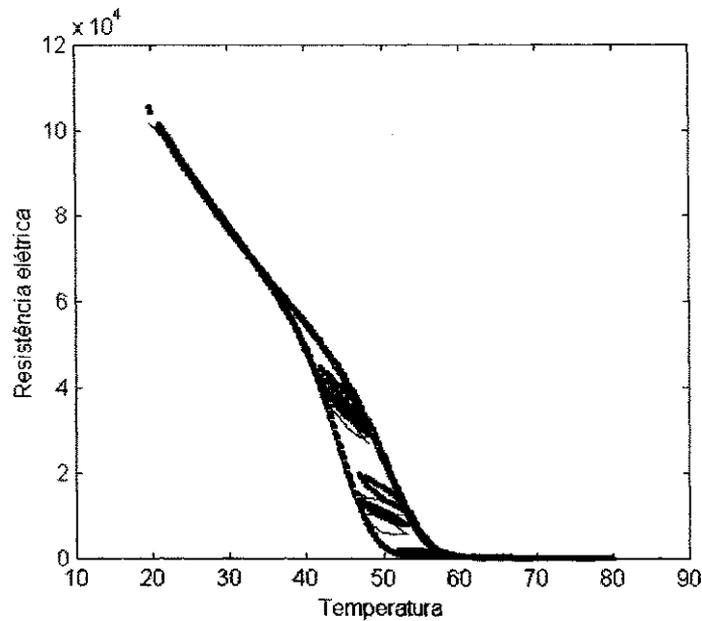


Figura 4.17: Comparação entre os ciclos internos gerados pelo modelo e os obtidos em experimentos. Em pontilhado, dados experimentais, em contínuo, estimado pelo modelo

4.4 Conclusão

Foi visto neste capítulo que é possível obter a partir de uma histerese simétrica uma histerese assimétrica obtida a partir de algum experimento.

A metodologia apresentada neste capítulo se aplica a qualquer histerese obtida experimentalmente.

O custo computacional de treinamento de uma rede neuronal para fazer o mapeamento é grande, mas uma vez treinada, a implementação do modelo é muito eficiente computacionalmente. Em algumas aplicações onde a histerese é muito assimétrica e não há modelos disponíveis, o custo computacional do treinamento da rede é justificado.

Esta técnica de adaptação do modelo de Preisach para representar histereses assimétricas ainda está no começo do seu desenvolvimento, para o caso do $\dot{V}O_2$, este modelo foi bem sucedido, mas para validar este modelo é necessário que novos dispositivos tenham suas curvas de histerese representadas por ele.

Capítulo 5

Conclusão

5.1 Conclusões

O modelo de Preisach é um modelo matemático e não está relacionado a nenhum fenômeno particular, segundo a interpretação de Krasnoselskii [8], que interpreta este modelo como um ente matemático, isto dá um carácter genérico ao modelo de Preisach.

Foi demonstrado também neste trabalho, que uma histerese para ser representada pelo modelo de Preisach precisa que algumas propriedades sejam satisfeitas, de maneira que existe uma limitação bem definida para as histereses que o modelo pode representar [9].

A generalidade do modelo têm um custo bastante alto: a dificuldade em aplicá-lo, até mesmo em histereses que obedecem ao teorema da representação, isto é outro fator (além do teorema da representação) que limita o uso do modelo. Portanto, este trabalho tratou de dois pontos importantes que limitam o uso do modelo de Preisach:

1. A dificuldade de implementação numérica e identificação, o que resulta em um modelo de aplicação bastante difícil;
2. O teorema da representação que limita o uso do modelo às histereses simétricas.

5.1.1 As dificuldades de aplicação

Pode-se definir dois aspectos referentes a dificuldade de aplicação do modelo: sua implementação numérica e sua identificação.

A implementação numérica, apresentada por Mayergoyz, apresenta o inconveniente de usar os próprios dados experimentais para interpolar a saída do modelo, portanto, os experimentos para sua identificação devem ser feitos com cuidados extremos, de maneira a evitar a presença

de ruídos. O uso de técnicas de interpolação, tornam a implementação do modelo computacionalmente pouco eficiente e tornava bastante complicado, o uso do modelo, na solução das equações diferenciais que descrevem o comportamento de um sistema físico dinâmico onde uma curva de histerese estivesse inserida.

Foi mostrado, no do capítulo 2, uma interpretação do modelo um pouco diferente da interpretação feita por Mayergoysz, e foi baseada no trabalho apresentado em [1]. Esta interpretação permitiu a obtenção de duas equações algébricas recursivas extremamente simples que resolvem numericamente a integral de Preisach. Com a obtenção destas equações, a implementação numérica e a identificação tornam-se tópicos claramente independentes.

A identificação do modelo de Preisach torna-se, então, o procedimento de encontrar uma expressão para $f_{\alpha'\beta'}(T_\alpha, T_\beta)$, um problema tipicamente de otimização não linear multidimensional, que foi tratado no capítulo 3. Foi proposta usar uma expressão para $f_{\alpha'\beta'}(T_\alpha, T_\beta)$ bastante complexa que necessitava de dezesseis parâmetros a serem identificados. Na primeira parte do capítulo 4, foi demonstrado o uso de uma função de distribuição determinada a priori para gerar uma histerese ideal para que seja mapeada para representar os dados experimentais.

5.1.2 Limitação do modelo à histereses simétricas

É enfatizado nos capítulos 2 e 3, que o modelo de Preisach está limitado às histereses simétricas. Esta limitação está diretamente relacionada à propriedade da congruência. A simetria ajuda a simplificar a identificação e implementação numérica do modelo, como é demonstrado neste trabalho, mas limita bastante o uso do modelo.

No capítulo 4, a idéia da assimetrização de um histerese simétrica que satisfaz ao teorema da representação, foi apresentada. Neste capítulo algumas considerações são feitas para a obtenção de histereses simétricas e a seguir é mostrado o uso de uma rede neuronal como função de assimetrização de uma histerese simétrica, tida como ideal. O mapeamento de uma histerese simétrica em uma histerese assimétrica qualquer obtida experimentalmente, teve um relativo sucesso, para o caso em estudo (VO_2).

5.2 Proposta de novos trabalhos

O estudo de histereses é um assunto bastante extenso e está na pauta de muitos grupos de pesquisa tanto na área de física quanto de engenharia. Este trabalho faz apenas algumas propostas bem específicas sobre o assunto e representa apenas uma parte de uma linha de pesquisa mais ampla do grupo de Instrumentação Eletrônica. O estudo de materiais usados

como sensores é uma linha de pesquisa bastante importante do grupo e dela são derivadas outras linhas. Devido ao interesse por sensores com transição de fase e com histereses em sua característica RxT , surgiu o interesse em estudar modelos de histereses.

Uma limitação do trabalho é que ele não leva em consideração o fenômeno de acomodação da histerese, este fenômeno leva a histerese a ter sua forma dependente da taxa de variação da entrada [4]. A dependência com a taxa de variação da excitação pode levar a histerese a um estado de caos, onde a previsão do comportamento da histerese é difícil [2].

Portanto, pode-se definir alguns trabalhos futuros:

1. Estudo sistemático sobre as condições de escolha das curvas de histerese ideais;
2. Generalização escalar do modelo;
3. Dependência com a taxa de variação da excitação (modelo dinâmico).

Apêndice A

Introdução aos algoritmos genéticos e redes neuronais

A.1 Algoritmos genéticos

A.1.1 Definição de algoritmos genéticos

Os métodos baseados em gradientes são muito susceptíveis a mínimos locais, por isso o ponto onde a busca vai iniciar deve estar bem próximo da solução ótima. Algoritmos que buscam a solução global do problema de otimização independentemente de estar próxima ou distante da solução ótima, são chamados métodos globalmente convergente. Os algoritmos genéticos são uma classe métodos de otimização globalmente convergentes, e não necessitam do conhecimento da derivada da função de custo e sua busca é feita em um conjunto de possíveis soluções candidatas. Os métodos tradicionais são iniciados com um valor aleatório muito próximo da solução ótima e os cálculos são feitos afim de que a solução inicial seja atualizada até que uma solução ótima seja encontrada, pode-se dizer que estes algoritmos fazem uma busca em linha, eles seguem um único caminho que pode ou não chegar à solução ótima. Os algoritmos genéticos fazem uma busca em todo o universo de possíveis soluções candidatas, assim deve-se informar ao algoritmo os limites de variação de cada um dos parâmetros, pode-se dizer que os algoritmos genéticos fazem sua busca aos saltos, percorrendo diferentes caminhos, tornando, portanto, a probabilidade de ficar preso em um mínimo local seja muito pequena. A desvantagem do algoritmos genéticos é a sua ineficiência em termos computacionais. Os algoritmos genéticos foram inspirados no mecanismo de evolução natural dos seres vivos, onde só os indivíduos que conseguem adaptar-se ao ambiente vão conseguir sobreviver.

A.1.2 O Algoritmo

Introdução aos algoritmos genéticos

Para uma espécie continuar existindo na natureza, é necessário que os indivíduos desta espécie, sofram adaptações às possíveis alterações do meio ambiente onde vivem, daí a necessidade da evolução desta espécie. Na teoria evolucionária dos seres vivos, existem duas formas básicas de uma espécie evoluir: através de mutação genética e a reprodução.

Segunda esta teoria, a evolução pode ocorrer por mutações no código genético dos seres vivos (nas cadeias de DNA). Para cada característica de um ser vivo, existe um gene específico. Quando ocorre uma mudança climática, por exemplo, somente os indivíduos que sofreram mutações em seu código genético, que os adaptem a nova situação, é que conseguirão sobreviver e se reproduzir, os outros, fatalmente, serão extintos.

Outra forma de evolução é aquela resultante da reprodução entre dois indivíduos que vão gerar novos indivíduos com características herdadas dos pais. Para evitar que a espécie pare de evoluir, é preferível que a reprodução seja entre indivíduos que não tenham parentesco para que seja mantido a diversidade, que constitui em um elemento primordial na evolução.

A terminologia usada nos algoritmos genéticos são também oriundas da teoria evolucionária dos seres vivos. A partir da exposição anterior, pode-se definir vários conceitos. Chama-se de “população” ao conjunto de indivíduos de mesma espécie, nos algoritmos genéticos, uma “população” é um conjunto de “soluções candidatas”. Define-se ainda dois operadores: um operador que indica a “mutação” e outro operador que indica a “reprodução”. Estes são os dois operadores básicos dos algoritmos genéticos. Quando há a “reprodução”, uma nova população é formada a partir da população anterior. Cada nova população constitui uma nova “geração”.

Cada indivíduo é uma solução candidata do problema de otimização, desta forma, uma população é um conjunto de soluções candidatas que podem ou não estar próximas da solução ótima. Portanto, basicamente, o algoritmo deverá definir quais os indivíduos vão sobreviver para, em seguida, reproduzam-se e/ou sofrer mutação para que seja gerada uma nova população e o algoritmo passe para uma nova geração.

Pode-se definir os componentes do algoritmo genético, como apresentados na tabela A.1.

O algoritmo genético pode ser representado da seguinte forma [7]:

- (1) Fornecer uma população inicial P_0 de N indivíduos.
- (2) $i \leftarrow 1$
- (3) $P'_i \leftarrow SelectionFunction(P_{i-1})$
- (4) $P_i \leftarrow ReproductionFunction(P'_i)$
- (5) $J = evaluate(P_i)$

EVOLUÇÃO GENÉTICA	PROBLEMA COMPUTACIONAL
Indivíduo	Solução de um problema
População	Conjunto de soluções
Ajustamento	Qualidade de uma solução
Cromossomo	Representação de uma solução
Gene	Parte da representação de uma solução
Reprodução e Mutação	Operadores de Busca

Tabela A.1: Componentes do algoritmo genético

(6) $i \leftarrow i + 1$

(7) Repetir os passos a partir do 3 até a condição de terminação, baseada no valor de J , seja satisfeita.

(8) Imprimir os melhores resultados

Representação dos indivíduos

Cada indivíduo (ou solução candidata) do problema, é chamado de “*cromossomo*”, que deve ter uma representação bem definida. A forma como os cromossomos serão representados vai determinar a estrutura do algoritmo genético e como seus operadores vão ser usados [7].

Cada solução, ou “*cromossomo*”, é descrito por uma seqüência de “*genes*” provenientes de um dado alfabeto. Um alfabeto pode ser constituído por bits 1 e 0, por letras, números inteiros, números em ponto flutuante, símbolos, matrizes, etc. O primeiro algoritmo genético construído, usava como alfabeto dígitos binários [5]. A representação dos “*cromossomos*” têm sido objeto de um estudo bastante intenso. Têm sido demonstrado que as representações mais naturais são, geralmente, as mais eficientes e produzem melhores resultados [7]. Para uso em aplicações de otimização numérica, umas das mais poderosas representações é o alfabeto constituído de valores em ponto flutuante, com valores dentro de limites bem estabelecidos [5]. Michalewicz [7] fez experimentos extensivos onde eram comparados várias formas de representação dos cromossomos e conseguiu demonstrar que os algoritmos genéticos que usam a representação em ponto flutuante dos genes, possuem uma eficiência superior a uma ordem de grandeza em relação às outras representações, em termos de tempo de processamento de CPU (tempo em que o microprocessador do computador fica ocupado). Michalewicz demonstra também que esta representação leva a uma solução mais precisa e mais coerente.

Função de seleção (SelectionFunction)

Na natureza só os indivíduos mais adaptados ao ambiente é que vão sobreviver. Nos algoritmos genéticos, somente os indivíduos que a “*Função de seleção (SelectionFunction)*” permitirão estar presentes na geração que se está formando. A função de seleção é fundamental ao algoritmo. Vários algoritmos de seleção são mostrados na referência [5]. Esta seleção pode ser feita através de uma relação probabilística associada ao ajuste da solução que está sendo submetida à função.

Um critério de seleção muito usado é atribuir a cada indivíduo uma probabilidade de seleção, P_j baseado no ajuste (*fitness*) de cada indivíduo j . No algoritmo, uma série U de N indivíduos aleatórios são gerados e são comparados à probabilidade cumulativa, $C_i = \sum_{j=1}^i P_j$, da população. Um indivíduo é selecionado para fazer parte da nova população se e somente se $C_{i-1} < U(i) \leq C_i$.

Holland [6], desenvolveu o primeiro método de seleção, que ele chamou de “*roulette wheel*”, cuja tradução aproximada seria de “*método da roleta russa*”. A probabilidade de cada indivíduo ser selecionado para a próxima geração P_i é dado pela expressão:

$$P_i = \frac{F_i}{\sum_{j=1}^{TamPop} F_j} \quad (A.1)$$

onde F_i é o ajuste (*fitness*) do indivíduo i . O método da roleta russa é destinado a maximização da função de custo, portanto, para que o algoritmo genético faça a minimização, deve-se fazer um escalonamento desta função, uma solução simples seria fazer com que a função de custo usada pelo algoritmo seja a função de custo que se deseja minimizar multiplicado por menos um, a outra solução seria o uso da expressão $1 - P_i$ para o cálculo da probabilidade de seleção, onde P_i é dado pela expressão A.1.

Em [7] é proposto a expressão A.2

$$P_i = q'(1 - q)^{r-1} \quad (A.2)$$

onde:

q é a probabilidade de seleção do melhor indivíduo;

r é o rank do indivíduo (o melhor possui $r = 1$);

$$q' = \frac{q}{1 - (1 - q)^2}$$

Quanto ao critério de seleção de indivíduos a determinação dos parâmetros de seleção é mais ligado à natureza do problema tratado. Desta forma, a escolha do método deve ser avaliado tendo sempre em foco o problema específico em questão, portanto vários métodos têm sido propostos para diferentes tipos de problemas.

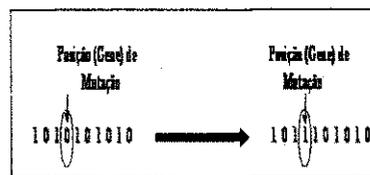


Figura A.1: Exemplo de mutação binária

Operadores genéticos

Os operadores genéticos fornecem os mecanismos básicos para o funcionamento do algoritmo. Existem dois operadores básicos: a “reprodução” e a “mutação”. A *reprodução* é o operador que permite que dois cromossomos pais gerem dois novos cromossomos filhos. A *mutação* é o operador que introduz uma alteração em um único cromossomo para obter um único novo cromossomo.

A mutação consiste na alteração de poucos genes, conforme uma distribuição estocástica, por exemplo, para o caso de uma representação binária, ocorre uma inversão em um dos bits, como ilustrado na figura A.1.

A mutação é considerada um método de redescobrimto de material genético perdido (mais preferível para pesquisa de soluções melhores). A mutação é aplicada aos indivíduos descendentes gerados após o processo da reprodução. Em geral a probabilidade de que alguma variável (gene) sofra mutação é inversamente proporcional ao número de variáveis do problema (tamanho do cromossomo). Desta forma, quanto maior for a dimensão do problema, menor é a probabilidade de que um indivíduo sofra mutação. Têm sido demonstrado que o algoritmo será tão mais eficiente quanto mais diversificada for as populações, mas existem limites para esta diversidade, desta forma, o operador de mutação têm um papel importante na diversificação das populações.

O outro operador básico do algoritmo, é o operador de reprodução. Supondo-se que os dois cromossomos pais P_1 e P_2 vão cruzar-se.

$$P_1 = (110|0110) = (p_{11}p_{12}p_{13}|p_{14}p_{15}p_{16}p_{17}) \quad (A.3)$$

$$P_2 = (011|1011) = (p_{21}p_{22}p_{23}|p_{24}p_{25}p_{26}p_{27}) \quad (A.4)$$

No operador de reprodução inicialmente determina-se um ou mais cortes entre dois genes adjacentes de cada cromossomo pai. No nosso exemplo, o corte foi feito entre os genes p_3 e p_4 . A seguir são gerados dois novos cromossomos o_1 e o_2 reunindo os genes à esquerda do corte

de p_1 ($p_{11}p_{12}p_{13}$) reunidos com os genes à direita do corte de p_2 ($p_{24}p_{25}p_{26}p_{27}$) para formar o_1 e os genes à esquerda do corte de p_2 ($p_{21}p_{22}p_{23}$) reunidos com os genes à direita do corte de p_1 ($p_{14}p_{15}p_{16}p_{17}$) para formar o_2 .

$$o_1 = (1101011) = (o_{11}o_{12}o_{13}o_{14}o_{15}o_{16}o_{17}) \quad (\text{A.5})$$

$$o_2 = (0110110) = (o_{21}o_{22}o_{23}o_{24}o_{25}o_{26}o_{27}) \quad (\text{A.6})$$

A eficiência de um operador genético de reprodução, muitas vezes, está relacionada com o tipo adequado de representação utilizado. Nos AGs os dois operadores clássicos, mutação e reprodução, são normalmente utilizados conjuntamente. Em cerca de 80% dos novos cromossomos são gerados a partir do operador reprodução e um pequeno percentual destinado ao uso do operador mutação. Normalmente o operador mutação é utilizado dentro de um AG para permitir uma diversificação no processo de busca, tentando com isso escapar de ótimos locais em problemas de otimização.

A.2 Redes neuronais

A.2.1 Introdução

As redes neuronais são estruturas computacionais que possui como característica interessante a capacidade de representar uma grande quantidade de funções, bastando que um treinamento seja feito. Este treinamento consiste em submeter a rede às entradas e aos resultados desejados repetidamente, até que a rede *aprenda* a mapear as entradas nas saídas desejadas. Portanto, redes neuronais são estruturas computacionais muito poderosa para determinar a função de mapeamento que vai transformar a histerese ideal obtida no item anterior em uma histerese qualquer obtida experimentalmente.

O processamento biológico ocorre em células chamadas de neurônios. Cada neurônio faz um processamento local e envia seu resultado aos outros neurônios do cérebro. Os cérebros, portanto, são constituídos por uma grande número de elementos de processamento independentes, conectados entre si.

A.2.2 Descrição

Uma rede neuronal é uma estrutura computacional inspirada pelo estudo do processamento neural biológico. Existem muitos tipos diferentes de redes neurais, desde redes relativamente simples até redes muito complexas, da mesma forma que existem muitas teorias sobre como funciona o processamento biológico.

Uma rede neuronal "feed-forward" possui *camadas*, ou subgrupos de *elementos de processamento*. Uma *camada* de processamento faz a computação dos dados que recebe e passa o resultado para outra camada. Até que um subgrupo de um ou mais elementos de processamento determinam a saída da rede. Cada elemento de processamento faz a sua computação baseada na soma ponderada de suas entradas. A primeira camada é a *camada de entrada*, a última a *camada de saída* e as camadas intermediárias são chamadas de *camadas escondidas*. Os elementos de processamento são unidades similares aos neurônios no cérebro humano, por isso recebem o nome de *neurônios*. As *sinapses* entre os neurônios são as conexões, que são representadas através de setas em um gráfico direcional na qual os nós são os neurônios (fig. A.2).

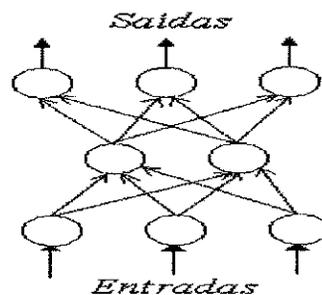


Figura A.2: rede neuronal feed-forward

A.2.3 Neurônios

Os neurônios são as unidades básicas de processamento de uma rede neuronal. Uma representação simplificada de um neurônio é apresentada na figura A.3.

Cada entrada está conectada a um neurônio da camada anterior. Cada entrada é multiplicada por um peso w_{ij} (que representa as sinapses) antes de entrar em uma somatória. A função $f(u)$ é chamada de função de ativação. O índice i é usado para representar a entrada do neurônio, que corresponderá também ao neurônio da camada anterior. O índice j representa o neurônio sendo considerado em uma determinada camada k .

A saída o_j do neurônio j pertencente a camada k será dado por:

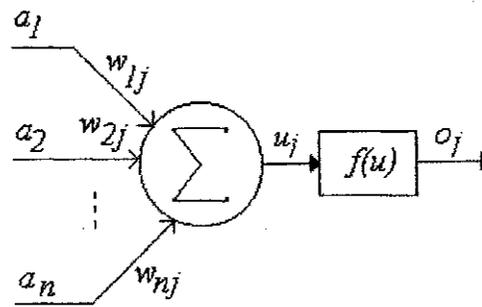


Figura A.3: Neurônio comum

$$o_j^{(k)} = f \left[\sum_{i=1}^n w_{ij}^{(k)} o_i^{(k-1)} \right] \quad (\text{A.7})$$

Existem três tipos de neurônios: neurônio comum, neurônio de polarização e neurônios de entrada. O neurônio comum é mostrado na figura A.3.

Neurônios de polarização são os neurônios cuja saída é constante e, normalmente, igual a um. Estes neurônios são usados para acelerar o processo de treinamento da rede.

A função de ativação dos neurônios é escolhida em função da aplicação. Uma função de ativação muito usada é:

$$f(u) = \frac{1}{1 + e^{-u}} \quad (\text{A.8})$$

A.2.4 Camadas

Camadas são conjuntos de neurônios. Existem três tipos de camadas: camada de entrada, camada de saída e camadas escondidas.

A camada de saída é a camada cujas saídas são o resultado do processamento da rede. O número de neurônios desta camada vai ser igual ao número de saídas da rede neuronal.

As camadas escondidas são aquelas que ficam entre a camada de entrada e a camada de saída. Estas camadas fazem o processamento propriamente dito em conjunto com a camada de saída. Todas as camadas escondidas devem ter pelo menos um neurônio de polarização. Este neurônio ajuda na aceleração do processo de treinamento da rede.

A.2.5 Observação

Para uma introdução mais abrangente sobre redes neuronais, ver as referências [11] e [12]. Um exemplo de uso de redes neuronais para representar histereses pode ser visto em [14].

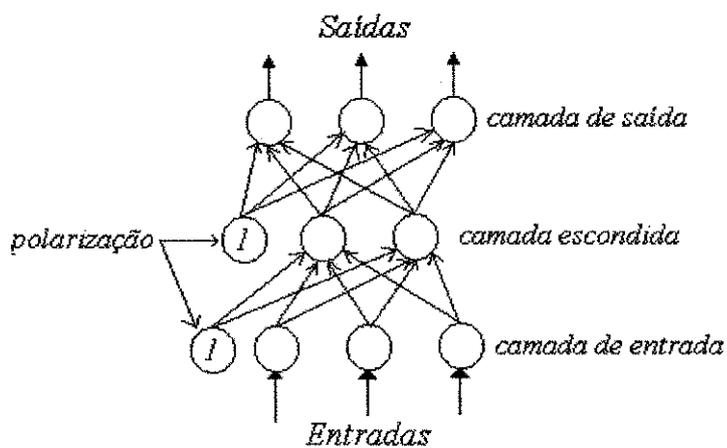


Figura A.4: rede neuronal com neurônios de polarização e uma camada escondida

Apêndice B

Toolbox para histereses no Matlab

B.1 Introdução

O Matlab é um software para computação técnica muito utilizado. Este software possui uma linguagem de programação estruturada muito poderosa, mas interpretada. O fato de usar uma linguagem interpretada, o Matlab costuma ser muito lento em muitas aplicações, principalmente na aplicação proposta neste trabalho. A grande vantagem no uso do Matlab é seu suporte para a manipulação de matrizes já incluída na linguagem, facilitando muito o desenvolvimento de programas técnicos. Outra característica é a disponibilidade de uma grande número de funções matemáticas já incluídas, além de um grande número de ferramentas para as mais diversas áreas prontas para o uso.

A grande desvantagem do Matlab, além de usar uma linguagem interpretada, é o preço da licença de uso que costuma ser muito elevado para os padrões dos usuários brasileiros, mas existem alternativas ao Matlab, tais como o “*Matcom*” e o “*Octave*”, ambos para Linux, grátis e totalmente compatíveis com o Matlab mas com um desempenho, em termos de velocidade de processamento, um pouco inferior ao Matlab.

Uma *toolbox* é um conjunto de funções que são usadas para executar alguma tarefa específica. Foram usadas duas toolboxes neste trabalho, a toolbox denominada *ih* (sigla em português de identificação de histereses), desenvolvida especialmente para este trabalho, e a *nnet* que acompanha o Matlab desenvolvida para trabalhos envolvendo redes neuronais.

A toolbox “*ih*” é derivada da toolbox “*goat5*”. A *goat5* é uma toolbox para algoritmos genéticos distribuído sob licença GPL devido a isto, a toolbox *ih* deve ser distribuído também sob esta licença. Ela é constituído de um grande número de funções e estruturas de dados, mas o usuário precisa conhecer apenas quatro (as funções *front-end*).

A toolbox “*nnet*” acompanha o Matlab, e, a princípio, o usuário necessita conhecer apenas

três funções. Esta toolbox é comercial, por isso está sujeita às limitações presentes no contrato de licença firmado com a Mathworks. Um manual completo pode ser obtido no site da Mathworks ou nos manuais que acompanham o Matlab, por isso esta toolbox não será apresentada aqui.

B.2 Identificação de histereses

B.2.1 Introdução

Para fazer a identificação de uma histerese é necessário estar com os dados experimentais disponíveis em um formato que o Matlab, o Matcom ou o Octave possam reconhecer, por isso o autor recomenda o uso do formato ASCII com a variável independente na primeira coluna e a variável dependente na segunda coluna.

Outra dado que deverá estar disponível é a posição em que inicia e termina cada uma das FODs dentro dos vetores dos dados experimentais. Estes dados consistem simplesmente nas posições em que há a reversão da variável dependente formando um vetor coluna.

Há duas formas de fazer a identificação. Uma forma é identificando cada uma das FODs independentemente e em seguida tentar descobrir como varia cada um dos parâmetros. A outra forma é usar todas as FODs simultaneamente.

B.2.2 Identificação individual

Neste método, cada uma das FODs será identificada separadamente. Supondo que os dados experimentais estejam armazenados no arquivo *hist101.dat* e os posições de reversão da entrada está em *limites.dat*, então para carregar os dados:

```
>>load hist101.dat -ascii % Carga dos dados experimentais  
>>load limites.dat -ascii % Carga das posições de reversão
```

Dispondo dos dados na memória, deve-se definir um vetor que conterà a FOD individual e definir o universo de busca do algoritmo genético:

```
>>dado=[hist101(limites(1):limites(2),1) hist101(limites(1):limites(2),2)]; % extração da  
primeira FOD para identificação  
>>universo=[10 -10;10 -10;10 -10;10 -10]; % Definição do universo de busca do algoritmo
```


Dispondo destes dados, pode-se fazer a identificação, que será feito em um único passo:

```
>>solglobal=ajusag2('idglobal',dado,tam_pop,num_geracoes,universo);
```

Onde *idglobal* é a função de custo usada na identificação.

B.3 Simulação das histereses

Neste trabalho, a implementação do modelo de Preisach formulada neste trabalho, torna a memória como um dos parâmetros da implementação numérica. Outra característica é que esta é uma implementação paramétrica, portanto, os parâmetros também são entradas.

O primeiro passo consiste em obter uma estrutura de dados que representará a memória do modelo. Isto é feito através da função *disphist*, como demonstrado através do fragmento de código a seguir:

```
>>memoria=disphist(T,R,alfa0,beta0,satp,satn);
```

Onde T é o valor inicial da excitação (temperatura), R é o valor inicial da saída do modelo, $alfa0$ é o valor da entrada quando a saturação superior da histerese é atingida, $beta0$ é o valor da entrada quando a saturação inferior é atingida, $satp$ é o valor de saturação superior da histerese e $satn$ é o valor da saturação inferior.

Através do fragmento de código a seguir, é demonstrado como fazer a simulação:

```
>>[y(i) memoria]=hister(T(i),memoria,'fod',sol);
```

Onde $y(i)$ é a saída do modelo, *memoria* representa a memória do modelo que é atualizada a cada vez que esta função é chamada, $T(i)$ é a entrada aplicada, *fod* é uma string com o nome da função que implementa a FOD, *sol* contém os parâmetros do modelo. Esta função só funciona quando a entrada for uma valor escalar.

Esta função implementa de forma simplificada o modelo de Preisach. Quando esta função for usada na simulação de sistemas dinâmicos, a memória do modelo deve ser preservada (através de uma variável temporária) até que as variáveis de estado do sistema estejam calculadas, quando então ela deverá ser atualizada.

B.4 Conclusão

B.4.1 Aplicação desta toolbox

Estas funções são usadas para o caso das histeres simétricas, caso o usuário esteja tentando encontrar um modelo para uma histerese assimétrica, ele deve, em primeiro lugar, simetrizar a histerese, e em seguida, encontrar o modelo da histerese simétrica e obter a função que vai mapear esta histerese simétrica na histerese experimental.

B.4.2 Códigos fontes

Toolbox de identificação

A toolbox de identificação é muito extensa, ela faz uso de muitas outras funções e estruturas de dados que tornam a apresentação neste texto dos seus códigos fontes inviáveis. Mas em breve, esta toolbox estará disponível para download no site <http://www.hysteresis.org/preisach/identification> ou no site do projeto GNU em <http://www.gnu.org>

Funções de simulação

As rotinas de simulação são independentes da toolbox de identificação, por isso podem ser usadas separadamente. Os códigos fontes destas funções são curtos e podem ser apresentados neste texto. A seguir os códigos são apresentados.

```
function memoria=disphist(alfa0,beta0,satp,satn)
%
%      memoria=disphist(T,R,alfa0,beta0,satp,satn)
%
%      Esta função inicializa uma estrutura de dados que representa a memória do modelo
de Preisach
% modificado (para mais detalhes, ler a dissertação).
% onde:
%   T   => valor inicial da excitação
%   R   => valor inicial da histerese
%   alfa0 => valor da entrada para saturação superior
%   beta0 => valor da entrada para saturação inferior
%   satp => valor da histerese na saturação superior
```

```
% satn => valor da histerese na saturação inferior
%
% Autor: José Adolfo da Silva Sena
% Projeto: Dissertação de mestrado
% Orientadores: Gurdip Singh Deep, PhD
% Raimundo Carlos Silvério Freire, PhD
%
```

```
alfa_0 = alfa0;
beta_0 = beta0;
alfa = T;
beta_ = T;
alfa_old = T;
beta_old = T;
falfa = R;
falfa_old = R;
fbeta = R;
fbeta_old = R;
Tk_1 = T;
Hk_1 = R;
sat_p = satp;
sat_n = satn;
d = 0;
```

```
memoria(1)=alfa_0;
memoria(2)=beta_0;
memoria(3)=alfa;
memoria(4)=beta_;
memoria(5)=alfa_old;
memoria(6)=beta_old;
memoria(7)=falfa;
memoria(8)=falfa_old;
memoria(9)=fbeta;
memoria(10)=fbeta_old;
memoria(11)=Tk_1;
```

```

memoria(12)=Hk_1;
memoria(13)=alfa_0; %Valor inicial da entrada (começa do menor sempre)
memoria(14)=satp; %Valor inicial da saída
memoria(15)=sat_p;
memoria(16)=sat_n;
memoria(17)=d;

```

```

function [val, memoria_nova]=hister(T,memoria,fod,sol)
%
%      [val, memoria_nova]=hister(T,memoria,fod,sol)
%
%      Esta função faz a simulação de uma histerese usando o modelo de Preisach modificado.
% onde:
%      val      => valor de saída calculado pelo modelo
%      memoria_nova => atualização da memória do modelo
%      T        => entrada do modelo
%      memoria  => memória atual do modelo
%      fod      => string com o nome da função que implementa as fods
%      sol      => parâmetros do modelo matemático de Preisach modificado
%
% Esta função foi projetada para uma simulação recursiva, desta forma, ela só funciona para
% uma entrada escalar. O parâmetro "memoria_nova" deve ser utilizado na próxima rodada
de
% cálculo. Outra consideração é que esta rotina assume que a histerese comece com a
entrada no
% valor mínimo.
%
% Autor: José Adolfo da Silva Sena
%
% Projeto: Dissertação de mestrado
% Orientadores: Gurdip Singh Deep, PhD
%              Raimundo Carlos Silvério Freire, PhD
%
%

```

```
memoria_nova=memoria;
alfa_0=memoria(1);
Tk_1=memoria(11);
alfa=memoria(3);
alfa_old=memoria(5);
beta_=memoria(4);
fbeta=memoria(9);
fbeta_old=memoria(10);
falfa=memoria(7);
falfa_old=memoria(8);
beta_old=memoria(6);
fk_1=memoria(12);
T_1=memoria(13);
H_1=memoria(14);
d=memoria(17);

if (T-T_1)<=0
    if d>=0
        Tk_1=T_1;
        fk_1=H_1;
        beta_old=beta_;
        fbeta_old=fbeta;
        beta_=Tk_1;
        fbeta=fk_1;
    end;
    if (T<alfa)
        fbeta=fbeta_old;
        beta_=beta_old;
        Tk_1=beta_;
        fk_1=fbeta_old;
    end
    H=fk_1+feval(fod,T,T,sol)-feval(fod,T,Tk_1,sol);
end;
```

```
if (T-T_1)>=0
    if d<=0
        Tk_1=T_1;
        fk_1=H_1;
        alfa_old=alfa;
        falfa_old=falfa;
        alfa=Tk_1;
        falfa=fk_1;
    end;
    if (T>beta_)
        falfa=falfa_old;
        alfa=alfa_old;
        Tk_1=alfa;
        fk_1=falfa;
    end;
    H=fk_1-feval(fod,Tk_1,Tk_1,sol)+feval(fod,Tk_1,T,sol);
end;
d=T-T_1;
T_1=T;
H_1=H;
val=H;
memoria_nova(3)=alfa;
memoria_nova(4)=beta_;
memoria_nova(5)=alfa_old;
memoria_nova(6)=beta_old;
memoria_nova(7)=falfa;
memoria_nova(8)=falfa_old;
memoria_nova(9)=fbeta;
memoria_nova(10)=fbeta_old;
memoria_nova(11)=Tk_1;
memoria_nova(12)=fk_1;
memoria_nova(17)=d;
memoria_nova(13)=T_1;
memoria_nova(14)=H_1;
```

Bibliografia

- [1] L.A.L. Almeida, G.S. Deep, A.M.N Lima, H. Neff, e R.S. Freire. Representação da Histerese em Sensores de Óxido DE Vanádio Utilizando o Modelo Clássico de Presaich. *XIII Congresso Brasileiro de Automática*, 2000.
- [2] N. Berglund e H. Kunz. Chaotic Hysteresis in an Adiabatically Oscillating Double Well. *Phys. Rev. Letters*, 78(9):1691–1694, MAR 1997.
- [3] O. Bottauscio, M. Chiampi, D. Chiarabaglio, e M. Repetto. Preisach-type hysteresis models in magnetic field computation. *Physics B*, pp. 34–39, 2000.
- [4] E. DellaTorre. A Preisach Model for Accommodation. *IEEE Transactions on Magnetics*, 30(5):2701–2707, SEP 1994.
- [5] David E. Goldberg. *Genetic Algorithms in Search, Optimization, and Machine Learning*. Addison-Wesley, 1997.
- [6] J. Holland. *Adaptation in natural and artificial systems*. The University of Michigan Press, 1975.
- [7] Christopher R. Houck, Jeffery A. Joines, e Michael G. Kay. A Genetic Algorithm for Function Optimization: A Matlab Implementaion. Relatório técnico, North Caroline State University, 1996.
- [8] M. Krasnoselskii e A. Pokrovskii. *Systems with Hysteresis*. Nauka, Moscow, 1983.
- [9] I.D. Mayergoyz. *Mathematical Models of Hysteresis*. Springer-Verlag, 1991.
- [10] Massachusetts Institute of Technology. GALib: A C++ Genetic Algorithms Library. Relatório técnico, Massachusetts Institute of Technology, JUL 1996. HTML document.
- [11] Valluru B. Rao e Hayagriva V. Rao. *Neural Networks and Fuzzy Logic*. MIS:Press, 115 West 18th Street New York, NY 10011, 2 edition, 1995.

- [12] Elaine Rich e Kevin Knight. *Artificial Intelligence*. McGraw-Hill, Inc, 1991.
- [13] H.H. Saliah e D.A. Lowther. The use of neural network in magnetic hysteresis identification. *Physica B*, 233(4):318–323, JUN 1997.
- [14] H.H. Saliah, D.A. Lowther, e B. Forghani. A Neural Network Model of Magnetic Hysteresis for Computational Magnetics. *IEEE Transactions on Magnetics*, 33(5):4146–4148, SEP 1997.
- [15] J.A.S. Sena, L.A.L. Almeida, G.S. Deep, R.C.S. Freire, e A.M.N. Lima. Modelagem de Histereses Magnéticas Utilizando Algoritmos Genéticos. *IV Congresso Brasileiro de Eletromagnetismo*, 2000.
- [16] J.R. Sun, G.H. Rao, e J.K. Liang. Thermal History Dependent Electronic Transport and Magnetic Properties in Bulk $\text{La}_{1/3}\text{Nd}_{1/3}\text{Ca}_{1/3}\text{MnO}_3$. *Physica Status Solidi*, 163(1):141–147, SEP 1997.
- [17] Yunhe Yu, Zhengchu Xiao, En-Bing Lin, e Nagi Naganathan. Analytic and experimental studies of a wavelet identification of Preisach model of hysteresis. *Journal of Magnetism and Magnetic Materials*, pp. 255–263, 1999.