



UNIVERSIDADE ESTADUAL DE CAMPINAS

FACULDADE DE ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO

DEPARTAMENTO DE SISTEMAS E CONTROLE DE ENERGIA


**IMPLEMENTAÇÃO DIGITAL DO CONTROLE INDIRETO POR ORIENTAÇÃO DO FLUXO DE ROTOR PARA O MOTOR DE INDUÇÃO UTILIZANDO ABORDAGENS NEURO - FUZZY**

*LINO ROSELL VALDENEBRO*


Orientador : Prof. Dr. Edson Bim  
Co-orientador: Prof. Dr. Jaime Szajner

Dissertação apresentada à Faculdade de Engenharia Elétrica e de Computação da Universidade Estadual de Campinas como parte dos requisitos exigidos para a obtenção do título de *Mestre em Engenharia Elétrica*.

Este exemplar corresponde à redação final da tese defendida por Lino Rosell Valdenebro e aprovada pela Comissão Julgadora em 27 / 02 / 97.

  
Orientador

Fevereiro/1997



878546

UNIDADE	BC
Nº CHAMADA:	UNICAMP
	R722i
V.	Ex.
TOMBO BC	30550
PROC.	281193
C	<input type="checkbox"/>
D	<input checked="" type="checkbox"/>
PREÇO	R\$ 11,00
DATA	24/02/97
Nº OPD	

CM-00099237-0

FICHA CATALOGRÁFICA ELABORADA PELA  
BIBLIOTECA DA ÁREA DE ENGENHARIA - BAE - UNICAMP

R722i

Rosell Valdenebro, Lino

Implementação digital do controle indireto por orientação do fluxo de rotor para o motor de indução utilizando abordagens neuro-fuzzy / Lino Rosell Valdenebro.--Campinas, SP: [s.n.], 1997.

Orientador: Edson Bim.

Dissertação (mestrado) - Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação.

1. Motores elétricos de indução. 2. Sistema de controle ajustável. 3. Controle automático. 4. Inteligência artificial. 5. Redes neurais (Computação) 6. Sistemas difusos. 7. Microprocessadores. I. Bim, Edson. II. Universidade Estadual de Campinas. Faculdade de Engenharia Elétrica e de Computação. III. Título.

*À minha família*

## Agradecimentos

Agradeço ...

Ao Prof. Dr. Edson Bim pela sua excelente orientação deste trabalho. Sua constante preocupação, incentivo e pronta disponibilidade até o final foram determinantes para a conclusão desta dissertação.

Ao Prof. Dr. Jaime Szajner e ao Prof. Dr. Márcio Luiz de Andrade Netto, os quais me aceitaram no curso de Mestrado e, sempre me incentivaram e ajudaram tanto no nível profissional como pessoal.

Ao meu amigo Prof. Raúl Diaz del Mazo, a sua esposa e amiga Prof. Elsa León, ambos da Universidade de Oriente, os quais me incentivaram a vir para o Brasil.

Ao meu colega e amigo Eng. José Alberto Torrico Altuna, cuja experiência e conhecimento em implementação digital foram fundamentais à realização do meu trabalho.

Ao meu amigo Barreda, quem muito me ajudou nos meus primeiros meses de Brasil.

A meu colega e amigo Jaime Reyes, quem me ajudou nos desenhos gráficos desta dissertação.

A Maria, sempre ao meu lado, pela sua compreensão, paciência e apoio.

À Faculdade de Engenharia Elétrica e de Computação, em especial ao Departamento de Computação e Automação, pela oportunidade dada à realização do curso de Mestrado.

À CAPES pelo suporte financeiro.

# SUMÁRIO

**RESUMO**

**ABSTRACT**

<b>Capítulo 1. INTRODUÇÃO.....</b>	<b>1</b>
<b>Capítulo 2. CONTROLE VETORIAL INDIRETO POR ORIENTAÇÃO DO FLUXO DE ROTOR DA MÁQUINA DE INDUÇÃO</b>	
2.1. Introdução.....	4
2.2. Equações Fundamentais do Controle por Orientação de Fluxo do Rotor.....	6
2.3. Características Conjugado-Freqüência de Escorregamento.....	10
2.4. Característica Fluxo de Rotor-Freqüência Escorregamento .....	15
2.5. Características Transitórias da Velocidade e do Conjugado, para Variação em Degrau de $I_{qs}$ .....	17
2.6. Sensibilidade aos Parâmetros.....	19
2.7. Influência do Grau de Acoplamento nas Características de Regime do Conjugado, Fluxo e Velocidade.....	26
2.8. Características de Resposta da Velocidade em Função do Grau de Acoplamento do Controle Vetorial.....	30
2.9. Considerações de Estabilidade.....	31
2.10. Breve Histórico dos Métodos de Solução do Problema de Sensibilidade aos Parâmetros.....	33

---

---

### **Capítulo 3. LÓGICA FUZZY E REDES NEURAIS ARTIFICIAIS, TEORIA E APLICAÇÕES NA ÁREA DE MÁQUINAS ELÉTRICAS**

3.1. Introdução.....	41
3.2. Lógica Fuzzy.....	43
3.2.1. Operações Básicas com Conjuntos Fuzzy.....	45
3.2.2. Variáveis e Termos Lingüísticos.....	45
3.2.3. Funções de Pertinência.....	46
3.2.4. Fuzzificação.....	48
3.2.5. Regras de Inferência.....	50
3.2.6. Defuzzificação.....	55
3.2.6.1. Método do Centro do Máximo.....	56
3.2.6.2. Método do Centro de Área.....	58
3.2.7. Aplicações na Área de Máquinas Elétricas.....	64
3.3 Redes Neurais Artificiais.....	68
3.3.1. Introdução.....	68
3.3.2. Modelo do Neurônio Artificial.....	70
3.3.3. Principais Arquiteturas.....	75
3.3.4. Aprendizado.....	77
3.3.5. Representação de Comportamento Dinâmico utilizando Redes Neurais Artificiais.....	84
3.3.6. Aplicações na Área de Máquinas Elétricas.....	92
<b>Capítulo 4. DESCRIÇÃO FUNCIONAL DO SISTEMA IMPLEMENTADO</b>	
4.1. Introdução.....	97

---

---

4.2. Diagrama de Blocos do Sistema Implementado.....	98
4.2.1. Características Gerais do Microcontrolador da Intel 87C196KD.....	100
4.2.2. Aquisição dos Sinais de Entrada do Microcontrolador.....	102
4.2.3 Regulador PI de Velocidade.....	104
4.2.4. Estimação do Ângulo Elétrico.....	106
4.2.5 Transformação do Sistema de Referência Síncrono ao Estacionário.....	107
4.3. Identificação da Constante de Tempo Elétrica de Rotor utilizando Redes Neurais Artificiais.....	110
4.4. Regulador Fuzzy de Velocidade.....	113

## **Capítulo 5. RESULTADOS EXPERIMENTAIS**

5.1. Introdução.....	119
5.2. Resultados referentes à Influência dos Parâmetros na Resposta de Velocidade do Sistema de Controle.....	120
5.3. Resultados Referentes ao Regulador Fuzzy de Velocidade.....	123
5.4. Resultados Referentes ao Sistema de Identificação da Constante de Tempo Elétrica do Rotor utilizando Redes Neurais Artificiais.....	126

## **Capítulo 6. CONCLUSÕES.....**

<b>APÊNDICE A: Dados do Motor de Indução.....</b>	<b>135</b>
---	------------

<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>136</b>
--	------------

## Resumo

Neste trabalho é apresentado o estudo e a implementação digital do controle indireto por orientação do fluxo de rotor para um motor de indução trifásico gaiola de esquilo. O método de orientação está baseado na determinação indireta do vetor fluxo de rotor. O acoplamento entre as variáveis de fluxo e conjugado eletromagnético da máquina, produto da variação dos parâmetros do modelo, é analisada e soluções são propostas e implementadas utilizando técnicas da Inteligência Artificial. Para determinar o valor atual da constante de tempo do rotor é implementado um sistema de identificação usando Redes Neurais Artificiais que infere o valor desta constante a partir da resposta transitória de velocidade quando o sistema é submetido a sinais de tipo degrau na corrente de conjugado. Com o objetivo de melhorar a robustez do sistema de controle o regulador PI convencional da malha de velocidade é substituído por um regulador fuzzy. O algoritmo de controle, o sistema de identificação e o regulador fuzzy de velocidade são implementados utilizando o Microcontrolador de INTEL 87C196KD que tem como sinais de entrada as correntes de estator e a velocidade mecânica do motor. Resultados experimentais e de simulação são apresentados e discutidos.



## Abstract

A study and the digital implementation of a rotor flux field oriented based control of a squirrel cage induction motor is presented. The flux orientation is based on the indirect determination of the rotor flux vector. The coupling between the flux and electromagnetic torque due to the parameter variation is analyzed and experimental solutions are investigated using Artificial Neural Networks (ANN) techniques. The rotor electrical time constant is obtained using an ANN identification system based on the speed response to a torque current step stator input. In order to improve the robustness of the control system, a conventional PI speed regulator is replaced by a fuzzy controller. The control algorithm, the identification system and the speed regulator are implemented on the INTEL 87C196KD microcontroller. The input signals to the microcontroller are the stator currents and the rotor speed. Experimental and digital simulation results are presented and discussed.

# **CAPÍTULO 1**

## **INTRODUÇÃO**

O surgimento da teoria de controle por orientação do campo ( BLASHKE, 1973 ), teve, sem dúvida, extraordinária repercussão no controle de acionamentos elétricos, que utilizam como elemento de conversão eletromecânica de energia, o motor de corrente alternada ( CA ). O emprego desta técnica de controle permitiu a estes motores apresentar um desempenho dinâmico equivalente aos de corrente contínua ( CC ) com excitação independente; que até então, dominavam as aplicações industriais. A existência de uma teoria de controle adequada, além das características de baixo custo e construção robusta apresentada pelos motores de CA, fez com que estes passassem rapidamente a serem empregados na maior parte dos acionamentos elétricos de alto desempenho.

O princípio de orientação pelo campo consiste no conhecimento da posição espacial do vetor fluxo escolhido ( de estator, de rotor ou de entreferro ) e, a partir disto, realizar a orientação conveniente deste vetor em um sistema de referência girante, com o objetivo de conseguir o desacoplamento desejado entre as variáveis de fluxo e conjugado eletromagnético. A informação referente à posição espacial do vetor fluxo pode ser obtida através de medições diretas na máquina ( bobinas exploratórias ), ou calculada a partir dos valores de corrente e tensão ( observadores de fluxo ). Um outro método consiste em estimar a posição espacial deste vetor, utilizando a informação de velocidade, as constantes do motor e sinais de referência gerados pelo controle. Estas duas abordagens permitem dividir os esquemas de controle por orientação do campo em direto e indireto.

Embora o método indireto de orientação apresente uma estrutura mais simples quando comparada com a do método direto, ele tem como desvantagem o fato de ser sensível aos parâmetros do motor, em particular aos valores da resistência do rotor e da indutância de magnetização, que dependem da temperatura e da saturação magnética respectivamente. Este problema conduz à perda de desacoplamento no controle e como consequência a um desempenho dinâmico não satisfatório.

Os avanços obtidos na área de controle adaptativo tem sido aproveitados convenientemente pelos pesquisadores da área de acionamentos elétricos. Em particular, no controle de máquinas, o projeto e implementação de reguladores adaptativos para diminuir o efeito negativo de perturbações externas, ou aquele relacionado com as incertezas paramétricas do modelo, tem sido objeto de diversos trabalhos nos últimos anos. O desenvolvimento nas técnicas da Inteligência Artificial ( IA ), tem contribuído em grande medida para solucionar os problemas de controle antes mencionados; através do projeto de algoritmos de identificação e controle "inteligentes", com uma característica inerentemente adaptativa.

A partir do início da década de 80, o número de implementações do controle de orientação pelo campo teve um grande desenvolvimento. Este crescimento não foi casual mas sim, devido ao desenvolvimento alcançado nas áreas de microeletrônica e de tecnologia de grande escala de integração ( VLSI ); e, que como consequência disto, viabilizou o surgimento de potentes microprocessadores facilitando a implementação de complexos algoritmos de controle.

Neste trabalho é apresentado um estudo e implementação do método de controle indireto mediante a orientação do fluxo do rotor utilizando o microcontrolador da INTEL 87C196KD. Para solucionar o problema de sensibilidade aos parâmetros deste método de controle é projetado e implementado um sistema de identificação da constante de tempo elétrica do rotor utilizando Redes Neurais Artificiais. Por outro lado, com a finalidade de aumentar a robustez do sistema é proposto e implementado um regulador de velocidade com base em "Lógica Fuzzy" para operar na malha de velocidade do controle.

A apresentação deste trabalho está organizada da seguinte forma:

No capítulo 2 é feito um estudo do controle indireto mediante a orientação do fluxo do rotor. O problema de sensibilidade aos parâmetros do motor, principalmente à resistência do rotor, apresentado neste método, é discutido inicialmente, através da comparação entre as características de fluxo e conjugado electromagnético para o caso de desacoplamento ideal e aquelas obtidas em função do grau de acoplamento. Um estudo do desempenho do sistema de controle é realizado mediante a análise das respostas de velocidade obtidas em simulação, quando o sistema é submetido a sinais de tipo degrau na referência de velocidade e, para diferentes condições de acoplamento.

No capítulo 3 é apresentada uma breve descrição dos fundamentos teóricos de duas das áreas da Inteligência Artificial (I): Lógica Fuzzy e Redes Neurais Artificiais, enfatizando os aspectos que consideramos de maior interesse, à aplicação na área de máquinas elétricas. São comentados alguns dos trabalhos atuais nesta área, que utilizam estes princípios da IA, sendo os exemplos tomados da literatura especializada.

O capítulo 4 apresenta uma descrição funcional dos principais blocos que constituem a implementação do sistema de controle. Em cada caso é esclarecida a forma de implementação de cada bloco. São analisados os fundamentos teóricos do sistema de identificação da constante de tempo elétrica do rotor, utilizando Redes Neurais Artificiais, e discutidos os detalhes da sua implementação. Na última seção desse capítulo é mostrado o projeto de um regulador "fuzzy" de velocidade para operar na malha de velocidade do controle, além de comentar os principais aspectos de implementação.

No capítulo 5, são apresentados resultados experimentais referentes ao desempenho do sistema de controle. A primeira parte do capítulo apresenta resultados da resposta de velocidade do sistema, para diferentes condições de acoplamento, dadas por variações na resistência de rotor. A seguir, mostra-se as curvas de resposta de velocidade utilizando o regulador PI convencional e o regulador "fuzzy" de velocidade. Por último são mostrados resultados referentes ao sistema de identificação da constante de tempo do rotor utilizando Redes Neurais Artificiais.

As conclusões sobre os resultados obtidos neste trabalho, como também os tópicos que poderão ser objetos de estudos futuros, estão apresentados no capítulo 6.

## **CAPÍTULO 2**

### *CONTROLE VETORIAL COM ORIENTAÇÃO INDIRETA DE FLUXO DE ROTOR DA MÁQUINA DE INDUÇÃO*

#### **2.1. Introdução**

Tem intensificado o número de aplicações industriais baseadas em motores de indução como elemento de conversão eletromecânica de energia nos acionamentos elétricos, principalmente nas aplicações nas quais os motores de corrente contínua eram preferidos pelo fato de possuírem uma adequada estrutura para o controle. Nos motores de corrente contínua as variáveis de fluxo e conjugado eletromagnético encontram-se fisicamente desacopladas, podendo ser controladas independentemente através das respectivas correntes de campo e de armadura.

Os motores de indução apresentam algumas vantagens em relação aos de corrente contínua tais como menor tamanho, menor custo e uma maior robustez. Por outro lado, a máquina de indução apresenta um modelo matemático complexo com características de não linearidade, multivariabilidade e parâmetros variantes no tempo, além de um inerente acoplamento entre as variáveis fluxo e conjugado eletromagnético.

O surgimento do controle vetorial por orientação de campo [1] apresenta-se como uma solução ao problema do acoplamento nas variáveis do motor, pois possibilita obter o desacoplamento entre as variáveis fluxo e conjugado da máquina, resultando em um controle de rápida resposta dinâmica e bom desempenho em regime permanente. Existem três esquemas de orientação do campo, dependentes do vetor fluxo a ser escolhido na orientação: fluxo de estator, de rotor ou de entreferro. Cada um destes esquemas possui características distintas no que se refere à estrutura do controle, da

resposta dinâmica, além de certas particularidades em relação ao problema de sensibilidade aos parâmetros.

O sucesso do controle por orientação de campo depende do conhecimento exato da posição espacial do vetor fluxo para o qual a orientação é desejada e, duas estratégias de implementação existem para determinar esta posição[1]:

- 1 - *Orientação indireta do campo*: geralmente utiliza o fluxo de rotor na orientação e tem sido a mais adotada por levar a um completo desacoplamento entre o torque e fluxo magnético. Nesta estratégia, a posição do fluxo é estimada a partir da relação do escorregamento que depende dos parâmetros resistência de rotor e indutância de magnetização da máquina e, portanto, a implementação é sensível a estes parâmetros.
- 2 - *Orientação direta do campo*: na literatura podemos diferenciar dois métodos: a) o esquema pelo qual a posição do fluxo é diretamente medida através de bobinas exploratórias [2,3,4] ou b) aquele que estima a posição do fluxo a partir das medições das correntes e tensões de estator [5,6]. Enquanto o uso de bobinas exploratórias tem o inconveniente de exigir alterações no motor e portanto na linha de produção industrial, o segundo método aplica-se aos motores de uso geral e exige processadores rápidos no processo de estimação.

O princípio de orientação de campo passou a ser largamente utilizado a partir do surgimento de dispositivos de potência de elevada frequência de chaveamento e microprocessadores rápidos que viabilizaram o desenvolvimento de processos algorítmicos de controle com a precisão e rapidez adequadas.

O objetivo deste capítulo é apresentar um estudo teórico do princípio do controle vetorial por orientação indireta do vetor fluxo do rotor, assim como analisar o grau de influência do problema de sensibilidade aos parâmetros no desempenho deste tanto no transitório como no regime permanente.

## 2.2. Equações Fundamentais do Controle por Orientação de Fluxo do Rotor

A máquina de indução trifásica com rotor gaiola de esquilo é representada no sistema de coordenadas  $d$ - $q$  girando na velocidade síncrona  $\omega_e$ , pelas seguintes equações [7]:

- equações de tensão do circuito de estator

$$v_{qs}^e = r_s i_{qs}^e + p \lambda_{qs}^e + \omega_e \lambda_{ds}^e \quad (2.1)$$

$$v_{ds}^e = r_s i_{ds}^e + p \lambda_{ds}^e - \omega_e \lambda_{qs}^e \quad (2.2)$$

- equações de tensão do circuito de rotor:

$$0 = v_{qr}^e = r_r i_{qr}^e + p \lambda_{qr}^e + (\omega_e - \omega_r) \lambda_{dr}^e \quad (2.3)$$

$$0 = v_{dr}^e = r_r i_{dr}^e + p \lambda_{dr}^e - (\omega_e - \omega_r) \lambda_{qr}^e \quad (2.4)$$

- equações do fluxo concatenado pelas bobinas de estator e de rotor

$$\lambda_{qs}^e = L_s i_{qs}^e + L_m i_{qr}^e \quad (2.5)$$

$$\lambda_{ds}^e = L_s i_{ds}^e + L_m i_{dr}^e \quad (2.6)$$

$$\lambda_{qr}^e = L_m i_{qs}^e + L_r i_{qr}^e \quad (2.7)$$

$$\lambda_{dr}^e = L_m i_{ds}^e + L_r i_{dr}^e \quad (2.8)$$

- conjugado eletromagnético gerado

$$T = \frac{3}{2} \frac{P}{2} \frac{L_m}{L_r} (\bar{\lambda}_{qdr} \times \bar{i}_{qds}) \quad (2.9)$$

na qual  $P$  é número de pólos e os vetores fluxo de rotor e corrente de estator são escritos como  $\bar{\lambda}_{qdr} = \lambda_{qr}^e - j \lambda_{dr}^e$  e  $\bar{i}_{qds} = i_{qr}^e - j i_{dr}^e$ .

O princípio da orientação de fluxo de rotor consiste em alinhar o fluxo do rotor segundo o eixo direto  $d$  do sistema de referência, cuja velocidade instantânea deve ser a mesma do fluxo de rotor. Desta forma, o vetor fluxo de rotor  $\bar{\lambda}_{qdr}^e$  é escrito como:

$$\bar{\lambda}_{qdr}^e = 0 - j\lambda_{dr}^e \quad (2.10)$$

ou seja, o vetor fluxo do rotor não possui componente segundo o eixo em quadratura. Em qualquer instante, a estratégia de controle por orientação de campo fundamenta-se em garantir a condição de  $\lambda_{qr}^e = 0$  e, por conseqüência,  $p\lambda_{qr}^e = 0$ .

A partir da expressão 2.10 deriva-se um conjunto de importantes relações entre as variáveis que descrevem a operação da máquina com controle por orientação de fluxo de rotor:

- considerando  $\lambda_{qr}^e = 0$  em (2.4) e substituindo a corrente  $i_{dr}^e$  dada por (2.8) obtém-se a equação para o fluxo de rotor :

$$\lambda_{dr}^e = i_{ds}^e \left( \frac{L_m}{1 + p \frac{L_r}{r_r}} \right) \quad (2.11)$$

- considerando  $\lambda_{qr}^e = 0$  em (2.9) obtém-se a expressão do conjugado eletromagnético:

$$T = \frac{3}{2} \frac{P}{2} \frac{L_m}{L_r} (\lambda_{dr}^e i_{qs}^e) \quad (2.12)$$

- com a condição de  $\lambda_{qr}^e = 0$  na expressão (2.7) obtém-se a relação

$$i_{qr}^e = -\frac{L_m}{L_r} i_{qs}^e \quad (2.13)$$

que substituída em (2.3) e considerando-se  $p\lambda_{qr}^e = 0$ , fornece a expressão da frequência de escorregamento  $\omega_s$ :



$$\omega_s = \frac{r_r}{L_r} \frac{L_m}{\lambda_{dr}^e} i_{qs}^e \quad (2.14)$$

na qual  $\omega_s = \omega_e - \omega_r$ .

A partir destas equações (2.11-2.14) pode-se afirmar que :

- O fluxo do rotor depende só da componente segundo o eixo  $d$  da corrente de estator, além disso têm características de atraso dadas pela própria constante de tempo elétrica do rotor. De forma geral o controle opera sob a condição de fluxo nominal, em outros casos o fluxo de rotor é uma variável controlada quando precisa-se trabalhar em condições de ótima eficiência [8].
- O conjugado eletromagnético apresenta uma dependência linear com a componente no eixo  $q$  da corrente de estator e com o vetor fluxo do rotor.
- A frequência de escorregamento necessária para obter o alinhamento expresso pela equação 2.11 é uma função linear da componente no eixo  $q$  da corrente de estator e uma função inversa do vetor fluxo de rotor.

O princípio do controle vetorial por orientação do fluxo do rotor pode ser ilustrado através do diagrama vetorial mostrado na Figura 2.1, no qual o desacoplamento entre o conjugado gerado e o fluxo magnético é evidenciado.

É interessante escrever a equação do conjugado eletromagnético em função da frequência de escorregamento. Substituindo-se (2.11) e (2.12) em (2.14) obtém-se:

$$T = \frac{3}{2} \frac{P}{2} \frac{\lambda_{dr}^2}{r_r} \omega_s \quad (2.15)$$

ou seja, dado um determinado valor de fluxo de rotor, o controle por orientação estabelece uma dependência linear entre o conjugado eletromagnético e a frequência de escorregamento. Por este fato, alguns autores referem-se ao controle vetorial indireto

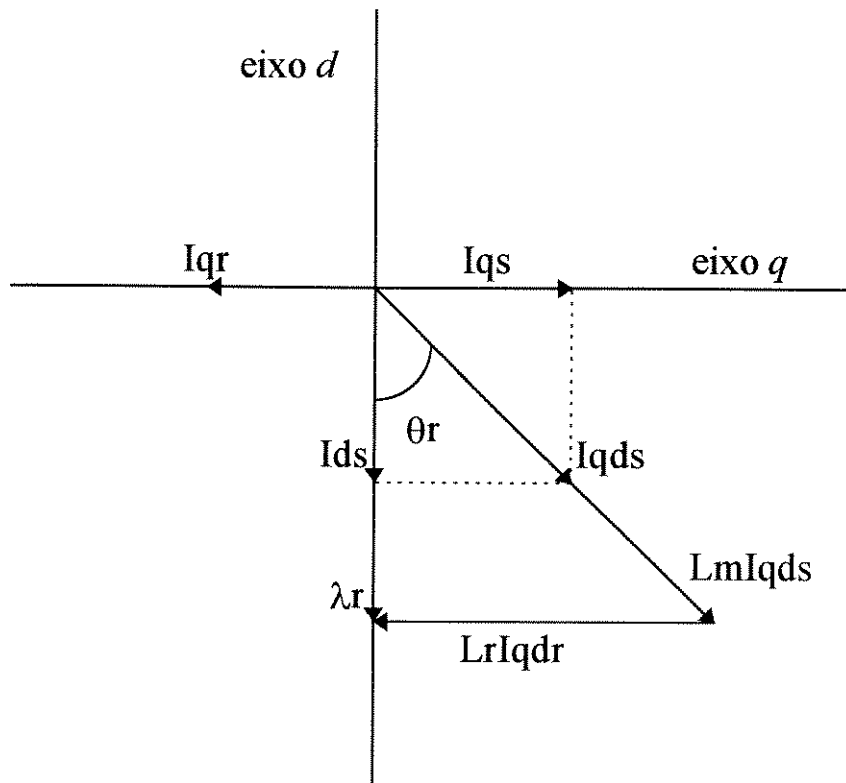


Figura 2.1- Diagrama vetorial da máquina de indução com orientação do fluxo de rotor.

por orientação de fluxo de rotor como um controle, primariamente, da freqüência de escorregamento. Esta linearidade entre conjugado e freqüência de escorregamento está ilustrada na Figura 2.2, e as características mostradas estão parametrizadas pelo fluxo de rotor  $\lambda_{dr}$ , pois ao alterar-se o fluxo  $\lambda_{dr}^e$ , altera-se a inclinação da característica  $T - \omega_s$ .

### 2.3. Características Conjugado-Freqüência de Escorregamento

A partir das equações de tensão do rotor ( 2.3 e 2.4 ) pode-se escrever, para a máquina operando em regime permanente ( $p = 0$ ), que as correntes de rotor em função da freqüência de escorregamento são dadas por:

$$i_{qr}^e = -\frac{\lambda_{dr}}{r_r} \omega_s \quad (2.16)$$

$$i_{dr}^e = -\frac{\lambda_{qr}}{r_r} \omega_s \quad (2.17)$$

Substituindo-se (2.16) e (2.17) em (2.7) e (2.8) obtém-se o seguinte sistema de equações para as componentes do vetor fluxo de rotor:

$$\lambda_{qr}^e = L_m i_{qs}^e - \frac{L_r}{r_r} \lambda_{dr}^e \omega_s \quad (2.18)$$

$$\lambda_{dr}^e = L_m i_{ds}^e - \frac{L_r}{r_r} \lambda_{qr}^e \omega_s \quad (2.19)$$

que, combinadas convenientemente, resultam nas expressões de fluxo de rotor em função das correntes de estator e da freqüência de escorregamento:

$$\lambda_{qr}^e = \frac{L_m i_{qs}^e - \frac{L_r}{r_r} \omega_s L_m i_{ds}^e}{1 + \left(\frac{L_r}{r_r} \omega_s\right)^2} \quad (2.20)$$




Figura 2.2 - Característica conjugado- frequência de escorregamento, no controle por orientação de fluxo de rotor.

$$\lambda_{dr}^e = \frac{L_m i_{ds}^e + \frac{L_r}{r_r} \omega_s L_m i_{qs}^e}{1 + \left(\frac{L_r}{r_r} \omega_s\right)^2} \quad (2.21)$$

Substituindo (2.20) e (2.21) na equação fundamental do torque (expressão 2.9) obtemos a expressão geral do conjugado eletromagnético em função da frequência de escorregamento  $\omega_s$  e da magnitude do vetor corrente de estator  $\bar{i}_{qds}$ :

$$T = \frac{3}{2} \frac{P}{2} \frac{L_m^2}{L_r} |\bar{i}_{qds}|^2 \frac{\omega_s \frac{L_r}{r_r}}{1 + \left(\omega_s \frac{L_r}{r_r}\right)^2} \quad (2.22)$$

Vale ressaltar que esta expressão é geral, não importando o método de controle adotado, pois ela estabelece a relação entre o conjugado produzido e as variáveis corrente de estator e frequência de escorregamento da máquina. Explicitando a componente  $i_{qs}^e$  em (2.14) e  $i_{ds}^e$  em (2.11), para as condições de regime, pode-se escrever para o controle por orientação do fluxo de rotor que:

$$|\bar{i}_{qds}|^2 = \frac{\lambda_{dr}^2}{L_m^2} [1 + \left(\omega_s \frac{L_r}{r_r}\right)^2] \quad (2.23)$$

e, substituindo-a em (2.22), obtém-se a expressão do conjugado (2.15), válida quando se tem a orientação de fluxo de rotor.

Na Figura 2.3 estão ilustradas as características  $T - \omega_s$  obtidas a partir de (2.22) e (2.15). Este conjunto de curvas são relativas à máquina de indução descrita no Apêndice A, considerando constantes os seus parâmetros. Uma análise do comportamento da máquina sob variação dos parâmetros será feito na seção 2.6 deste capítulo.

Podemos observar que a reta que representa a relação  $T - \omega_s$  com controle por orientação de fluxo de rotor intercepta a característica natural e não linear  $T - \omega_s$  da

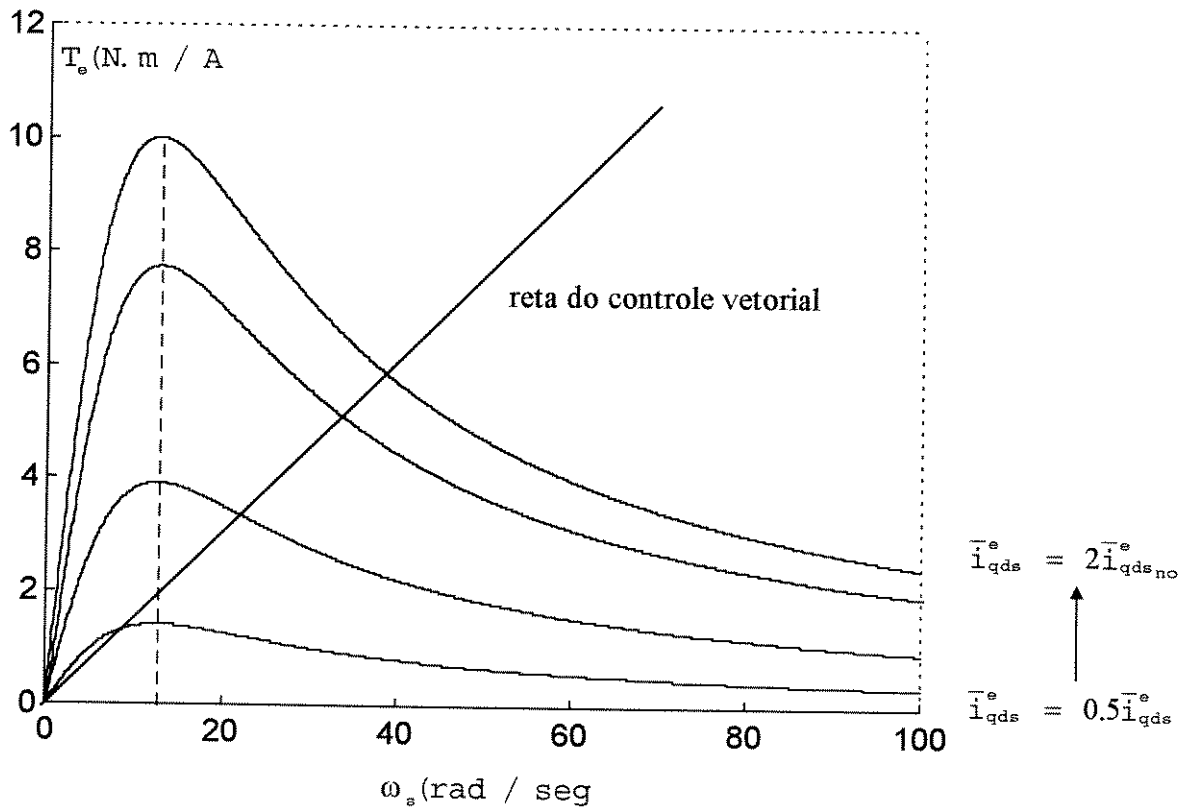


Figura 2.3 - Característica conjugado eletromagnético - frequência de escorregamento, para diferentes valores de fluxo de rotor.

máquina de indução. Este ponto de interseção, que representa o ponto de operação, está diretamente ligado ao valor das correntes de estator. Observa-se também que o valor da frequência de escorregamento para o qual se tem o conjugado máximo produzido pela máquina independe da corrente de estator, como indicado pela linha tracejada neste mesmo gráfico.

Tomando a derivada do conjugado electromagnético em relação à frequência de escorregamento obtemos:

$$\frac{dT}{d\omega_s} = \frac{3}{2} \frac{P}{2} \frac{L_m^2}{L_r} |i_{qds}|^2 \frac{L_r}{r_r} \frac{1 - (\omega_s \frac{L_r}{r_r})^2}{(1 + (\omega_s \frac{L_r}{r_r})^2)^2} \quad (2.24)$$

Como no ponto em que ocorre o máximo da função temos

$$\frac{dT}{d\omega_s} = 0 \quad (2.25)$$

e considerando este fato em (2.24) obtemos o valor da frequência de escorregamento que define o máximo conjugado produzido pela máquina como sendo dado por:

$$\omega_s = \frac{r_r}{L_r} \quad (2.26)$$

e substituindo este resultado em (2.22) obtemos o valor máximo do conjugado electromagnético:

$$T_{max} = \frac{3}{2} \frac{P}{2} \frac{L_m^2}{L_r} \frac{|i_{qds}^e|^2}{2} \quad (2.27)$$

Fica claro que o valor do conjugado máximo apresenta uma dependência quadrática com a indutância de magnetização, mostrando o efeito negativo da saturação magnética, já que o valor de  $L_m$  diminui com a saturação magnética.

Como já foi observado o valor da inclinação da reta do controle por orientação de fluxo de rotor determina a posição desta em relação ao ponto de máximo conjugado.

Se o valor de fluxo do rotor for alterado, a inclinação da reta aumenta, como mostrado na Figura 2.4. Observa-se que à medida que aumentamos o valor de fluxo do rotor a característica da curva de controle vetorial se aproxima do ponto de operação de conjugado máximo para um valor fixo da corrente de estator. De certa forma este comportamento sugere trabalhar com valores de fluxo maiores com o objetivo de obter a maior capacidade de conjugado electromagnético por ampère. De outro lado, à medida que aumentamos o valor do fluxo deve-se levar em conta no modelo da máquina o fenômeno da saturação magnética e, conseqüentemente, a variação de parâmetros.

Portanto, modificações devem ocorrer naquilo que até agora discutimos, pois em nossas análises consideramos que os parâmetros da máquina eram constantes. Existem alguns trabalhos [9] em que a máxima eficiência e o máximo conjugado por ampère são procurados, selecionando a magnitude do fluxo de rotor conveniente e levando em conta o efeito da variação da indutância de magnetização. Os problemas derivados das mudanças dos parâmetros da máquina no comportamento do controle serão comentados a partir da seção 2.6 deste capítulo.

#### 2.4. Característica Fluxo de Rotor - Frequência de Escorregamento

Com o objetivo de estudar a característica de fluxo do rotor - frequência de escorregamento usaremos um enfoque similar ao usado no caso do conjugado eletromagnético. Obtendo, primeiramente, a curva geral do fluxo de rotor em função da frequência de escorregamento e do vetor corrente  $i_{qds}$ , para depois particularizar ao caso do controle vetorial.

A partir das componentes do fluxo do rotor nos eixos  $d$  e  $q$  é possível expressar o módulo deste como segue:

$$\left| \bar{\lambda}_{qdr}^e \right| = \sqrt{\lambda_{qr}^e{}^2 + \lambda_{dr}^e{}^2} \quad (2.28)$$



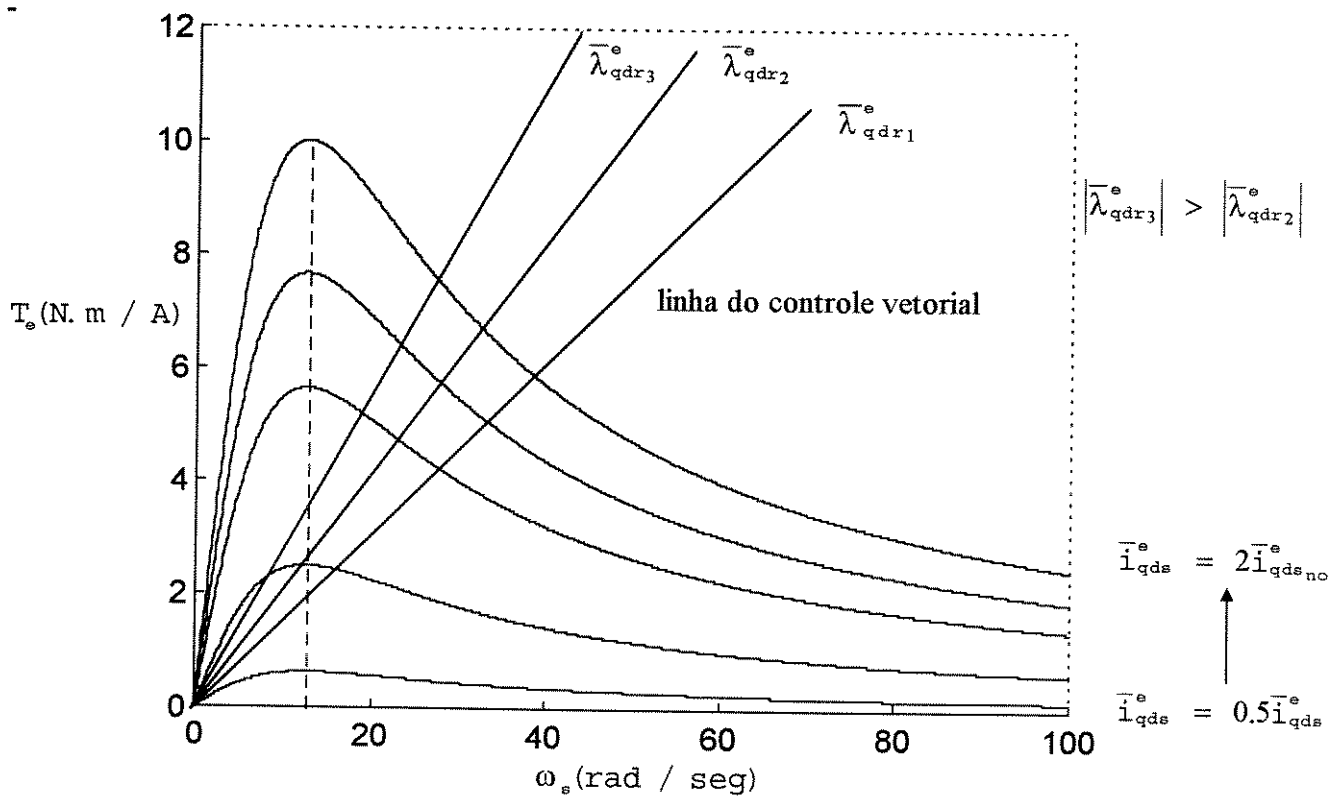


Figura 2.4 - Gráfico de conjugado eletromagnético - frequência de escorregamento da máquina para o casos geral (curvas não lineares) e com orientação (retas parametrizadas pelo fluxo  $\lambda_{qdr}$ ).

Substituindo-se as equações 2.20 e 2.21 em (2.28) obtemos a expressão geral da magnitude do fluxo de rotor em função das correntes do estator e da frequência de escorregamento:

$$\left| \lambda_{qdr}^e \right| = \frac{L_m r_r}{\sqrt{r_r^2 + (\omega_s L_r)^2}} \left| i_{qds}^e \right| \quad (2.29)$$

A partir desta expressão obtemos a família de curvas mostradas na Figura 2.5 para diferentes valores de corrente de estator relativa ao seu valor nominal para a máquina do apêndice A.

Como pode ser observado na Figura 2.5, a linha do controle vetorial é paralela ao eixo da frequência de escorregamento como sugere a equação (2.12) para a máquina operando em regime permanente. Geralmente, na operação da máquina de indução o valor do fluxo de rotor escolhido é o nominal, pois valores acima deste pode levar a máquina a saturação magnética com a conseqüente queda de desempenho do estado transitório e o de regime permanente. Pode-se ainda, operar com valores de fluxo abaixo do nominal (enfraquecimento de campo), quando se quer otimizar a eficiência da máquina em condições de cargas leves ou mesmo quando se deseja altas velocidades.

## 2.5. Características Transitórias da Velocidade e do Conjugado, para Variação em Degrau de $I_{qs}$

Um dos testes mais usuais na avaliação do controle por orientação de fluxo é o da aceleração e frenagem da máquina, não necessariamente com inversão. Este teste consiste em tomar curvas do conjugado e da velocidade quando o motor é alimentado com a componente da corrente de estator  $i_{qs}$  tendo a forma de onda quadrada e a componente  $i_{ds}$  sendo mantida constante.




Figura 2.5 - Característica do fluxo de rotor - frequência de escorregamento, para a máquina sob orientação indireta de fluxo (linha paralela ao eixo de  $\omega_s$ ) e para a situação em que não se tem a orientação.

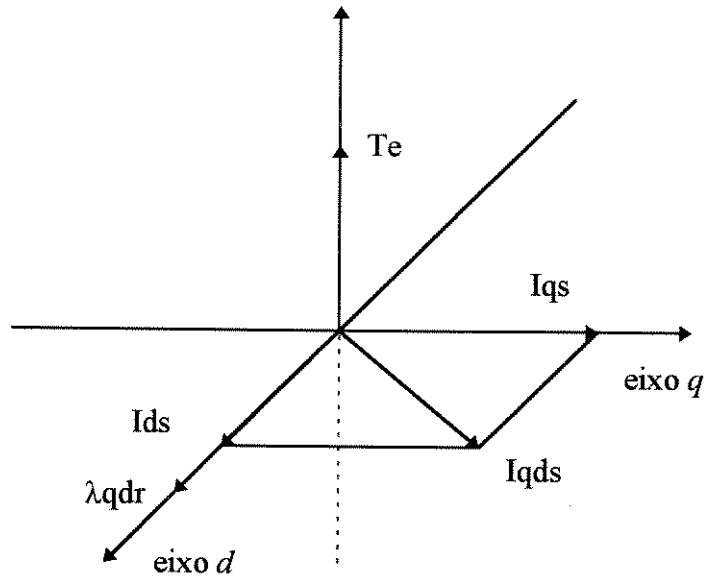
O diagrama vetorial do controle com parâmetros constantes, indicando o sentido do vetor conjugado eletromagnético está ilustrado na Figura 2.6. Como, a partir da equação 2.10 o conjugado é o resultado do produto vetorial dos vetores corrente de estator  $I_{qds}$  e fluxo de rotor  $\lambda_{qdr}$ , a direção do conjugado é perpendicular ao plano em que se encontram os vetores corrente e fluxo, e o sentido sendo determinado pela regra da mão direita. Dos diagramas vetoriais da Figura 2.6, observa-se que se o vetor  $I_{qds}$  for invertido, inverte-se o sentido do conjugado eletromagnético produzido pela máquina. Esta inversão de sentido provoca frenagem e, se for mantida por um tempo apropriado, conduz à inversão na velocidade da máquina.

Para o controle por orientação de fluxo de rotor, qualquer mudança na corrente  $i_{qs}$  não interfere nas variáveis de eixo direto da máquina. Sendo assim, a partir da equação 2.12, concluímos que, se os parâmetros do motor são constantes, o conjugado gerado tem uma dependência linear com a componente de corrente  $i_{qs}$  e apresentando um perfil ao longo do tempo igual ao desta corrente.


Na faixa em que conjugado é constante a aceleração da carga também será constante, e portanto a velocidade ( $\omega = \int accel. = K.t$ ) terá um perfil linear de crescimento ou de diminuição, dependendo do sentido do conjugado, como mostrado na Figura 2.7.

## 2.6. Sensibilidade aos Parâmetros

As equações 2.12, 2.13 e 2.14 obtidas para o fluxo do rotor, conjugado eletromagnético e frequência de escorregamento, respectivamente, sob condição de orientação de fluxo de rotor, possuem uma forte dependência com os parâmetros da máquina. Por exemplo, se o valor de comando da frequência de escorregamento definido pela equação 2.14 diferir do real, a condição expressa na equação 2.11 deixa de ser válida, significando com isto que o vetor fluxo do rotor não estará mais alinhado com o eixo direto. Desta forma, haverá o acoplamento entre as variáveis de controle e a consequente deterioração do controle.



(a)



(b)

Figura 2.6 - Diagrama vetorial da máquina com de orientação do fluxo de rotor indicando a direção do conjugado eletromagnético para  $i_{qs}$  (a) positivo e (b) negativo.




Figura 2.7 - Características transitória ideais do conjugado e da velocidade quando a componente de corrente  $i_{qs}$  varia em degrau.

Os parâmetros da máquina mudam com a temperatura de trabalho e com a saturação magnética, sendo mais afetadas a resistência e a indutância de magnetização. A temperatura do rotor pode atingir valores de até 150°C acima da temperatura ambiente, provocando um aumento na resistência do rotor de 50% no seu valor nominal. O efeito de saturação magnética na indutância de magnetização pode diminuir o seu valor até 80% do nominal. A partir de estudos, Krishnan, Doran et al [10] mostram limites superior e inferior de variação da constante de tempo do rotor  $T_r$  em relação ao seu valor nominal  $T_r^*$ . Assim, para a variações típicas de resistência do rotor, temos

$$0.5 < \frac{T_r}{T_r^*} < 1.5 \quad (2.30)$$

e, para o caso de alteração da indutância de magnetização,

$$0.8 < \frac{T_r}{T_r^*} < 1.2. \quad (2.31)$$

Da equação 2.14 observa-se que o valor de comando da frequência de escorregamento que garante o desacoplamento, depende do valor exato da constante de tempo elétrica do rotor da máquina. No controle indireto por orientação do fluxo de rotor, as variáveis independentes são a corrente de estator e a frequência de escorregamento. O erro no cálculo da frequência de escorregamento de referência leva a determinação incorreta da posição espacial do fluxo de rotor e, portanto, prejudicando as respostas transitória e de regime permanente do controle.

Da mesma forma que expressamos o fluxo de rotor em função das variáveis independentes  $i_{qs}$ ,  $i_{ds}$  e  $\omega_s$  (equações 2.20 e 2.21), podemos também fazer o mesmo com as correntes de rotor. Substituindo (2.20) e (2.21) em (2.7) e (2.8), obtemos

$$i_{qr}^e = \frac{L_m i_{qs}^e - \frac{L_r}{r_r} \omega_s L_m i_{ds}^e}{L_r (1 + (\frac{L_r}{r_r} \omega_s)^2)} - \frac{L_m i_{qs}^e}{L_r} \quad (2.32)$$

$$i_{dr}^e = \frac{L_m^i e_{qs} - \frac{L_r}{r_r} \omega_s L_m^i e_{ds}}{L_r (1 + (\frac{L_r}{r_r} \omega_s)^2)} - \frac{L_m^i e_{ds}}{L_r} \quad (2.33)$$

A partir de (2.20), (2.21), (2.32) e (2.33) são obtidos os lugares dos vetores corrente e fluxo do rotor parametrizados pelo escorregamento, para o vetor corrente de estator constante, como mostrados na Figura 2.8. Observa-se que a frequência de escorregamento é diretamente responsável pela posição relativa entre os vetores fluxo do rotor e corrente de estator. Como o conjugado eletromagnético é diretamente proporcional ao produto vetorial entre estes dois vetores, é evidente que o valor do escorregamento produzido vai influenciar no conjugado da máquina, estando a máquina sob orientação ou não. As equações 2.20 e 2.21 reduzem-se às do controle vetorial com orientação indireta do vetor fluxo do rotor, substituindo nela o valor de comando da frequência de escorregamento dado pela equação 2.14.

O efeito de valores incorretos na frequência de escorregamento pode ser ilustrado através de diagramas vetoriais obtidos a partir das expressões (2.20), (2.21), (2.29) e (2.30). Na Figura 2.9 estão mostrados os diagramas vetoriais correspondentes à situação em que a frequência de escorregamento de comando gerada pelo controle é maior que a necessária para obter o desacoplamento ideal (Fig. 2.9a) e a situação em que o escorregamento de comando é menor que o ideal (Fig. 2.9b).

Dos diagramas vetoriais observa-se que, no caso em que a frequência de escorregamento é menor que a ideal, o valor em estado estacionário do fluxo do rotor vai ser maior que o desejado, localizando-se no quarto quadrante. Por sua vez, no caso deste escorregamento ser maior que o ideal, o valor do fluxo do rotor em estado estacionário será menor que o desejado, localizando-se no terceiro quadrante. Para concluir sobre o efeito do erro no valor de referência da frequência de escorregamento no valor do conjugado gerado, é necessário ter informação da posição espacial entre os vetores fluxo do rotor e corrente de estator, pelo fato de que o conjugado eletromagnético é proporcional ao produto vetorial destes dois vetores e, isto vai ser considerado posteriormente nesta seção.




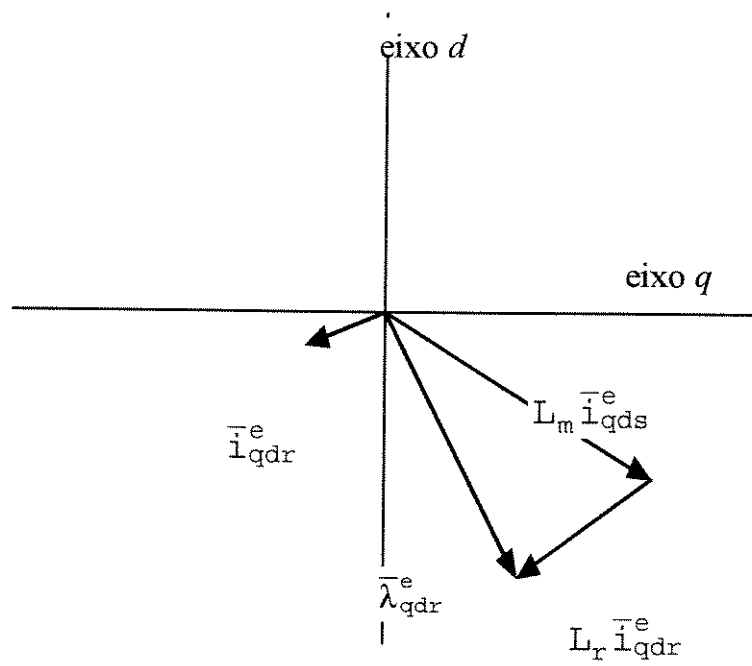



Figura 2.8 - Lugares da corrente e do fluxo de rotor parametrizados pelo escorregamento, com o vetor corrente de estator constante.



(a)



(b)

Figura 2.9- Diagrama vetorial para os casos em que frequência de escorregamento de comando (a) menor e (b) maior que a necessária.

### 2.7. Influência do Grau de Acoplamento nas Características de Regime do Conjugado, Fluxo e Velocidade

Para estudar o comportamento do conjugado eletromagnético da máquina em função do grau de acoplamento, utilizaremos um procedimento semelhante aquele da seção 2.5.

Definindo o grau de acoplamento como:

$$K_r = \frac{T_r}{T_r^*} \quad (2.34)$$

O escorregamento usado no controle será dado por:

$$\omega_s = \frac{K_r i_{qs}^e}{T_r i_{ds}^e} \quad (2.35)$$

Quando a constante de tempo do rotor adotada está correta não existe diferença entre a especificada e a real, resultando em  $K_r = 1$ . É claro, que neste caso a máquina apresenta um perfeito desacoplamento entre o fluxo e o conjugado eletromagnético, e a frequência de escorregamento  $\omega_s$  expressa por (2.35) será idêntica àquela dada por (2.14).

Substituindo (2.34) e (2.35) em (2.22), obtemos a seguinte expressão para o conjugado eletromagnético da máquina em função da frequência de escorregamento:

$$T = \frac{3 P L_m^2}{2 2 r_r} i_{ds}^2 \omega_s \left( \frac{K_r^2 + T_r^2 \omega_s^2}{K_r^2 + K_r^2 T_r^2 \omega_s^2} \right) \quad (2.36)$$

Para o desacoplamento ideal em que  $K_r = 1$ , esta expressão reproduz aquela obtida para o caso de orientação perfeita (equação 2.26) na qual existe uma relação linear entre o conjugado e a frequência de escorregamento  $\omega_s$ . Já, no caso geral em que  $K_r \neq 1$ , o conjugado apresenta uma relação não linear com  $K_r$  e  $\omega_s$ , como indica o termo entre parênteses na expressão 2.36.

No caso de ocorrer o acoplamento, o conjugado eletromagnético produzido apresenta uma variação em relação aquele obtido na condição de desacoplamento ideal, para uma dada frequência de escorregamento. Este comportamento pode ser demonstrado matematicamente a partir das equações obtidas tanto para o caso geral como particular; substituindo a equação 2.36 na equação 2.15:

$$\Delta T = \frac{(K_r^2 - 1) \omega_s^2 T_r^2}{K_r^2 (1 + \omega_s^2 T_r^2)} \quad (2.37)$$

na qual  $\Delta T$  é o erro absoluto do conjugado eletromagnético relativo ao seu valor para a condição de desacoplamento ideal. Para  $K_r > 1$  (ganho do escorregamento maior que o ideal) o erro no conjugado resulta em  $\Delta T > 0$ , e para  $K_r < 1$ , tem-se  $\Delta T < 0$ .

A expressão do fluxo do rotor em função do coeficiente de acoplamento e da frequência de escorregamento pode ser obtida substituindo a equação 2.35 em 2.29, resultando:

$$\lambda_{dr}^e = L_m^i e \frac{\sqrt{1 + \left(\frac{\omega_s T_r}{K_r}\right)^2}}{\sqrt{1 + (\omega_s T_r)^2}} \quad (2.38)$$

A partir desta equação algumas conclusões importantes podem ser extraídas:

- A curva ideal de orientação de campo corresponde ao termo  $L_m^i e$  e a expressão 2.38 aparece modificada por um fator que depende do escorregamento de operação e do grau de acoplamento  $K_r$ . Este fato também ocorreu para conjugado eletromagnético.
- Uma análise da equação, permite verificar o comportamento ilustrado anteriormente por meio de diagramas vetoriais. Por exemplo, suponhamos que o ganho do escor-

regamento usado no controle seja menor que o real. Neste caso o fator  $K_r$  é menor que a unidade, logo o termo dentro do parênteses do numerador será maior que o correspondente termo do denominador e, conseqüentemente, o valor do fluxo do rotor aumentará em relação ao valor de regime do controle por campo orientado. No caso de termos  $K_r > 1$ , o valor de regime do fluxo do rotor será menor que o obtido pela orientação de campo quando o controle encontrava-se na condição de desacoplamento perfeito.

- Como foi discutido no caso do fluxo do rotor o grau de acoplamento faz com que o fluxo do rotor no estado de regime permanente aumente ou diminua e é evidente que este fato refletirá no conjugado eletromagnético gerado pela máquina. Sendo o conjugado proporcional ao produto vetorial dos vetores fluxo do rotor e corrente de estator do motor, devemos também considerar o ângulo espacial entre os vetores fluxo do rotor e corrente de estator ( este ângulo e também conhecido como ângulo da impedância do rotor).

Nordin et al [11] mostram que embora a amplitude do fluxo do rotor aumente com o incremento no erro  $T_r / T_r^* < 1$ ,  $K_r < 1$ , o ângulo de impedância do rotor diminui e o seno deste também. A diminuição no ângulo de impedância do rotor é maior que o aumento na magnitude do fluxo do rotor e como conseqüência o valor do conjugado electromagnético da máquina no estado estacionário vai ser menor que o correspondente para o caso de desacoplamento perfeito. No caso de  $T_r / T_r^* > 1$ ,  $K_r > 1$ , foi comentado o fato de que o fluxo do rotor diminui, por outra parte ocorre um incremento do angulo de impedância do rotor e conseqüentemente do seno deste angulo, para esta condição a diminuição no fluxo do rotor é maior que o aumento no angulo respectivamente, por conseguinte o conjugado electromagnético diminui. As conclusões feitas anteriormente para o conjugado eletromagnético não podem ser generalizadas independentemente da potência do motor, com está discutido neste mesmo trabalho de Nordin. Mostra-se que para motores de indução de grande potência, a existência de uma indutância de magnetização maior faz com que dentro da condição

$T_r / T_r^* < 1$ , existam faixas de aumento do conjugado em relação ao esperado. No trabalho de Lipo esta comparação é feita entre motores de indução de 1 hp e de 100 hp.

## 2.8. Características de Resposta da Velocidade em Função do Grau de Acoplamento do Controle Vetorial.

Como visto anteriormente, o grau de acoplamento do controle vetorial modifica as características de fluxo e conjugado eletromagnéticos da máquina. Como a velocidade está relacionada com os conjugados eletromagnético e de carga, é necessário analisar a resposta de velocidade quando há perda da condição de desacoplamento ideal.

Para estudar as características de velocidade do motor diante de variações no grau de acoplamento no controle, adotaremos para a máquina o modelo linearizado em torno de um determinado ponto de operação, como apresentado no artigo de Yau-Tze Kao et al [12]. O diagrama de blocos do modelo desenvolvido neste trabalho está mostrado na Figura 2.10 (a), na qual  $G_C(s)$  é a função de transferência do regulador usado na malha de velocidade e  $T_m$  é constante de tempo mecânica referente às partes girantes.

O estudo do efeito do erro no ganho da frequência de escorregamento na resposta de velocidade da máquina será feito de maneira análoga ao caso de parâmetros constantes, ou seja o sistema é submetido a uma entrada degrau de corrente de estator  $I_{qs}$  que está associada à produção de conjugado eletromagnético. É importante assinalar que neste teste a malha de velocidade não é considerado, ou seja, a magnitude da onda da corrente  $I_{qs}$  não é corrigida pelo erro de velocidade. Na Figura 2.10 (b) está colocada a estrutura em diagrama de blocos do sistema utilizado na obtenção de transitórios de velocidade através de simulação e, na Figura 2.11, estão apresentados os resultados obtidos para os casos em que a relação  $T_r / T_r^*$  é igual a 1, 0.5 e 2. Como se observa, se a frequência de escorregamento gerada pelo controlador estiver errada, a velocidade transitória da máquina apresentará uma característica não linear. A inclinação da res-

posta de velocidade, no início do processo, é inferior ao do caso ideal quando o valor gerado do escorregamento é maior que o efetivo, e superior no caso contrário.

É necessário assinalar que os perfis das curvas de velocidade obtidas, no caso ideal ou com erro no ganho da frequência de escorregamento, baseiam-se na hipótese de que o motor opere com cargas leves no seu eixo. Se estiver operando com grandes cargas, a fricção e as características inerciais da carga devem ser consideradas no modelo.

## 2.9. Considerações de Estabilidade

Uma vez analisadas e comentadas as características de resposta da velocidade do motor quando é submetido, em malha aberta, à uma entrada degrau de corrente  $I_{qs}$ , falta-nos analisar o comportamento da resposta dinâmica de velocidade quando é fechado a malha de velocidade. Assumindo no diagrama de blocos da Figura 2.10 (a) que  $G_c(s) = K_p + \frac{K_I}{s}$  representa um regulador PI convencional que fornece na sua saída o valor de  $I_{qds}$  necessário para uma determinada referência de velocidade, a relação entre as velocidades de referência do sistema  $\omega_r(s)$  e a real no domínio da frequência  $\omega_r^*$  será dada por:

$$\frac{\omega_r(s)}{\omega_r^*(s)} = \frac{G(s)H(s)}{1 + G(s)H(s)} \quad (2.39)$$

na qual

$$G(s) = \frac{(K_p + \frac{K_I}{s})(s + \frac{1}{T_r^*})}{(s + \frac{1}{T_r})(s + \frac{1}{T_m})} \quad (2.40)$$

Para analisar a resposta dinâmica de velocidade em malha fechada consideremos  $H(s) = 1$ , e submetamos o sistema a um sinal de referência de velocidade do tipo degrau de amplitude unitária, ou seja,

$$\omega_r(s) = \frac{1}{s} \quad (2.42)$$

Quatro valores da relação  $T_r^* / T_r$  foram consideradas na simulação: (1)  $T_r^* / T_r = 1$ , (2)  $T_r^* / T_r = 1.25$ , (3)  $T_r^* / T_r = 2$  e (4)  $T_r^* / T_r = 10$ . Embora seja muito difícil termos este último valor, ele é considerado apenas para aumentarmos a compreensão do efeito do grau de influência do acoplamento na resposta. Os resultados estão mostrados na Figura 2.12.

Dos resultados de simulação, observa-se que à medida que a relação  $T_r^* / T_r$  aumenta, a resposta dinâmica de velocidade piora, levando a um maior tempo de regime. Para o caso em que  $T_r^* / T_r = 10$ , este tempo de regime é aproximadamente 8 vezes daquele verificado para o caso de desacoplamento ideal (primeiro caso). Por outro lado, o sistema começa também a apresentar características oscilatórias, à medida que cresce a relação  $T_r^* / T_r$ .

Os resultados obtidos a partir da simulação podem ser fundamentados com maior rigor, a partir de estudos teóricos do sistema de malha fechada no domínio da frequência. Como exemplo, podemos estudar a alocação dos pólos e zeros do sistema em função da relação  $T_r^* / T_r$ .

Dos diagramas de pólos e zeros mostrados na Figura 2.13, observa-se a presença de dois pólos complexos conjugados que se aproximam do eixo imaginário à medida que cresce a relação  $T_r^* / T_r$ . A resposta dinâmica de um sistema estável de ordem superior pode ser analisada como a soma de curvas exponenciais e senoidais amortecidas [13]; em particular os pólos de malha fechada do sistema aparecem na solução como termos exponenciais, a distância de um pólo de malha fechada ao eixo imaginário vai deter-



minar o tempo de estabelecimento do transitório associado a este; sendo que quando maior for esta distância, maior será o tempo de estabelecimento. Neste caso particular, a proximidade dos pólos do eixo imaginário faz com que aumente as características oscilatórias na resposta do sistema.

Um outro enfoque que nos permite ampliar o nosso conhecimento sobre a velocidade de resposta do sistema está relacionada com o estudo da resposta de frequência do sistema em malha fechada. Esta análise pode ser feita a partir dos diagramas logarítmicos de amplitude e fase em função da frequência ( diagramas de Bode ) que aplicada ao nosso caso fornece as curvas mostradas nas Figuras 2.14 e 2.15.

Adotando a definição de largura de banda, dada por Ogata [13], como sendo a faixa de frequências  $0 \leq \omega \leq \omega_c$  para a qual a amplitude em função da frequência não cai a níveis abaixo de 3 db do seu valor na frequência 0, podemos concluir, a partir dos resultados mostrados, que a largura de banda do sistema decresce à medida que a relação  $\frac{T_r^*}{T_r}$  aumenta. Em consequência disto, a velocidade de resposta do sistema diminui, como já tínhamos observado nas curvas mostradas na Figura 2.12, nas quais ficou evidente o aumento do tempo de estabelecimento da resposta transitória.

## 2.10. Breve Histórico dos Métodos de Solução do Problema de Sensibilidade aos Parâmetros

A preocupação dos pesquisadores da área de controle de máquinas elétricas diante o problema de sensibilidade aos parâmetros tem-se constituído em uma intensa atividade de pesquisa e, vários estudos e implementações estão presentes na literatura especializada. Nesta seção, é feita uma breve revisão histórica dos métodos de solução do problema de sensibilidade aos parâmetros, dirigida aos interesses deste trabalho.

Uma das primeiras publicações, com as características acima citadas e que serviu de base a estudos posteriores, corresponde a Garcés [39], o qual utiliza como medida do acoplamento do controle, uma expressão modificada da potência reativa que é função

de tensões e correntes medidas. O princípio do método implementado no trabalho consiste no cálculo da função proposta para condições atuais do motor, assim como o cálculo desta para a condição de desacoplamento ideal; o erro entre os valores resultantes deste cálculo, permite inferir a variação ocorrida na constante de tempo do rotor. Para ajustar a constante usada no controle, esta variação é somada à constante atual. Uma desvantagem do método de Garcés está no fato de que não são considerados os efeitos da saturação magnética.

Em outros trabalhos [40,41,42,43], diversas abordagens para tratar este problema são estudadas e em muitos casos implementadas. Em particular, Lorenz [44] estuda as características de resposta de velocidade do controle indireto por orientação do fluxo do rotor, quando o sistema é submetido a uma onda quadrada na referência da componente de corrente de estator no sistema síncrono, associada com o conjugado eletromagnético ( $i_{qs}^e$ ). Curvas típicas deste teste, obtidas a partir de simulação foram mostradas e analisadas na seção 2.8 deste capítulo, para diferentes valores da relação  $\frac{T_r}{T_r^*}$ . Lorenz propõe usar as características de resposta transitória da velocidade a este tipo de teste como uma medida da variação da constante de tempo do rotor. Uma outra característica deste método é a de manter a estrutura convencional do controle indireto invariável em termos de aquisição, ou seja não é necessário adquirir sinais adicionais, além das medições de correntes e velocidade requeridas pelo controle. Deve ser considerado, que a forma do perfil de velocidade mostrado, é válido quando o motor opera com cargas leves, ou para cargas puramente inerciais.

No capítulo 5 deste trabalho, é apresentado um sistema de identificação da constante de tempo do rotor utilizando Redes Neurais Artificiais, o qual utiliza como base o teste proposto por Lorenz.

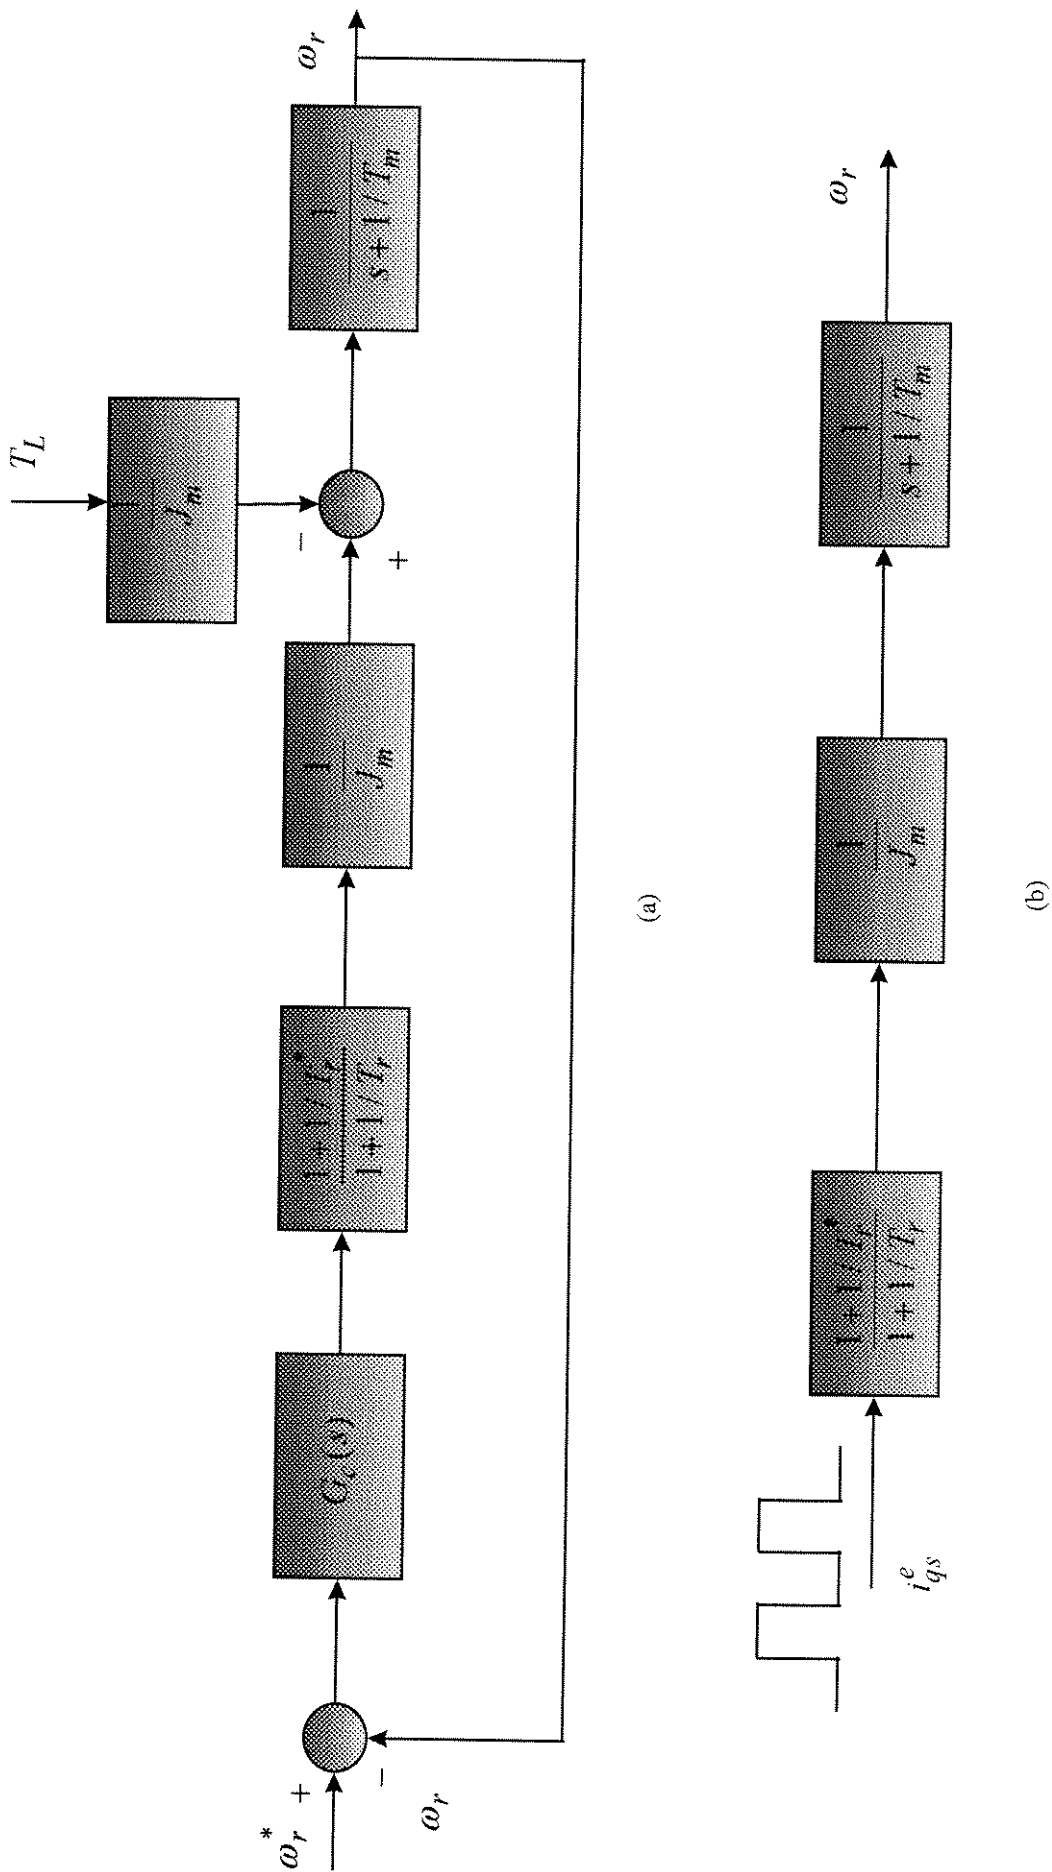


Figura 2.10 - Diagrama de blocos do sistema de controle utilizado na simulação. (a) malha fechada (b) malha aberta.




Figura 2.11 - Perfis de velocidade para variação em degrau da corrente  $I_{qs}$  nos seguintes casos: (a)  $K_r = 1$ , (b)  $K_r = 0.5$ ,  $K_r = 2$ .

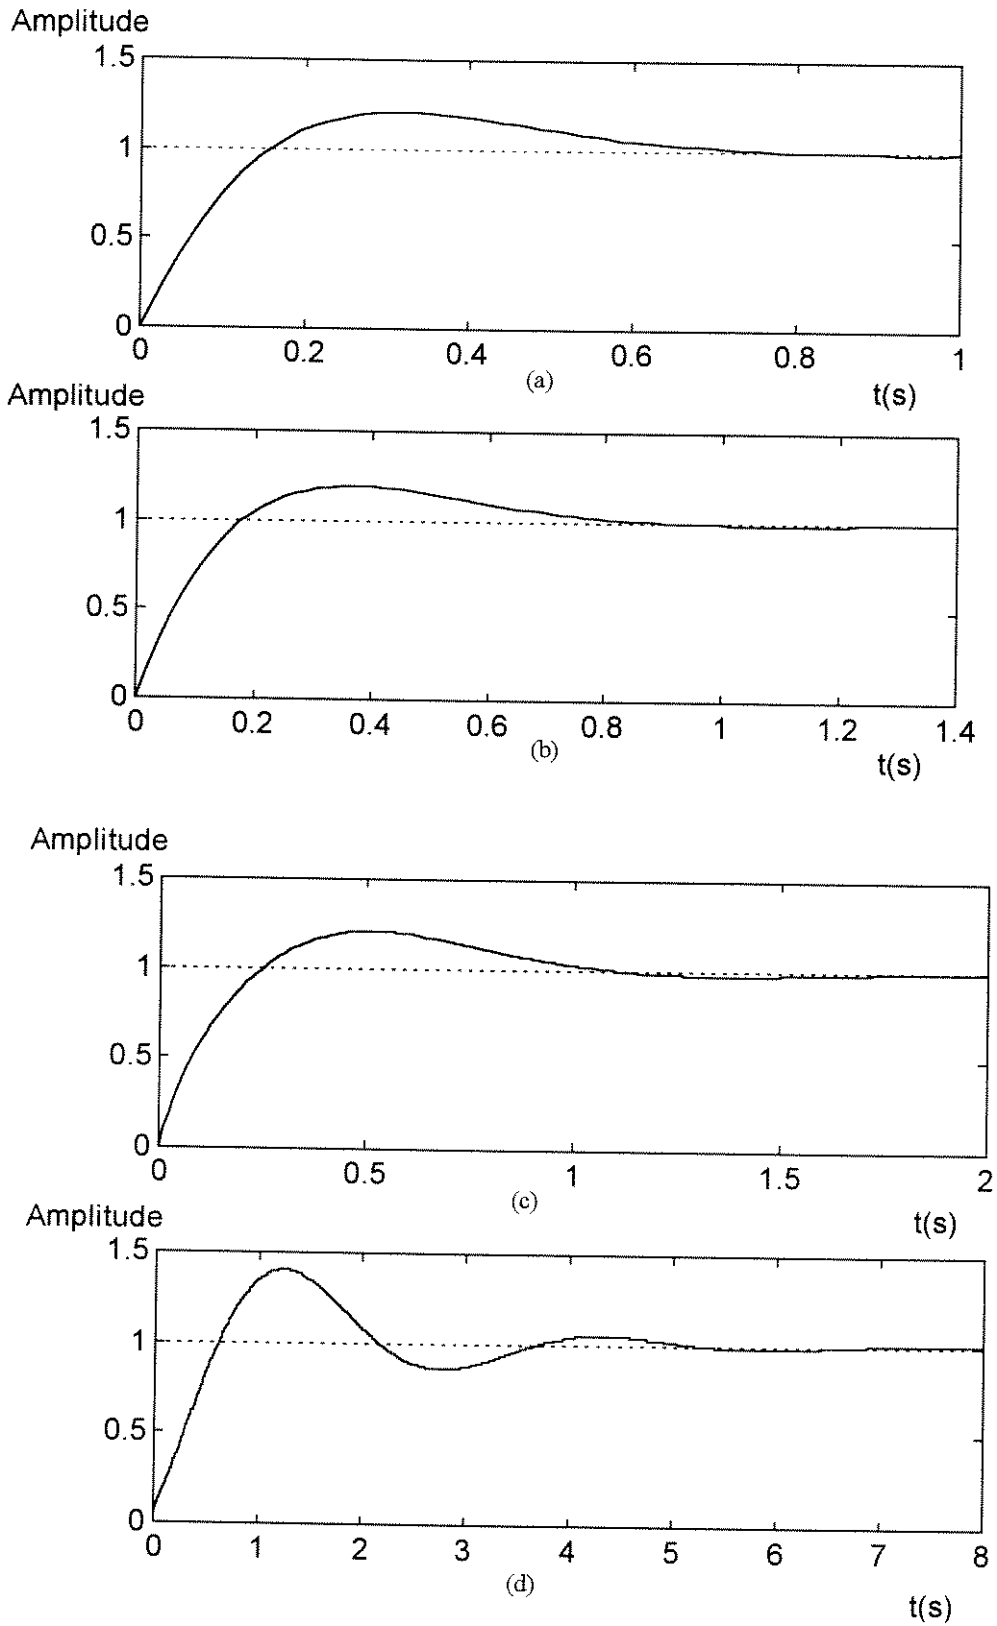


Figura 2.12 - Resposta de velocidade a um degrau de referência para os valores de  $T_r^* / T_r$  :

(a) 1 (b) 1.25 (c) 2 e (d) 10.

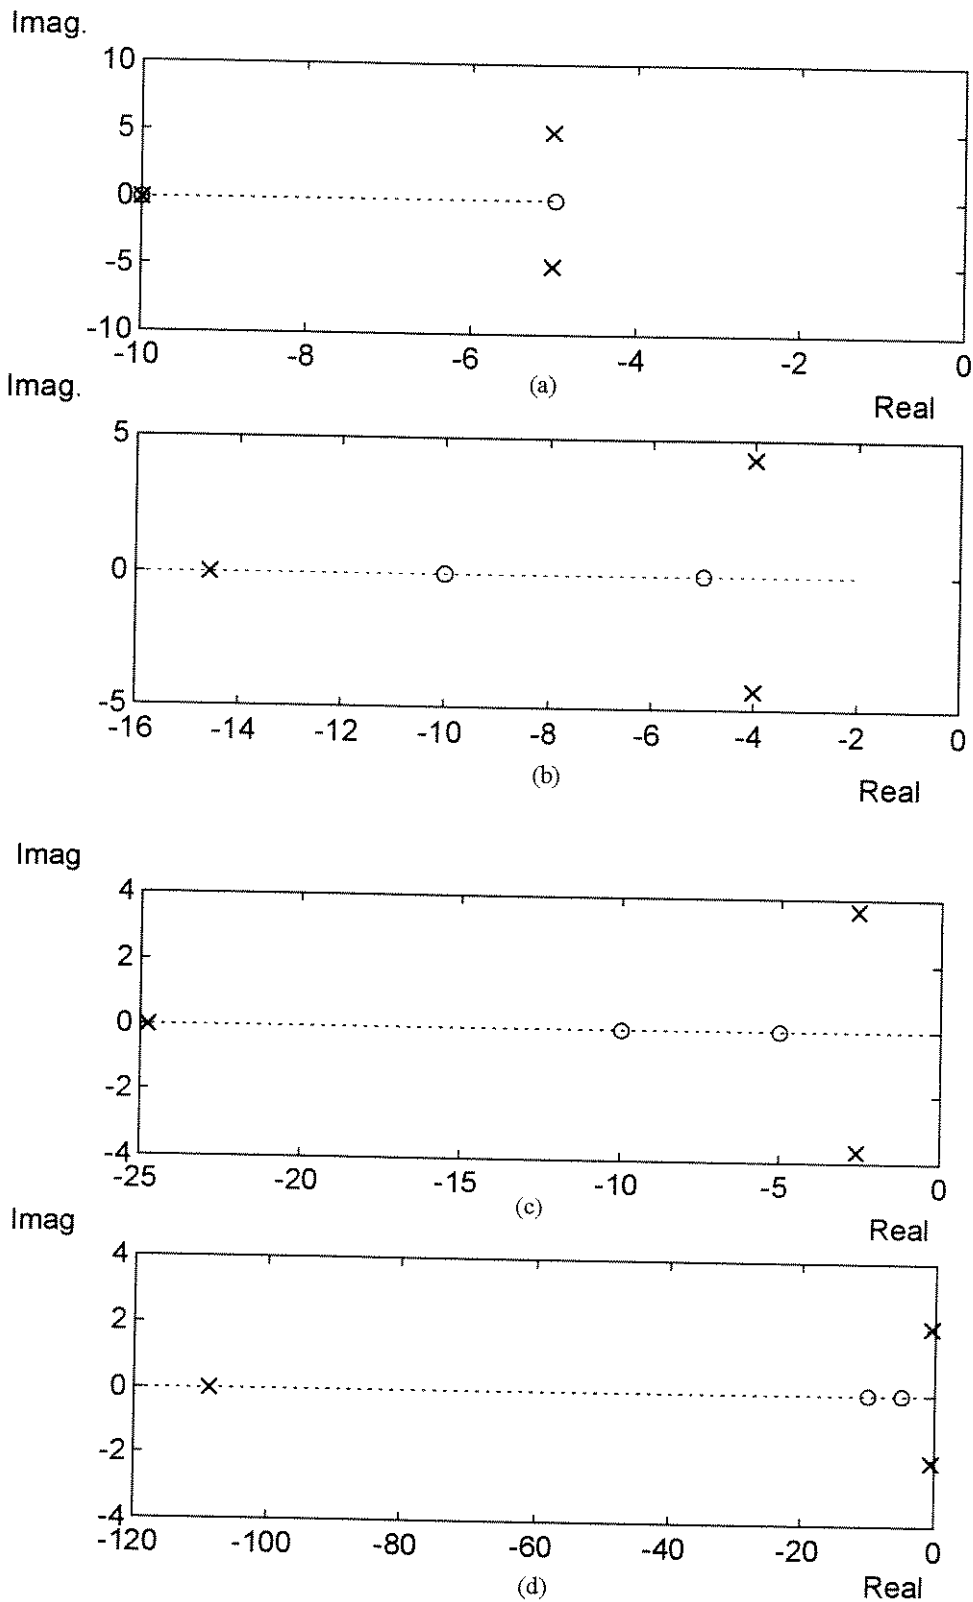
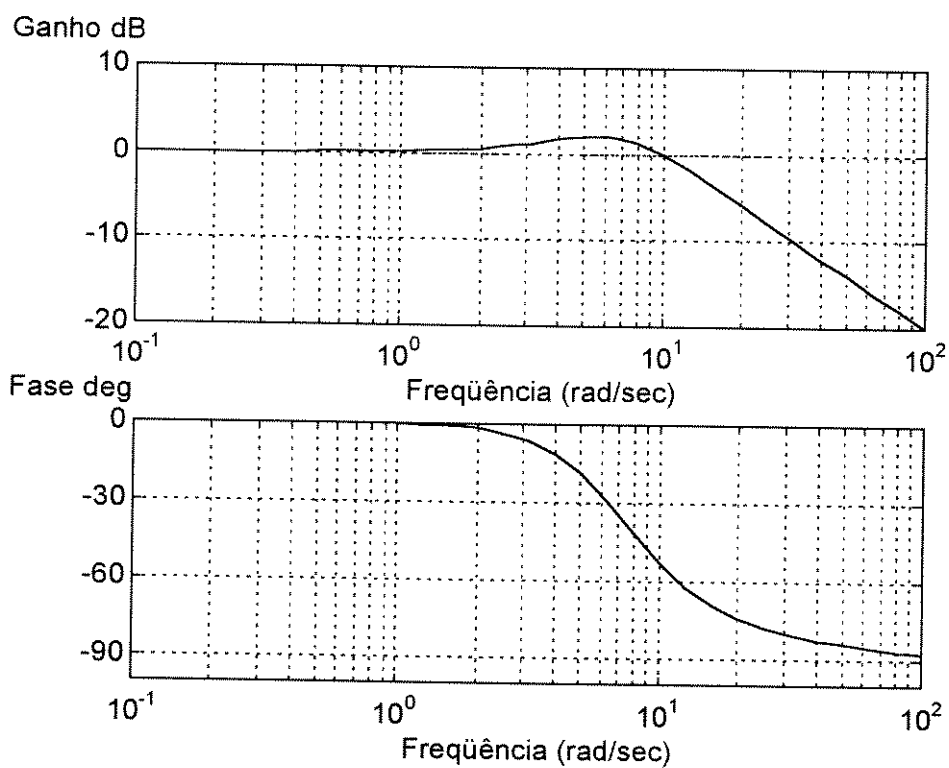
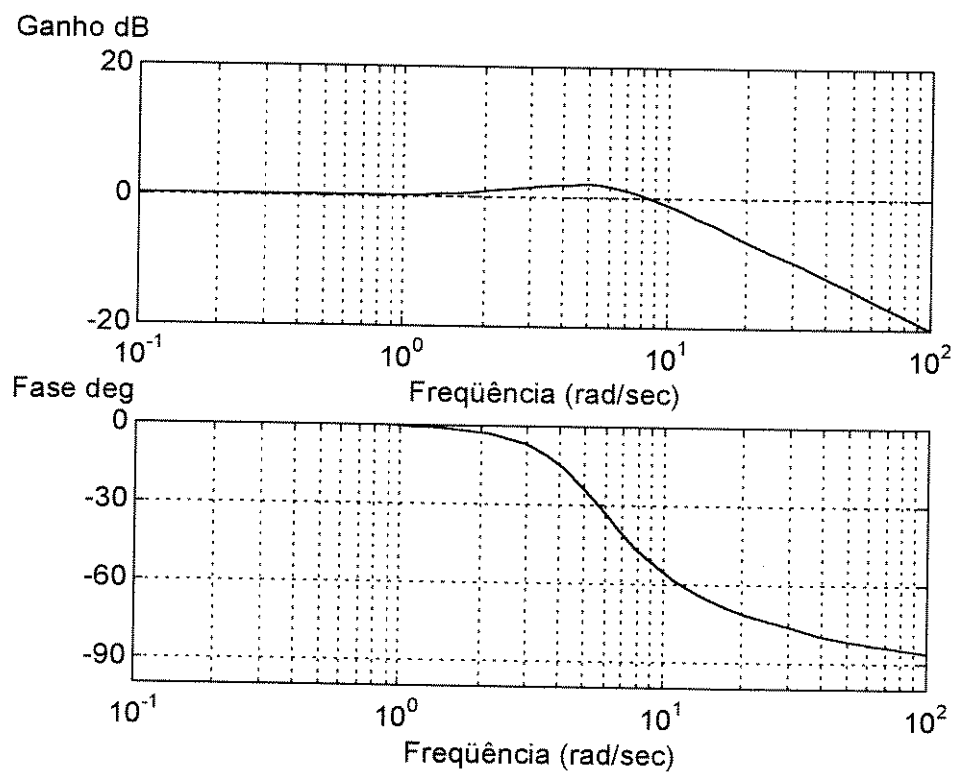


Figura 2.13 - Diagrama de pólos e zeros do sistema de controle em malha fechada para os valores de  $T_r^* / T_r$ : (a) 1 (b) 1.25 (c) 2 e (d) 10.




(a)




(b)

Figura 2.14 - Diagrama de Bode para o sistema em malha fechada. (a)  $K_r = 1$  (b)  $K_r = 1.25$ .



(a)



(b)

Figura 2.15- Diagrama de Bode para o sistema em malha fechada. (a)  $K_r = 2$  (b)  $K_r = 10$ .



## **CAPÍTULO 3**

### *Lógica Fuzzy e Redes Neurais Artificiais. Teoria e Aplicações na Área de Máquinas Elétricas*

#### **3.1 Introdução**

A teoria convencional de controle tem uma metodologia bem estabelecida de análise e projeto para o caso de sistemas lineares. A partir do modelo matemático destes sistemas é feita a análise dos principais índices teóricos de controle, entre os quais os de controlabilidade, observabilidade e estabilidade, assim como os diversos métodos de projeto são apresentados com o devido rigor matemático.

Infelizmente esta abordagem não é válida para os sistemas não lineares. Nestes, o modelo matemático é descrito por equações diferenciais não lineares e só é possível, na maioria dos casos, encontrar soluções aproximadas ao problema de controle, mesmo assim sob certas restrições. Partindo da hipótese de que o grau de não linearidade é pequeno, utilizam-se métodos de linearização e o problema pode ser resolvido através das técnicas de sistema lineares [13], como por exemplo, o método da função descritiva que permite estudar a estabilidade destes sistemas a partir da análise no domínio da frequência.

Outras técnicas de análise e projeto de sistemas não lineares incluem a solução das equações diferenciais presentes no modelo usando técnicas baseadas no plano de fase e no segundo método de Liapunov. Sem dúvida, estas metodologias apresentam difícil

dades relacionadas com a ordem das equações como é caso do método do plano de fase e outras que tem a ver com o grau de não linearidade como ocorre no segundo método de Liapunov [13].

Um outro problema que pode ocorrer relaciona-se com o fato do modelo matemático da planta não ser suficientemente conhecido ou ainda apresentar parâmetros variáveis no tempo, o que levaria a necessidade de se recorrer a um modelo de identificação do sistema. Para eliminar estas restrições, várias teorias de controle adaptativo tem sido desenvolvidas tais como: *Self-Tuning Regulator (STR)*, *Model Reference Adaptive Control (MRAC)*, *Sliding Mode Control (SMC)*. É precisamente neste aspecto que o desenvolvimento nas áreas da Inteligência Artificial (IA) propicia soluções interessantes.

A IA encontra-se dividida em três grandes ramos:

- Sistemas Especialistas
- Lógica Fuzzy
- Redes Neurais Artificiais

Os crescentes avanços nestas áreas da IA tem direcionado os pesquisadores vinculados ao trabalho em sistemas de potência e energia ao estudo da aplicação de novas idéias e métodos na solução dos problemas referentes ao controle, estimação e identificação, entre outros. O desenvolvimento teórico de algoritmos e metodologias da IA tem sido objeto de novos e interessantes estudos e a sua aplicação na área da eletrônica de potência tem-se constituído recentemente em um tema de estudos [14].

Neste capítulo, são apresentados os fundamentos teóricos essenciais de dois dos três ramos da IA - Lógica Fuzzy e Redes Neurais Artificiais- para em seqüência realizar uma revisão crítica de trabalhos que reportam a aplicação destes na área de máquinas elétricas, destacando em cada caso os objetivos e potencialidade destas aplicações em relação aos esquemas convencionais de controle.

### 3.2 LÓGICA FUZZY

O professor Lofti A. Zadeh da Universidade de California de Berkeley, em seu artigo "Fuzzy Sets" [15] publicado em 1965, abriu um nova área de pesquisa que motivou e tem motivado engenheiros a procurarem soluções, aos problemas de controle, baseadas em técnicas *Fuzzy*, principalmente no Japão [16].

O significado em inglês do termo *Fuzzy* está relacionado ao que parece ser confuso ou sem uma definição precisa, como podemos concluir a partir de uma consulta ao dicionário Webster's Ninth New Collegiate:

**Fuzzy:** 1. *marked by or given a suggestion of fuzz; 2. lacking in clarity of definition.*

Sendo assim, Timothy [17] atribui à baixa popularidade no mercado dos Estados Unidos de produtos baseados nesta técnica, quando comparado com o Japão, em parte a este significado lingüístico do termo *Fuzzy*. Ele se reporta ao seguinte fato: imaginem um consumidor norte-americano comum tentando comprar uma "Fuzzy Camera". Poderia pensar que as fotos não iriam ter a nitidez requerida. No Brasil podemos ter a repetição da mesma situação se utilizarmos a expressão Câmera Nebulosa.

Na verdade, os métodos baseados em Lógica *Fuzzy* tem a capacidade de tratar com problemas complexos de controle, tais como os apresentados nas áreas de robótica, controle de processos químicos, transmissão automatizada para veículos, controles eletrônicos e, mais recentemente, na área de acionamentos elétricos que tem sido objeto de diversas implementações [14]. Desta forma, os controladores e estimadores utilizando a lógica *Fuzzy* constituem-se em uma técnica importante nos métodos de projeto e de análise na teoria do controle adaptativo.

Muitas definições existem para a Lógica Fuzzy, indo das mais abstratas, no sentido de empregar uma linguagem da lógica matemática, até àquelas em que a ênfase é dada na representação do conhecimento numa determinada aplicação. Neste trabalho empregaremos uma definição formal do conceito, dada por Ross [18], que ao nosso ver resume o termo com clareza sem perder o rigor da linguagem matemática:

*"Lógica Fuzzy é uma metodologia para expressar as leis operacionais de um sistema em termos lingüísticos, em vez de empregar equações matemáticas".*

A partir desta definição pode-se dizer que a Lógica Fuzzy permite descrever o comportamento de um dado sistema usando termos da linguagem cotidiana. No artigo de Zadeh é apresentada a idéia de que, se as pessoas podem tomar decisões e atuar com um alto grau de precisão a partir de informações de um meio impreciso por natureza, então é possível realizar o controle de processos baseado na mesma abordagem, ou seja, usando dados não bem definidos, mas obtendo resultados precisos [15].

Tanto a Lógica Convencional ( lógica "booleana" ) como a Lógica Fuzzy baseiam-se na teoria de conjuntos. Na teoria clássica um dado elemento pertence ou não a um conjunto: grau de pertinência "1" significa que ele pertence e a pertinência "0" está associada ao fato do elemento não pertencer a este conjunto. Por outro lado, na teoria de conjuntos Fuzzy, um elemento poderá apresentar graus de participação ou de pertinência intermediários no intervalo [1,0]. Se um dado elemento pertence totalmente ao conjunto a ele é atribuído o grau de pertinência "1"; se pertence parcialmente o grau de participação poderá ser "0.4", e se não pertencer ele possuirá grau "0". Como pode ser observado, a lógica Fuzzy permite trabalhar com situações onde o conhecimento das variáveis que caracterizam o estado do sistema é vago ou impreciso.

Antes de apresentar as aplicações recentes deste paradigma na área de máquinas elétricas, é necessário estabelecer um certo formalismo baseado na linguagem da lógica matemática que permita uma melhor compreensão do projeto dos sistemas de controle baseados na Lógica Fuzzy. Com o objetivo de propiciar uma familiarização aos que trabalham na área de máquinas elétricas, algumas definições que são usados extensivamente na literatura especializada de Lógica Fuzzy são apresentadas na seqüência.

### 3.2.1. Operações básicas com conjuntos Fuzzy

Entende-se como conjunto Fuzzy o conjunto dos elementos de um universo de discurso  $X$ , caracterizados por um grau de pertinência ou participação  $\mu(x)$ , com valores no intervalo  $[0,1]$ .

As operações básicas da teoria convencional de conjuntos ( união, intercepção, complemento ou negação ) são também válidas para os conjuntos Fuzzy definidas como segue:

**União** (equivalente à operação lógica OR da lógica "booleana"): Dado dois conjuntos Fuzzy A e B de um universo de discurso  $X$ , a união  $A \cup B$  é também um conjunto Fuzzy de  $X$  com função de pertinência dada por

$$\mu_{A \cup B}(x) = \max[\mu_A(x), \mu_B(x)], \text{ para } \forall x \in X \quad (3.1)$$

**Interseção** (equivalente à operação lógica AND da lógica "booleana"): Dado dois conjuntos Fuzzy A e B de um universo de discurso  $X$ , a interseção  $A \cap B$  é também um conjunto Fuzzy de  $X$  com função de pertinência dada por

$$\mu_{A \cap B}(x) = \min[\mu_A(x), \mu_B(x)], \text{ para } \forall x \in X \quad (3.2)$$

**Complemento ou negação** (equivalente à operação lógica NOT da lógica "booleana"): O complemento ou negação de um conjunto Fuzzy A do universo de discurso  $X$ , denotado por  $\bar{A}$ , é também um conjunto Fuzzy com função de pertinência dada por

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x), \text{ para } \forall x \in X \quad (3.3)$$

### 3.2.2. Variáveis e termos lingüísticos

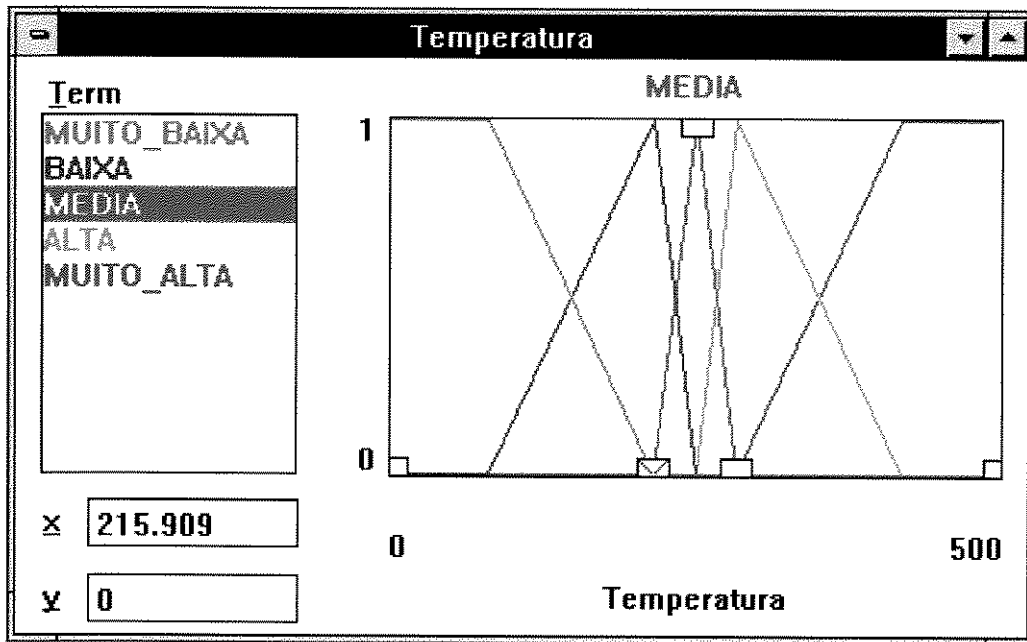
Na teoria da Lógica Fuzzy uma variável lingüística é aquela cujos valores representam conceitos e não números e os termos utilizados para representar estes conceitos são conhecidos como termos lingüísticos. Por exemplo, podemos supor que os termos lingüísticos associados à variável "Temperatura" em um processo qualquer de transfe-

rência de calor sejam *muito frio*, *frio*, *médio*, *quente* e *muito quente*; sendo que cada um destes termos lingüísticos é representado por um determinado conjunto Fuzzy. Outro exemplo de variável lingüística é a velocidade angular de um motor elétrico que pode estar associada, por exemplo, aos seguintes termos lingüísticos: *baixa*, *média* e *alta*. Como pode ser observado nestes dois exemplos, o projetista tem a liberdade de definir tantos termos lingüísticos quantos quiser para uma determinada variável. Esta definição depende, essencialmente, das especificações do sistema e da experiência do projetista.

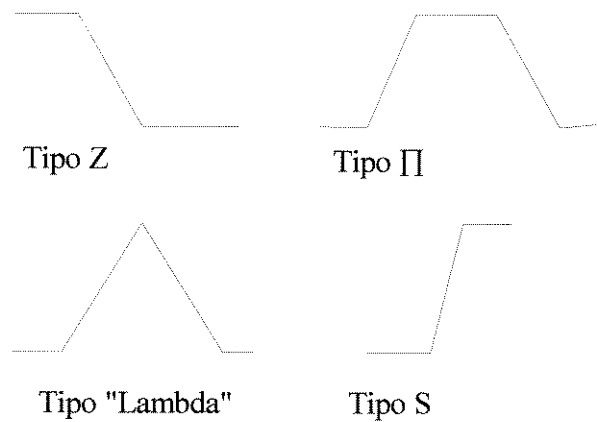
### 3.2.3. Funções de Pertinência

As funções de pertinência representam o grau com que o valor do universo de discurso de uma variável pertence a um determinado conjunto Fuzzy. O termo variável usado neste contexto refere-se a aquela que no sistema toma valores reais do universo. Por exemplo, um valor determinado do universo da variável temperatura pode ser 300 °C. Este valor de temperatura apresenta determinado grau de pertinência dentro de cada um dos conjuntos Fuzzy definidos para a variável lingüística "Temperatura", sendo este grau dado pelo valor da função de pertinência de cada conjunto. A Figura 3.1 (a) ilustra um gráfico típico das funções de pertinência para cada um dos conjuntos Fuzzy da variável lingüística "Temperatura".

Na literatura científica correlata à área da Lógica Fuzzy são apresentadas diferentes formas para as funções de pertinência dos conjuntos Fuzzy, embora na maioria das aplicações prepondere as funções padrões de pertinência representadas pelos tipos "Z", "Π", "Lambda" e "S", como mostradas na Figura 3.1 (b). O aspecto positivo destas funções é o fato de que a representação matemática de cada uma delas pode ser feita no máximo com 4 pontos de definição, dando-lhes então características de fácil implementação, fácil leitura dos valores de pertinência, bem como um tempo pequeno de execução do algoritmo, que deve ser considerado quando se quer reguladores de alta velocidade de resposta.



(a)



(b)

Figura 3.1- (a) Funções típicas de pertinência para os conjuntos Fuzzy da variável lingüística "Temperatura" (b) Padrões de funções de pertinência.

### 3.2.4. Fuzzificação

No processo de fuzzificação os valores tomados pelas variáveis a partir do universo de discurso são transformados em conceitos lingüísticos que são representados por conjuntos Fuzzy. A cada valor da variável é atribuído um valor de pertinência em cada um dos conjuntos fuzzy que a formam, sendo este valor dado pela função de pertinência correspondente.

Suponhamos um sistema de controle no qual o regulador recebe duas variáveis de entrada e em função destas deve-se calcular a ação de controle. Genericamente, chamemos as variáveis de entrada do regulador como "*Variável de Entrada #1*" e "*Variável de Entrada #2*" e a variável de saída do regulador como "*Ação de Controle*". Em um sistema real as variáveis de entrada poderiam ser a pressão e temperatura adquiridas na saída dos sensores correspondentes, enquanto a variável de saída seria o grau de abertura da válvula de fluxo de gás. Consideremos ainda, sem perda de generalidade, que os termos lingüísticos associados às variáveis são representados pelos seguintes conjuntos Fuzzy: *pequena*, *média* e *grande*, com funções de pertinência mostradas na Figura 3.2.

Suponhamos agora que a partir dos sensores do sistema obtém-se os seguintes valores para as variáveis de entrada:

$$\text{Variável\_de\_Entrada\_}\#1 = 27 \text{ e Variável\_de\_Entrada\_}\#2 = 45.$$

O grau de pertinência destes valores em cada conjunto Fuzzy é calculado tomando, no eixo das ordenadas, a leitura correspondente aos valores das variáveis representados na abcissa. No nosso caso, utilizando o conjunto Fuzzy "*pequena*", as variáveis de entrada #1 e #2 terão grau de pertinência 0 e 0.33 respectivamente, como mostrado na Figura 3.2. Na Tabela 3.1 estão colocados os graus de pertinência dos valores destas nos outros conjuntos Fuzzy.



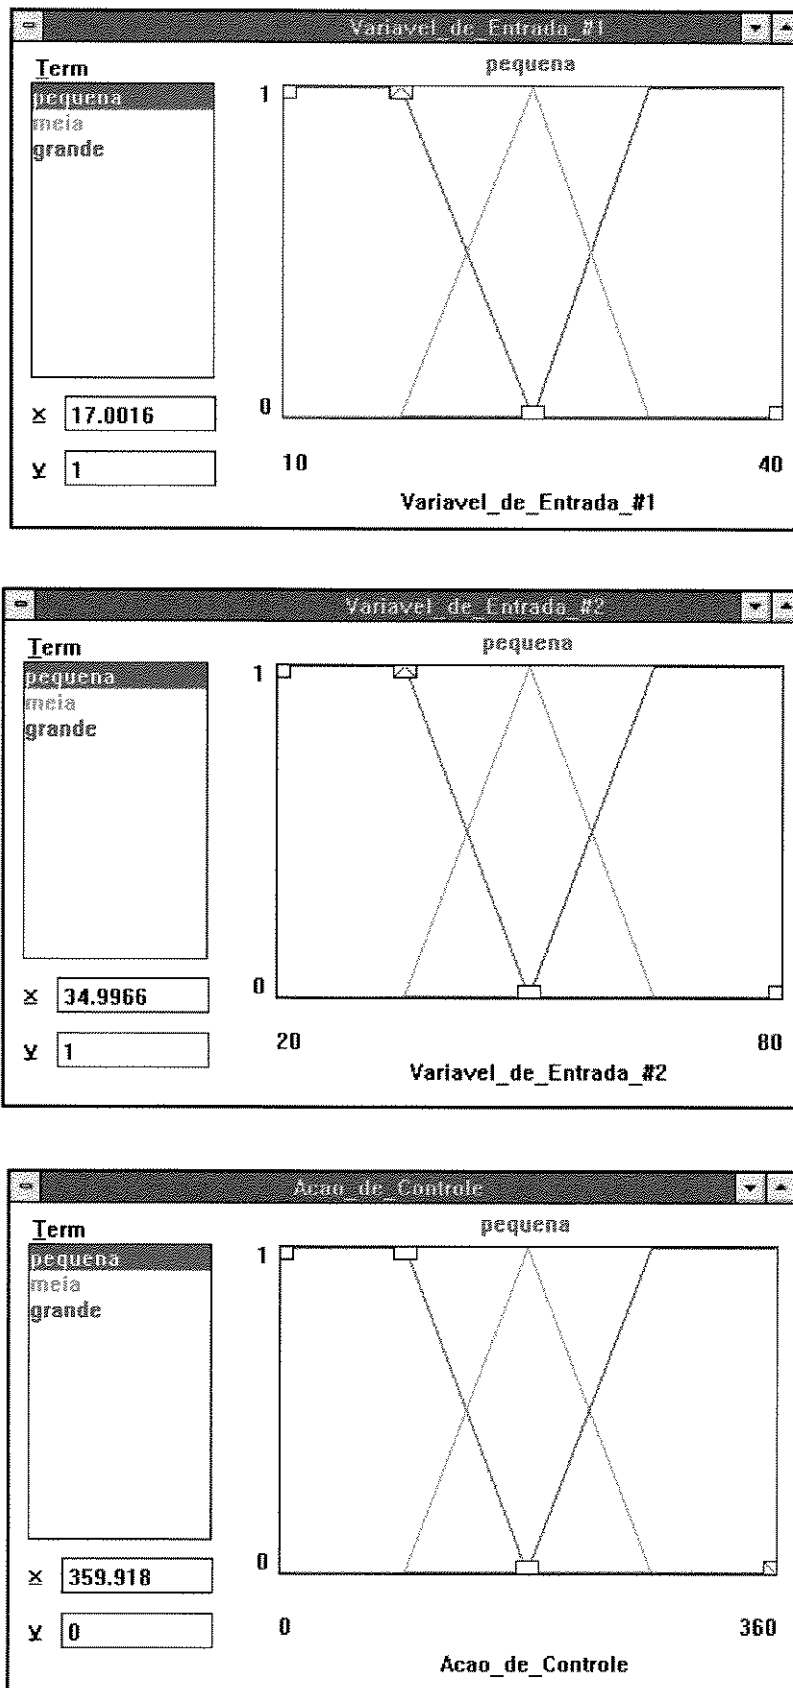


Figura 3.2- Funções de pertinência para as variáveis de entrada e de saída do exemplo.

**Tabela 3.1 - Graus de pertinência das variáveis de entrada em cada conjunto fuzzy.**

Conjuntos Fuzzy	"Variável de Entrada #1"	"Variável de Entrada #2"
pequena	0	0.33
"média"	0.71	0.66
"grande"	0.28	0

### 3.2.5. Regras de Inferência

Os sistemas baseados em Lógica Fuzzy usam as chamadas regras de inferência que representam a relação entre as variáveis lingüísticas e, é através destas regras que são tomadas as decisões ou as ações de controle a partir de entradas determinadas. As regras de inferência são formadas por dois elementos básicos: o *antecedente* da regra e o *conseqüente* desta. O *antecedente* da regra consiste em uma ou mais condições expressas por meio de conjunções lingüísticas, como, por exemplo, AND e OR. As regras são formadas através do seu *antecedente* e *conseqüente* o que é conhecido na Lógica com o nome de *implicação*; desta forma a estrutura geral de uma regra pode ser representada como segue:

**IF antecedente THEN conseqüente**

Particularizando mais um pouco os termos *antecedente* e *conseqüente*, a estrutura geral da regra pode ser expressa como:

**IF x é A AND y é B THEN z é C**

na qual x, y e z são variáveis lingüísticas com o seus universos de discurso representados por X, Y, Z respectivamente; e A, B, C são conjuntos Fuzzy de x, y e z.

No regulador genérico comentado anteriormente algumas regras de inferência poderiam ser as seguintes:

- (1) **IF** "Variável de Entrada #1" = pequena **AND** "Variável de Entrada #2" = média  
**THEN** "Ação de Controle" = média
- (2) **IF** "Variável de Entrada #1" = média **AND** "Variável de Entrada #2" = grande  
**THEN** "Ação de Controle" = grande

O número máximo de regras para o regulador vai ser dado por todas as combinações possíveis dos conjuntos Fuzzy adotados para cada variável lingüística. No nosso caso particular, temos 3 conjuntos para cada variável de entrada resultando então, no máximo, em  $3 \times 3 = 9$  regras de inferência. De forma geral, uma aplicação pode ser representada pelo mínimo de 3 e no máximo 7 conjuntos Fuzzy. Recomenda-se inicialmente que sejam implementados 3 conjuntos para cada variável, para na segunda etapa, de posse de resultados, possa se fazer, se for o caso, a adição de mais conjuntos.

O processo de inferência a partir das regras consiste de duas etapas: *Agregação e Composição*.

### Agregação

Nesta etapa deve-se determinar o grau de validade do antecedente de uma regra, utilizando operadores Fuzzy especiais. Em aplicações de controle que possuem um menor grau de complexidade, os operadores mais usados são o operador "MIN" para representar a conjunção "AND" e o operador "MAX" para representar a conjunção "OR". Estes operadores da etapa de agregação têm como operandos o valor de pertinência obtido no processo de fuzzificação para cada um dos termos lingüísticos presentes no antecedente da regra.

Suponhamos que no nosso exemplo o projetista tenha elaborado para o regulador as regras da Tabela 3.2.

Tabela 3.2 - Regras de inferência do regulador fuzzy.

#	Variável_de_Entrada_#1	Variável_de_Entrada_#2	DoS	Ação_de_Con- trole
1	pequena	pequena	1.0	pequena
2	pequena	média	1.0	média
3	pequena	grande	1.0	média
4	média	pequena	1.0	grande
5	média	média	1.0	média
6	média	grande	1.0	grande
7	grande	pequena	1.0	pequena
8	grande	média	1.0	média
9	grande	grande	1.0	grande

Os resultados do processo de fuzzificação foram mostrados na tabela 3.1. Considerando o operador “MIN” para representar a conjunção “AND”, e desta forma, o processo de agregação pode ser representado como segue:

Grau de Validade do Antecedente =  $\text{MIN}\{ \text{Grau de Validade da Condição \#1, Grau de Validade da Condição \#2} \}$ .

A operação anterior repete-se para cada uma das regras do sistema, resultando nos dados da Tabela 3.3.

Tabela 3.3 - Graus de validade dos antecedentes das regras.

N <sup>o</sup> da Regra	Validade do Antecedente
1	$\text{MIN}(0, 0.33) = 0$
2	$\text{MIN}(0, 0.66) = 0$
3	$\text{MIN}(0, 0) = 0$
4	$\text{MIN}(0.71, 0.33) = 0.33$
5	$\text{MIN}(0.71, 0.66) = 0.66$
6	$\text{MIN}(0.71, 0) = 0$
7	$\text{MIN}(0.28, 0.33) = 0.28$
8	$\text{MIN}(0.28, 0.66) = 0.28$
9	$\text{MIN}(0.28, 0) = 0$

### Composição

A segunda etapa do processo de inferência é a composição. Na etapa de composição o grau de validade do *antecedente* de cada regra que foi obtido na fase de agregação é usado para determinar o grau de validade do *conseqüente* desta.

O cálculo depende do método de inferência usado e para o caso do método standart “MAX-MIN”, o grau de validade do *conseqüente* da regra é considerado igual ao grau de validade do antecedente desta. Consideremos, como exemplo, a regra n<sup>o</sup> 4 do sistema proposto expressa por:

**IF** “Variável\_de\_Entrada\_#1” = *média* **AND** “Variável\_de\_Entrada\_#2” = *pequena*  
**THEN** “Ação de Controle” = *grande*.

Da tabela 3.3 obtemos o grau de validade do *antecedente* da regra e usando o método de inferência “MAX-MIN” para determinar o grau de validade do *conseqüente*, obtemos:

$$\text{Grau de Validade do Conseqüente} = \text{Grau de Validade do Antecedente} = 0.33.$$

Outro método de inferência também usado com frequência é o Método de Mapa de Inferência Associativo Fuzzy ( FAM ). Neste método, a cada regra é atribuído um grau de suporte determinado, que representa a importância individual da regra no conjunto, sendo este grau de suporte expresso por valores contidos na faixa de 0 a 1. No método, o cálculo do grau de validade do conseqüente é efetuado expressando a relação entre o grau de validade do *antecedente* e o grau de suporte da regra em particular, mediante um operador de composição. O operador de composição mais usado para a operação anterior é o operador produto “PROD”. Na tabela 3.3 na qual está colocada o conjunto de regras do sistema, o termo que aparece na coluna 4 é precisamente o grau de suporte de cada regra e é importante notar que no projeto original da base de regras este termo tem valor 1 para cada regra. Isto quer dizer que não existe nenhum nível de hierarquia entre as regras.

Para ilustrar o uso do método *FAM*, suponhamos que a regra nº 4 apresenta um grau de suporte de 0.5 e então, sob esta condição, o método opera da seguinte maneira:

$$\text{Grau de Validade do Conseqüente} = \mathbf{PROD}\{\text{Grau de Validade do Antecedente}, \\ \text{Grau de Suporte da Regra}\}$$

Substituindo os valores do nosso exemplo na expressão anterior, obtemos:

$$\text{Grau de Validade do Conseqüente} = \mathbf{PROD} \{ 0.33 , 0.5 \} = 0.165$$

Por outra parte, é perfeitamente possível que mais de uma regra tenha o mesmo conseqüente. Se observarmos a Tabela 3.2 o conseqüente *grande* é igual para as regras 4, 6 e 9 e neste caso, o grau de validade maior destes conseqüentes é selecionado para o processamento posterior. Desta forma para as regras comentadas e usando a tabela original de regras com “DoS” igual a 1, obtemos:

**Regra Nº 4:** Grau de Validade do Conseqüente *grande* = 0.33

**Regra Nº 6:** Grau de Validade do Conseqüente *grande* = 0

**Regra Nº 9:** Grau de Validade do Conseqüente *grande* = 0

Grau de Validade do *Conseqüente grande* após processo de inferência = 0.33

Como resultado final do processo de inferência é atribuído um valor de pertinência a cada conjunto Fuzzy da variável de saída do sistema, que neste caso é a “Ação de Controle”. Então, aplicando o algoritmo descrito anteriormente, obtemos os resultados lingüísticos mostrados na Tabela 3.4.

**Tabela 3.4 - Graus de validade em cada conjunto fuzzy da variável de saída após o processo de inferência.**

Conjuntos Fuzzy	Grau de Validade
pequena	0.28
média	0.66
grande	0.33

### 3.2.6. Defuzzificação

Como se observa na Tabela 3.4, o resultado do processo de inferência são graus de pertinência para a variável de saída em cada um dos conjuntos Fuzzy. Se pensássemos em um processo de controle de temperatura para o qual a variável de saída do nosso regulador fosse a abertura da válvula que comanda o fluxo de vapor ao interior do processo; uma saída como a anterior poderia ser *média*, um grau menor *grande*, ou ainda uma porcentagem menor *pequena*. Evidentemente, o sistema de regulação da válvula, seja pneumática ou elétrica, não conseguiria entender este tipo de comando. Se a ação de controle fosse abrir a válvula de vapor 30 graus, qualquer sistema de

regulação ou um operador comum do processo conseguiria executar tal comando. Na verdade, estamos tratando com termos lingüísticos resultantes do processo de inferência e estes precisam ser traduzidos em valores reais do universo de discurso da variável de saída, constituindo no que é denominado de defuzzificação.

Como na saída do processo de inferência ( ver tabela 3.4 ) cada termo lingüístico apresenta um grau de pertinência determinado, qualquer que seja o método de defuzzificação usado, ele vai tentar obter um resultado que reflete o peso de cada conjunto na solução final, a partir dos resultados da inferência. Vários métodos de defuzzificação têm sido reportados na literatura científica da área, sendo que os mais implementados são:

- Método do Centro do Máximo ( CoM )
- Método do Centro de Área ( CoA )

### 3.2.6.1. Método do Centro do Máximo

O Método do Centro do Máximo faz o cálculo do valor de saída como uma média ponderada usando o valor real da variável para o qual ocorre o máximo da função de pertinência de cada conjunto Fuzzy, e, o grau de pertinência obtido no processo de inferência para cada um deles. Matematicamente, este processo de cálculo pode ser expresso por:

$$x_0 = \frac{\sum_{i=1}^n x_{i_{máx}} \mu(x_i)}{\sum_{i=1}^n \mu(x_i)} \quad (3.4)$$

na qual:

$x_{i_{máx}}$  é valor do universo de discurso da variável de saída para o qual ocorre o máximo da função de pertinência no conjunto  $i$ .



$\mu(x_i)$  é grau de pertinência para o conjunto  $i$  obtido como resultado na etapa de inferência.

Das funções de pertinência da variável de saída “Ação de Controle” do nosso exemplo, podemos obter os valores para os quais ocorre o valor máximo em cada conjunto como é mostrado a seguir:

### Conjunto “pequena”

É importante notar que a função de pertinência é do tipo “Z” e como consequência disto, o valor máximo não ocorre para um valor fixo do universo de discurso, mais sim dentro de um intervalo. Quando isto acontece, o procedimento comum é tomar como valor representativo do intervalo a média dos extremos, ou seja,

$$x_{1_{máx}} = x_{pequena_{máx}} = \frac{(90 - 0)}{2} = 45$$

### Conjunto “média”

Neste conjunto, o valor máximo é único no intervalo do universo de discurso, ou seja,

$$x_{2_{máx}} = x_{media_{máx}} = 180$$

### Conjunto “grande”

O comportamento neste conjunto é similar ao apresentado no conjunto “pequena”. desta forma,

$$x_{3_{máx}} = x_{grande_{máx}} = 270 + \frac{(360 - 270)}{2} = 315$$

Substituindo na equação 3.4 os valores correspondentes aos graus de pertinência em cada conjunto da tabela 3.4 e os resultados de máximo obtidos anteriormente,obtemos:

$$x_0 = \frac{(0.28 \cdot 45 + 0.66 \cdot 180 + 0.33 \cdot 315)}{0.28 + 0.66 + 0.33} = 185.31$$

Os resultados deste algoritmo de defuzzificação estão ilustrados na Figura 3.3, na qual os graus de pertinência de cada conjunto ( 0.28, 0.66, 0.33 ) e o resultado final ( 185.122 ) estão ressaltados.

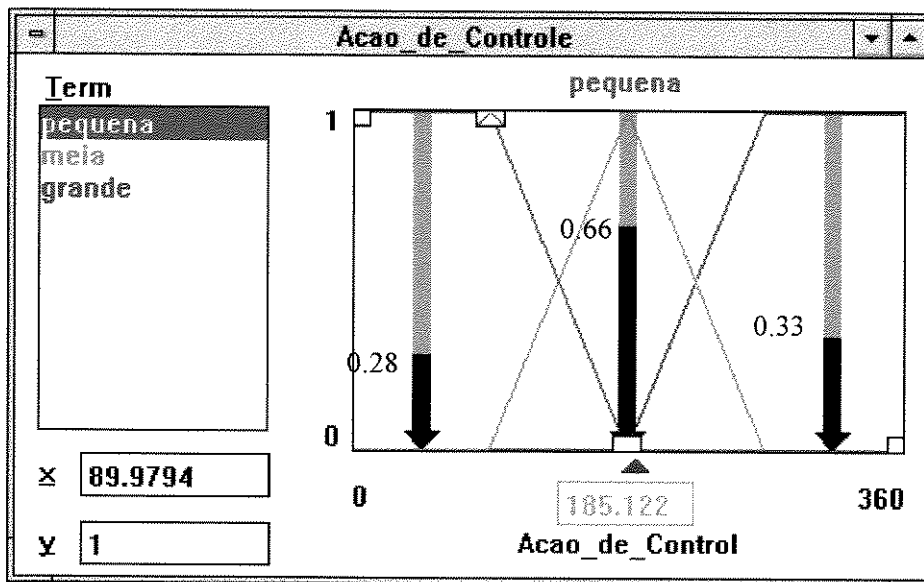


Figura 3.3 - Resultados do processo de defuzzificação.

### 3.2.6.2. Método do Centro de Área

O Método do Centro de Área ( CoA ) também conhecido como o Método do Centro de Gravidade é um dos métodos mais usados nas implementações de sistemas baseado em Lógica Fuzzy. Como ele utiliza um processo de integração numérica nos cálculos, se caracteriza por ser muito mais lento quando comparado com o Método do Centro do Máximo. O tempo envolvido no processo de integração pode ser melhorado com definições adequadas do passo de integração, em outros casos usam-se aproximações deste método para atingir uma maior rapidez de cálculo.

Matematicamente o algoritmo de cálculo pode ser expresso como segue:

$$x_0 = \frac{\int x\mu(x)dx}{\int \mu(x)dx} \tag{3.5}$$

na qual :

$x$  é o valor do universo de discurso da variável de saída,

$\mu(x)$  é o grau de pertinência de um valor  $x$  do universo de discurso da variável de saída.

Para ter uma idéia melhor do processo computacional envolvido no algoritmo de defuzzificação usando o Método do Centro de Área, desenvolve-se, a partir dos dados do exemplo, o cálculo do método. É evidente da equação 3.5, que para o cálculo das integrais, é necessário conhecer as equações das funções de pertinência para cada um dos conjuntos Fuzzy da variável de saída; como também os pontos definidos pela interseção entre a linha horizontal passando pelos graus de pertinência com as respectivas funções. Podemos então, dividir o algoritmo de cálculo em três passos como segue:

- Cálculo das equações das funções de pertinência
- Cálculo dos pontos de intercepção
- Cálculo das integrais correspondentes

#### Cálculo das equações das funções de pertinência

O cálculo das equações das funções de pertinência é feito, para cada conjunto Fuzzy individualmente, a partir dos pontos de definição de cada um deles tomados do gráfico correspondente. Para nosso exemplo obtemos:

conjunto "pequeno"

$$\mu(x) = 1 \quad x \in [0,90] \quad (3.6)$$

$$\mu(x) = -\frac{1}{90}x + 2 \quad x \in [90,180] \quad (3.7)$$

conjunto "média"

$$\mu(x) = \frac{1}{90}x - 1 \quad x \in [90,180] \quad (3.8)$$

$$\mu(x) = -\frac{1}{90}x + 3 \quad x \in [180,270] \tag{3.9}$$

conjunto “grande”

$$\mu(x) = \frac{1}{90}x - 2 \quad x \in [180,270] \tag{3.10}$$

$$\mu(x) = 1 \quad x \in [270,360] \tag{3.11}$$

Cálculo dos pontos de interseção

Os resultados obtidos pelo método standart “MAX-MIN” no processo de inferência estão representados no gráfico da Figura 3.4.

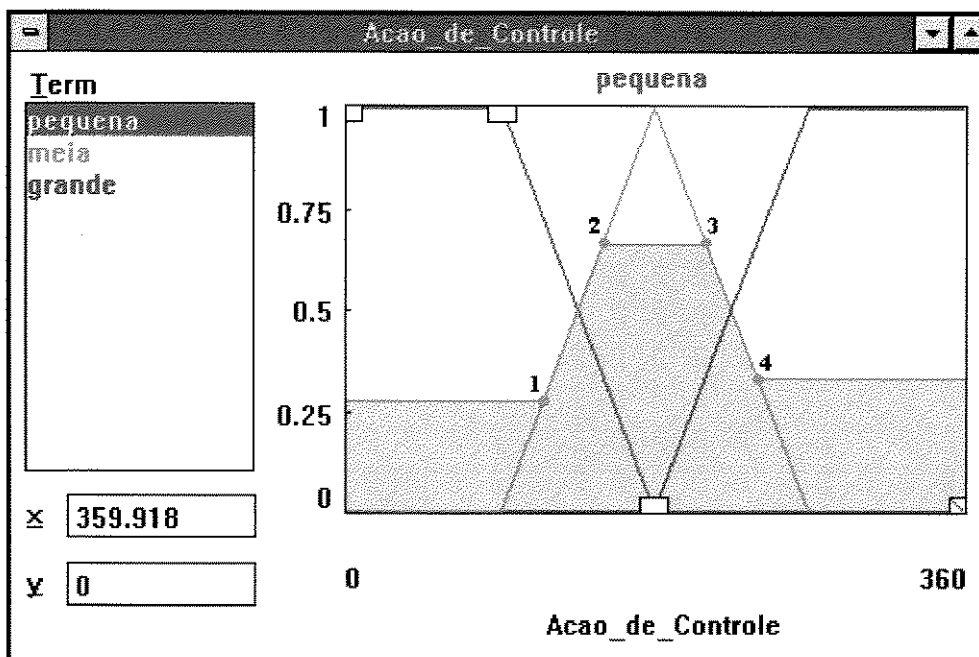


Figura 3.4 - Resultado do processo de inferência pelo método "MAX-MIN".

Podemos assinalar que o propósito do algoritmo de cálculo expresso na equação (3.5) é obter a abcissa do ponto de centro de área ou centro de gravidade da área sombreada; ademais para o cálculo das integrais correspondentes são necessários 4 pontos de interseção (P<sub>1</sub>,P<sub>2</sub>,P<sub>3</sub>,P<sub>4</sub>). Para calcular os pontos de interseção substitui-se o

valor de ordenada dados pelos graus de pertinência resultantes da inferência, nas equações das retas correspondentes e obtêm-se o valor da abcissa do ponto. Na Tabela 3.5 estão colocados os resultados para cada um destes pontos.

**Tabela 3.5 - Coordenadas dos pontos de interseção da Figura 3.4.**

Ponto	Ordenada ( y )	Abeissa ( x )
1	0.28	115.2
2	0.66	149.4
3	0.66	210.6
4	0.33	240.3

#### Cálculo das integrais correspondentes

O cálculo das integrais do numerador e o denominador da equação 3.5 pode ser feita dividindo o processo de integração em uma soma de integrais definidas para cada intervalo definido pelos pontos de interseção. Para a integral do numerador obtemos:

$$\int_0^{360} x\mu(x)dx = I_1 + I_2 + I_3 + I_4 + I_5 \quad (3.12)$$

na qual cada fator é definido como segue:

$$I_1 = \int_0^{x_1} 0.28x dx = 1857.945 \quad (3.13)$$

$$I_2 = \int_{x_1}^{x_2} x\left(\frac{1}{90}x - 1\right) dx = 2159.129 \quad (3.14)$$

$$I_3 = \int_{x_2}^{x_3} 0.66x dx = 7270.56 \quad (3.15)$$

$$I_4 = \int_{x_3}^{x_4} x\left(-\frac{1}{90}x + 3\right)dx = 3290.2 \quad (3.16)$$

$$I_5 = \int_{x_4}^{360} 0.33x dx = 11856.226 \quad (3.17)$$

Substituindo (3.13) - (3.17) em (3.12):

$$\int_0^{360} x\mu(x)dx = 26434.061 \quad (3.18)$$

nas quais  $x_1$ ,  $x_2$ ,  $x_3$  e  $x_4$  são as abcissas dos pontos  $P_1$ ,  $P_2$ ,  $P_3$  e  $P_4$  respectivamente.

O cálculo da integral do denominador é feito de maneira similar, e é importante notar que a forma desta integral constitui graficamente o valor da área inferior à curva de  $\mu(x)$  para um dado intervalo. Portanto,

$$\int_0^{360} \mu(x)dx = A_1 + A_2 + A_3 + A_4 + A_5 \quad (3.19)$$

na qual:

$$A_1 = \int_0^{x_1} 0.28dx = 32.256 \quad (3.20)$$

$$A_2 = \int_{x_1}^{x_2} \left(\frac{1}{90}x - 1\right)dx = 16.074 \quad (3.21)$$

$$A_3 = \int_{x_2}^{x_3} 0.66dx = 40.392 \quad (3.22)$$

$$A_4 = \int_{x_3}^{x_4} \left(-\frac{1}{90}x + 3\right)dx = 14.701 \quad (3.23)$$

$$A_5 = \int_{x_4}^{360} 0.33 dx = 39.501 \quad (3.24)$$

Substituindo (3.20) - (3.24) em (3.19):

$$\int_0^{360} \mu(x) dx = 142.924 \quad (3.25)$$

O cálculo das integrais definidas expressas pelas equações (3.20) - (3.24) é facilitado, neste caso em particular, por ter-se usado funções padrões de pertinência na definição dos conjuntos fuzzy da variável de saída. Como consequência disto, o cálculo se reduz a determinar a área de figuras geométricas conhecidas, em particular retângulos e trapézios.

Uma vez calculadas as integrais do numerador e denominador de (3.5) é possível obter o valor final de saída defuzzificada, aplicando o Método do Centro de Área, substituindo-se (3.18) e (3.25) em (3.5):

$$x_0 = \frac{\int_0^{360} x\mu(x) dx}{\int_0^{360} \mu(x) dx} = \frac{26434.061}{142.924} = 184.951 \quad (3.26)$$

Como se constata é evidente a complexidade do procedimento de cálculo computacional envolvido no Método do Centro de Área quando comparado com o Método do Centro do Máximo. Isto deve ser levado em consideração como um dos critérios práticos de implementação mais importantes. Na atualidade, com a existência de microprocessadores de uma alta velocidade de processamento, estas desvantagens do segundo método em relação ao primeiro passa a ocupar um nível secundário em termos de implementação e isto viabiliza as aplicações baseadas em Lógica Fuzzy.

### 3.2.7. Aplicações na Área de Máquinas Elétricas

Recentemente, tem crescido o número de publicações que relatam a aplicação da teoria da lógica Fuzzy aos problemas de identificação, estimação e controle das máquinas elétricas. Nesta seção comentaremos algumas aplicações típicas, que ao nosso ver, indicam a tendência atual de aplicação desta técnica na área de máquinas elétricas.

#### *Controle de velocidade*

A aplicação da Lógica Fuzzy ao controle de velocidade dos motores elétricos se configura como o principal foco de diversos estudos e implementações, demonstrando que diante dos problemas de não linearidade, perturbações na carga e variações dos parâmetros do modelo matemático da máquina, o regulador Fuzzy de velocidade apresenta um controle rápido e robusto quando comparado com o controle convencional. Nestas aplicações de controle o regulador PI convencional é substituído por um regulador Fuzzy que tem como entrada o erro entre a velocidade de referência e a velocidade real do motor e produz uma saída que estabelece o incremento na variável de controle. Bose et al [19] implementaram, para um motor de corrente contínua, este regulador com as variáveis de entrada anteriormente mencionadas e a saída é o incremento na corrente de armadura. Neste mesmo artigo, é estudado o uso de um regulador fuzzy adicional na malha de corrente, assim como na linearização das características do conversor. O número de regras de inferência usadas foi de 49, pois para cada uma das duas variáveis de entrada foram selecionados 7 conjuntos fuzzy.

Sheng et al [20], Ying-Yu et al [21], Ichiro et al [22] mostram resultados da implementação de um regulador fuzzy na malha de velocidade para o motor de indução operando com orientação de campo, em que o número de regras de inferência é o mesmo do trabalho de Bose. São apresentados resultados comparativos do regulador proposto com o PI convencional para diferentes condições de operação e, em particular, é estudada a resposta dinâmica do sistema diante de sinais de referência de velocidade de tipo degrau e para distintos valores do conjugado de carga, mostrando que o regulador Fuzzy possui um desempenho melhor em termos de velocidade de resposta.



Em todos estes trabalhos a definição do conjunto de regras é feita empiricamente, baseando-se na análise da resposta transitória e do comportamento em regime permanente.

### *Controle de Eficiência no Motor de Indução*

O problema de eficiência na operação dos acionamentos elétricos tem sido tema de grande preocupação, por causa dos custos crescentes da energia e dos problemas associados ao meio ambiente. Quando se adota a orientação de fluxo, a estratégia de maximização da eficiência consiste em estabelecer valores de fluxo magnético que diminuam as perdas totais de energia ( perdas ferro e cobre ) na máquina. A formulação da lei de controle ótimo apresenta problemas de sensibilidade aos parâmetros pois os mesmos são fortemente dependentes da saturação magnética e da temperatura de operação da máquina.

Kirschen, Novotny e Lipo [23] apresentam um método para o controle de eficiência do motor de indução baseado no ajuste adaptativo do fluxo do rotor usando o controle vetorial indireto da máquina de indução e a medição direta da potência de entrada ao sistema no lado CC. A referida estratégia consiste em que, para uma determinada carga, se o conjugado no eixo da máquina ou a velocidade é mantida constante, a eficiência do sistema será máxima quando a potência de entrada seja mínima. O controlador adaptativo proposto ajusta iterativamente uma variável do sistema ( neste caso a componente de corrente de estator associada ao fluxo do rotor ) até detectar o valor mínimo na medição da potência de entrada. Uma característica distintiva do método de Kirschen é o fato de que em cada iteração o fluxo do rotor é atualizado em passos fixos ( 3.3 % do valor nominal ), independentemente da variação da potência de entrada. A seleção do passo poderia influir na convergência do método; por exemplo, se o passo é muito grande isto poderia criar oscilações na busca do mínimo e se for muito pequeno o processo de busca do ótimo poderia ser muito demorado. Com base na abordagem de Lipo, Bose et al. [24] propõem o uso de um regulador Fuzzy para otimizar eficiência na máquina de indução operando sob o controle vetorial indireto. A principal vantagem deste regulador é que o passo de ajuste do regulador é diminuído de maneira adaptativa, melhorando, conseqüentemente, a rapidez de convergência do método de busca. O

fato do regulador diminuir a componente de corrente de estator no eixo em quadratura produz um efeito indesejável que é a diminuição do conjugado eletromagnético. Isto é solucionado pelo malha de velocidade do controle vetorial e, para compensar as possíveis oscilações de conjugado é implementado um compensador.

### *Estimação de formas de onda*

De forma geral, os conversores eletrônicos de potência geram formas de onda de tensão e corrente distorcidas. Os instrumentos de medição ( voltímetros, amperímetros, vatímetros ) têm a tarefa de processar estas formas de onda e determinar as suas características, entre estas: rms total, valor fundamental de rms, potência ativa e reativa, fator de potência entre outros. O anterior é feito usando-se modelos matemáticos, no caso de que estes existam, ou usando-se "look-up table".

Quando são usados modelos matemáticos, aparece a desvantagem de que para se obter a maior precisão, o processo de cálculo pode chegar a ser bem demorado, principalmente produto dos processos de integração presentes. O emprego de "look-up tables" por uma parte é bem mais rápido, mais o tamanho da tabela de busca aumenta conforme aumentamos as especificações de precisão, em outros casos mantém-se um tamanho adequado da tabela de busca e empregam-se métodos de interpolação numérica com os consequentes custos de processamento associados.

No anterior inspira-se o trabalho de Simões et al [25], neste trabalho eles mostram a implementação de um estimador de parâmetros baseado em Lógica Fuzzy para a corrente de linha de um retificador trifásico a diodo que alimenta uma carga capacitiva. As variáveis de entrada ao estimador de parâmetros são neste caso a largura (  $W$  ) e o comprimento da onda (  $H$  ), e como variáveis de saída emprega-se o valor rms da corrente (  $I_s$  ), o valor fundamental rms e o fator de deslocamento (  $DPF$  ). O número de conjuntos fuzzy para a variável de entrada  $W$  foi de 6, no caso do comprimento da onda (  $H$  ) usaram 11 conjuntos fuzzy, por conseguinte o número total de regras de inferência foram 66. Para as variáveis de saída  $I_s$  e  $DPF$  o número de conjuntos fuzzy usados foram de 16 e 6 respectivamente.

O fator de potência PF foi determinado mediante métodos relacionais a partir dos valores "defuzzificados" das variáveis de saída, dado pela relação:

$$PF = DPF \frac{I_f}{I_s} \quad (3.27)$$

Dos resultados da implementação neste trabalho conclui-se sob a melhora na rapidez de cálculo assim como a possibilidade de se obter múltiplas saídas a partir de uma premissa simples nas regras.

### *Estimação de corrente*

A TEXAS INSTRUMENTS [26] apresenta os detalhes da implementação de um sistema fuzzy com o objetivo de identificar a relação não linear entre a frequência de escorregamento e a corrente de estator de referência em um motor de indução. O sistema de controle no qual foi colocado o estimador fuzzy apresenta dois "loop" de controle: um interno no qual as três correntes de fase de estator são controladas usando-se reguladores PI convencionais e outro que calcula a frequência de escorregamento usando um outro regulador PI.

A frequência de escorregamento obtida na saída do PI da malha externa foi usada como a variável de entrada ao estimador fuzzy, sendo a saída a corrente de estator de referência. O estimador fuzzy estabelece um valor constante para a corrente de magnetização em todos os pontos de operação. O número de conjuntos fuzzy tanto para a variável de entrada como para a de saída do estimador foi 7. Outro fato marcante nesta implementação é o de que as regras de inferência do estimador são atualizadas constantemente usando técnicas neuro-fuzzy; esta atualização é verificada antes da execução das etapas de "fuzzificação e defuzzificação". O artigo relata resultados experimentais do sistema implementado destacando o comportamento dinâmico satisfatório, quando este é submetido a sinais de teste na referência de velocidade do tipo onda quadrada.

### 3.3. Redes Neurais Artificias

#### 3.3.1. Introdução

Um dos ramos da Inteligência Artificial ( IA ) que tem recebido a atenção de pesquisadores de diversas áreas do conhecimento é o de Redes Neurais Artificias. Se o objetivo é criar um modelo inteligente, a maneira mais natural, segundo alguns autores, é a de tentar simular, de certa forma, o processo da inteligência humana, constituindo-se então esta busca a principal inspiração das Redes Neurais Artificias.

Diversas definições podem ser encontradas na literatura especializada para as Redes Neurais Artificias mas, em princípio, em todas elas fica evidente a perspectiva deste ramo da IA como um modelo computacional com características de processamento paralelo distribuído capaz de representar não só o conhecimento mas também de aplicá-lo. Um fato marcante destes modelos é que o conhecimento é armazenado na rede por um processo de aprendizado, além de que a sua representação é baseada nas conexões entre as unidades de processamento que estruturam o modelo. Desta forma, a sua similaridade com os processos que aparecem no cérebro humano ficam ressaltados. Os modelos desenvolvidos usando Redes Neurais Artificias são conhecidos na literatura como modelos conexionistas.

O trabalho que marca o surgimento das pesquisas na área das Redes Neurais é de autoria de McCulloch e Pitts que em 1943 propuseram o primeiro modelo para o neurônio artificial. A partir deste modelo surgiram outros, tais como o Perceptron de F. Rosenbalt e o modelo Adaline de Bernard Widrow. O modelo Perceptron provocou, de início, um grande entusiasmo nos pesquisadores da área, pelo fato de que ele imitava em uma boa medida um neurônio biológico e apresentava algoritmos de aprendizagem bem definidos.

Em 1969 Minsky e Papert publicam o livro "Perceptrons" onde são analisadas as principais limitações deste modelo e ficou demonstrado que as Redes Neurais Artificias baseadas na estrutura de neurônio proposta por Rosenbalt não constituíam um modelo computacional de propósito geral [27]. A partir deste momento, mais especificamente no intervalo que se inicia no final dos anos 60 e vai até início dos anos 80, o número

de publicações nesta área diminuiu consideravelmente, fato este que alguns autores atribuem ao efeito ocasionado na comunidade científica pelas críticas contidas no livro de Minsky e Papert, chegando-se até a denominar esta etapa como de período escuro. Na verdade, o que se constata é que a falta de publicações durante este período não representou o abandono das pesquisas na área, pois muitos trabalhos relevantes apresentados posteriormente, foram resultado das pesquisas feitas neste período. Podemos citar como representativos desta fase, os trabalhos de Steven Grossberg e Gail Carpenter que apresentaram o modelo "Adaptive Resonance Theory" ( ART ) na Universidade de Boston [28], o de Teuvo Kohonen [29] da Universidade de Helsinki no seu modelo denominado "Self - Organizing Maps" e o de Paul Werbos que, no início dos anos 70, apresentou o princípio matemático do algoritmo de treinamento com retropropagação do erro, desenvolvido posteriormente para o aprendizado das redes neurais de múltiplas camadas na metade dos anos 80 por David Rumelhart e os seus colegas.

A partir da segunda metade dos anos 80, o número de trabalhos referentes à área das Redes Neurais Artificiais cresceu de maneira considerável. Uma das principais contribuições deste período pertence à John Hopfield [30] que, em 1982, apresentou um novo modelo computacional cuja característica fundamental era o fato de que na estrutura do modelo existia interação entre os neurônios e o principal argumento de defesa do modelo foi que no nível da rede existia capacidade computacional, que não aparecem a nível do neurônio; este tipo de rede neural é conhecido até hoje como Rede de Hopfield. Outro trabalho de grande importância foi de Rumelhart, comentado anteriormente, pois contribuiu não só na fundamentação teórica mas também no desenvolvimento de aplicações práticas, e desta forma pode-se superar as limitações do modelo Perceptron indicadas por Minsky e Papert.

As pesquisas em Redes Neurais tem sido intensas e em particular nas diversas áreas das ciências exatas, fato este facilitado pelo desenvolvimento da microeletrônica que viabilizou, a nível comercial, o surgimento de potentes microprocessadores com elevada velocidade de processamento.

### 3.3.2. Modelo do Neurônio Artificial

O neurônio artificial pode ser definido como a principal unidade de processamento de uma rede neural. Na Figura 3.5 está ilustrado o modelo de um neurônio artificial e podemos identificar três componentes fundamentais do modelo, segundo Haykin [31]:

- **conexões sinápticas:** são as ligações através das quais os neurônios artificiais se comunicam, recebem ou enviam sinais. É associado à cada conexão um peso que expressa a intensidade desta, no neurônio artificial. Estes pesos de cada conexão ou equivalentemente de cada sinapse podem ser positivos (ação ativadora ) ou negativos (ação inibidora). Do ponto de vista computacional, o sinal de entrada do neurônio é multiplicado pelo valor do peso associado à intensidade da conexão. Por exemplo, no modelo da Figura 3.5, o sinal de entrada  $x_1$  é multiplicado pelo valor do peso  $W_{k1}$ . De maneira geral, para um neurônio  $k$ , o sinal de entrada  $x_j$  é multiplicado pelo peso  $W_{kj}$ .
- **Somador:** uma vez que todos os sinais de entrada de um neurônio artificial foram multiplicados pelo peso correspondente, eles devem ser somados. Esta operação pode ser vista como o produto escalar do vetor de pesos  $W$  pelo vetor de entrada  $X$  do neurônio  $k$ .
- **Função de ativação:** Como última etapa de processamento, o sinal de saída do bloco somador passa como parâmetro de entrada à uma função denominada função de ativação que, por sua vez, define a saída do neurônio em função do nível da entrada. Os valores de saída desta função encontram-se tipicamente nos intervalos  $[0, 1]$  ou  $[-1, 1]$ .

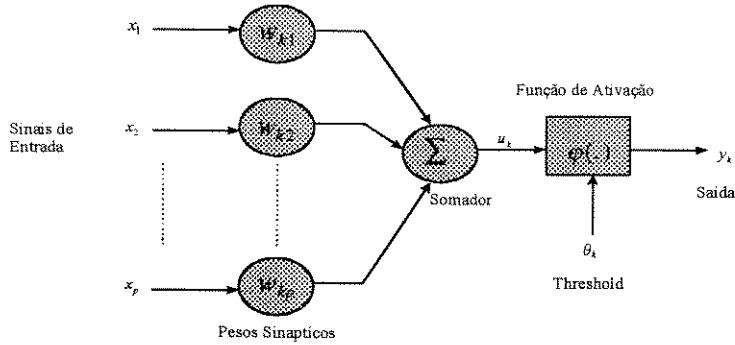


Figura 3.5 - Modelo não linear de um neurônio artificial

Formulação matemática do modelo

O modelo de um neurônio artificial k apresentado anteriormente pode ser formulado matematicamente usando as seguintes relações:

$$u_k = \sum_{j=1}^p w_{kj} x_j \tag{3.28}$$

$$v_k = \sum w_{kj} x_{kj} - \theta_k \tag{3.29}$$

$$y_k = \varphi(v_k) \tag{3.30}$$

nas quais:

$x_j$  é a entrada j ao neurônio

$w_{kj}$  é o valor do peso do neurônio k associado à entrada j

$u_k$  é a saída do bloco somador

$\theta_k$  é o "threshold"

$\varphi(.)$  é a função de ativação

$p$  é o número de sinais de entrada

### Funções de ativação

Diversos tipos de funções de ativação tem sido apresentados na literatura, mas serão adotados os três tipos básicos identificados por Haykin [31]. A expressão matemática de cada uma destas funções de ativação para um neurônio  $k$ , é dada a seguir:

#### 1.- Função "Threshold"

$$\begin{aligned} y_k &= 1 \text{ para } v_k \geq 0 \\ &= 0 \text{ para } v_k < 0 \end{aligned} \quad (3.31)$$

#### 2. Função linear por partes

$$\begin{aligned} \varphi(v_k) &= 1, \text{ para } v_k \geq \frac{1}{2} \\ &= v_k \quad \frac{1}{2} > v_k > -\frac{1}{2} \\ &= 0, \quad v_k \leq -\frac{1}{2} \end{aligned} \quad (3.32)$$

Este tipo de função de ativação pode ser analisada como a aproximação de um amplificador não linear com um fator de amplificação unitário na região linear. Outro fato importante a destacar desta função é que a mesma pode ser reduzida à função "threshold" à medida que o fator de amplificação tende a infinito, sendo este uma medida da inclinação na região linear da característica.

#### 3.- Função Sigmóide

Este tipo de função de ativação é um dos mais utilizados nas arquiteturas das Redes Neurais Artificiais, sendo uma função monótona crescente no domínio da variável de entrada e com propriedades assintóticas, sendo definida como:



$$\varphi(v_k) = \frac{1}{1 + \exp(-av_k)} \quad (3.33)$$

na qual  $a$  é um parâmetro diretamente relacionado com a inclinação da função (*slope parameter*). À medida que o parâmetro  $a$  aumenta a função sigmóide aproxima-se da função "threshold". Outras características importantes desta função são as propriedades de continuidade e diferenciabilidade, sendo esta última fundamental à teoria das Redes Neurais.

As três funções de ativação definidas anteriormente apresentam a sua saída limitada no intervalo  $[0, 1]$ . Em certas situações é desejado que a saída de um dado neurônio esteja no intervalo  $[-1, +1]$ , com este fim as funções de ativação precisam ser redefinidas. Sendo assim, a função threshold é redefinida como

$$\begin{aligned} \varphi(v_k) &= 1, \quad v_k > 0 \\ &= 0, \quad v_k = 0 \\ &= 1, \quad v_k < 0 \end{aligned} \quad (3.34)$$

No caso da função sigmóide, geralmente é usada uma função com características similares, por exemplo a função tangente hiperbólica definida como

$$\varphi(v_k) = \tanh\left(\frac{v_k}{2}\right) = \frac{1 - \exp(-v_k)}{1 + \exp(-v_k)} \quad (3.35)$$

Na Figura 3.6, estão mostradas as curvas características das três funções de ativação típicas comentadas anteriormente com saída limitada no intervalo  $[0,1]$  bem como a função de ativação tangente hiperbólica com saída no intervalo  $[-1, +1]$ . No caso particular da função sigmóide (Fig. 3.7 c), são apresentadas três características parametrizadas pelos valores de  $a = 0.4$ ,  $a = 0.6$  e  $a = 0.8$  com o objetivo de mostrar a influência deste fator no grau de inclinação da função.

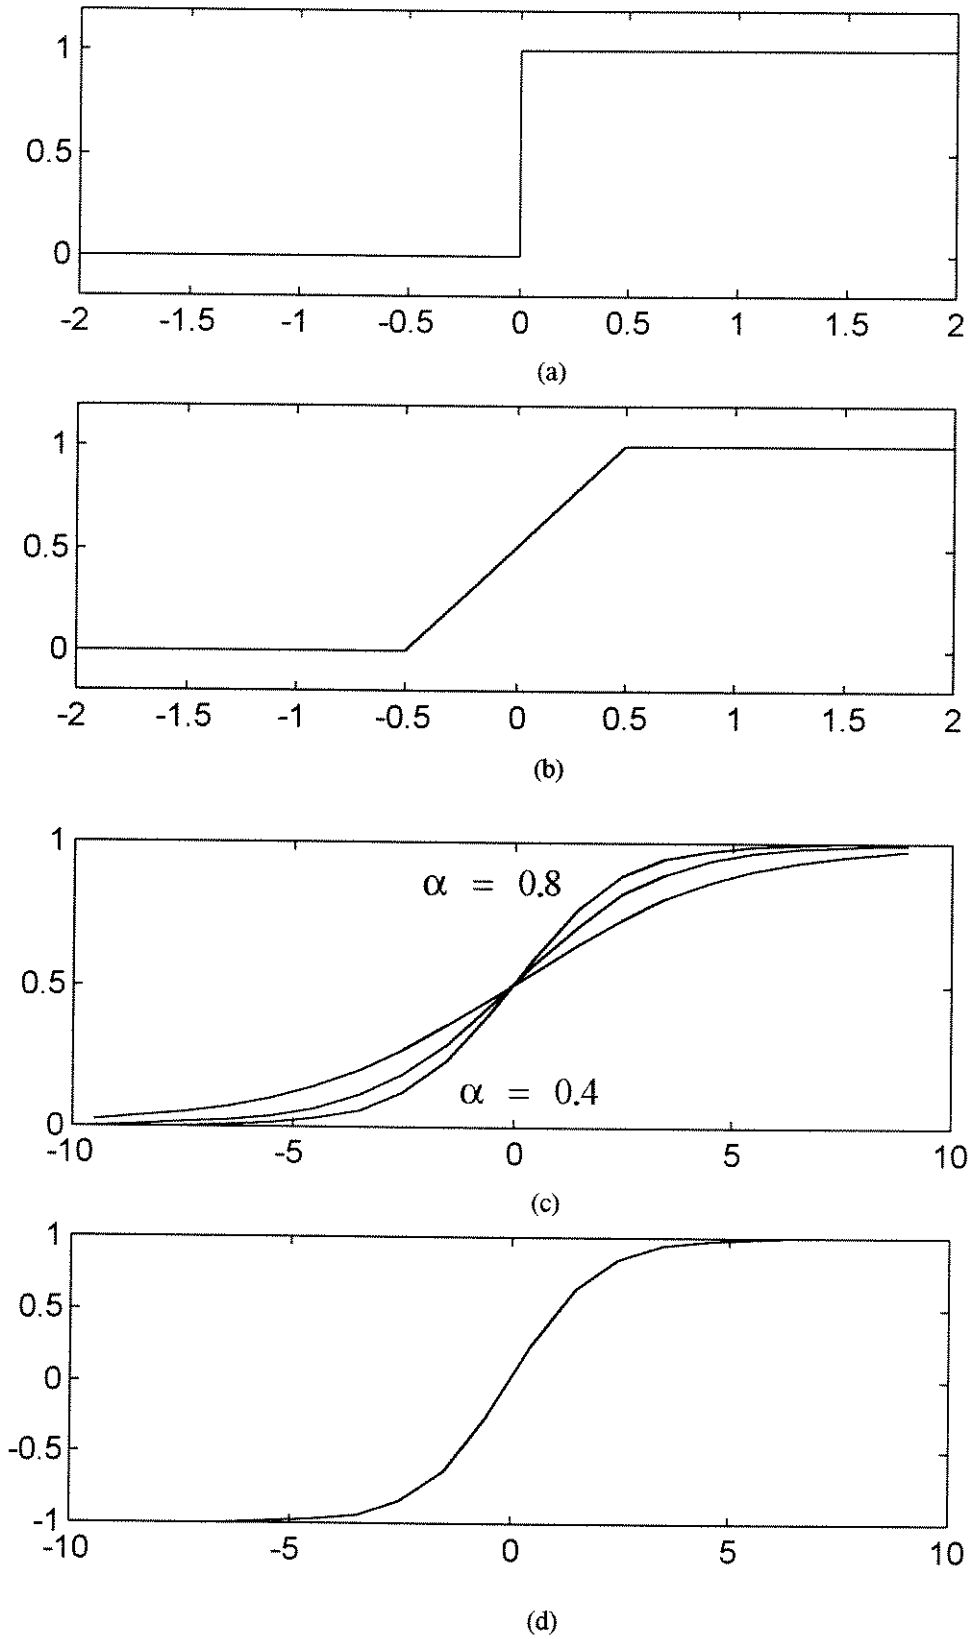


Figura 3.6- Curvas características das funções de ativação:

(a) "treshold" (b) linear por partes ( c ) signóide (d) hiperbólica


### 3.3.3. Principais arquiteturas

A partir do modelo da unidade de processamento mais simples que é o neurônio, são criadas as estruturas ou arquiteturas das Redes Neurais Artificiais, cuja topologia vai estar determinada pela forma com que estes neurônios encontram-se interconectados na rede. Por este fato, utiliza-se a denominação de modelos conexionistas. Embora na literatura sejam encontradas diversas topologias, consideraremos somente aquelas que são mais freqüentemente estudadas na literatura, a saber: *redes neurais não recorrentes de múltiplas camadas* e *redes neurais recorrentes*.

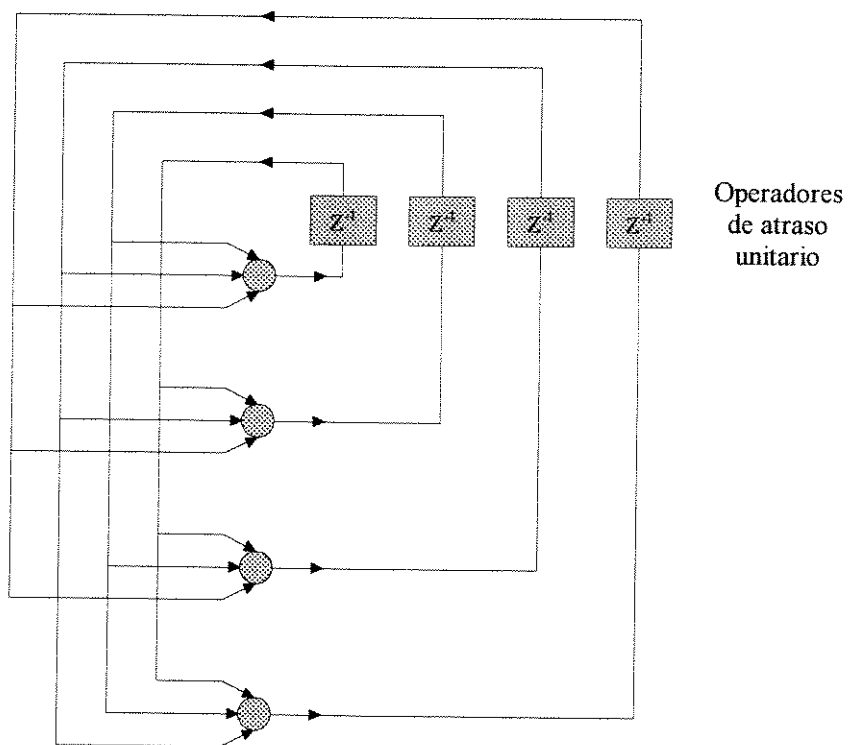
#### Redes Neurais não recorrentes de múltiplas camadas

Neste tipo de rede os neurônios encontram-se organizados em forma de camadas, sendo que cada camada está conectada à camada posterior através de conexões à semelhança das sinapses dos neurônios naturais. Três tipos de camadas podem ser diferenciadas dentro da estrutura desta rede, como mostradas na Figura 3.7(a): a camada de entrada, a escondida e a de saída.

A propagação do sinal de entrada na rede não recorrente de múltiplas camadas se realiza da seguinte maneira: os sinais de saída de cada camada são propagados à imediatamente posterior até chegar à camada de saída. Os valores da saída da última camada da rede (camada de saída) representam a resposta da rede ao padrão de entrada apresentado. As camadas escondidas em uma rede neural não recorrente com várias camadas de neurônios servem de intermediárias entre a entrada externa da rede e a saída fornecida por esta. Incrementando o número de camadas escondidas da rede aumenta-se o número de pesos e conseqüentemente é aumentada a sua capacidade e, isto pode tornar o processo de aprendizado da rede mais lento.



(a)



(b)

Figura 3.7- Modelos de Redes Neurais Artificiais: (a) não recorrente de múltiplas camadas  
(b) recorrentes.

### - Redes Neurais Recorrentes

As Redes Neurais Recorrentes diferem das Redes Não Recorrentes de múltipla camadas pela existência de pelo menos um malha de realimentação [31], como mostrado na Figura 3.7 (b). A rede apresenta somente uma camada de neurônios e o sinal de saída de um neurônio é realimentado aos neurônios restantes. Outras estruturas de redes recorrentes podem apresentar várias camadas e ainda ter neurônios com autorealimentação, ou seja, o sinal de saída de um neurônio é realimentado na sua própria entrada. A presença de realimentação na estrutura destes tipos de rede produz um grande impacto na capacidade de aprendizado destas, assim como no seu desempenho. As conexões de realimentação são obtidas usando blocos com elementos de atraso unitário que juntos com a natureza não linear dos neurônios fazem com que este tipo de rede seja representativo de um comportamento dinâmico não linear.

#### 3.3.4. Aprendizado

No início da seção de Redes Neurais Artificiais foi salientado o fato de que estas tinham a capacidade de representar conhecimento como também de aplicá-lo em situações reais. O processo através do qual o conhecimento de um domínio de aplicação é adquirido e representado pela rede neural é conhecido como processo de aprendizado. A incorporação deste conhecimento é conseguido através do ajuste dos pesos associados aos enlaces entre os neurônios. O processo de determinação do conjunto de pesos que garantem um bom desempenho da rede constitui o chamado treinamento da rede neural.

No processo de treinamento da rede são apresentados a esta exemplos de um domínio de aplicação dado, estes exemplos conformam o conjunto de treinamento da rede; este conjunto é formado por pares de vetores de entrada e saída e, representam o conhecimento externo da aplicação que a rede deve representar. Como resultado final do aprendizado, a rede neural deve ser capaz não só de representar o conhecimento apresentado a ela através do conjunto de treinamento, como também ter a capacidade de

generalizar, ou seja, deve responder com um alto grau de confiabilidade às entradas não usadas como parte do conjunto de treinamento.

De maneira geral o aprendizado ou em outras palavras o processo de ajuste dos pesos da rede pode se dividido em:

- Aprendizado não adaptativo
- Aprendizado adaptativo

No aprendizado não adaptativo os pesos da rede são calculados diretamente, usando expressões matemáticas que contêm informações relacionadas com o conjunto de treinamento. Exemplo deste tipo de aprendizado aparece nos métodos de treinamento empregados no modelo de Hopfield. O aprendizado adaptativo começa com uma inicialização dos pesos da rede que depois serão ajustados iterativamente segundo uma regra de ajuste pré-determinada.

Existem dois métodos básicos para o processo de aprendizado adaptativo que estão diretamente relacionados com a informação contida no conjunto de treinamento: aprendizado não supervisionado e o aprendizado supervisionado

No aprendizado não supervisionado os elementos que integram o conjunto de treinamento da rede contêm só os vetores  $X$  de entrada, e a partir destes é feito o ajuste dos pesos segundo um critério que, na maioria das vezes, é de natureza competitiva. Um exemplo deste aprendizado está presente na rede de Kohonen e de Carpenter - Grossberg.

O aprendizado supervisionado baseia-se em minimizar uma função objetivo ou função de custo  $E$  que representa, de alguma forma, o erro entre a saída desejada e a saída real da rede. Neste caso, o conjunto de treinamento da rede está formado por vetores que representam a entrada e saída desejada. Geralmente, a função de custo escolhida é a do erro médio quadrático e o método de otimização usado com maior frequência, para minimizar esta função, é o conhecido método do gradiente descendente. Para efetuar o aprendizado supervisionado da rede neural utiliza-se-se, geralmente, o algoritmo de aprendizado "*backpropagation*" aplicado extensivamente no treinamento de

redes não recorrentes de multiplas camadas, obtido por vários autores ( Paul Werbos em 1974, David Parker em 1982, Le Cun e David Rumelhart em 1986 ); este algoritmo baseia-se nos princípios matemáticos do método do gradiente descendente. A seguir são mostrados os passos de execução deste algoritmo.

### *Passo 1: Inicialização*

Nesta etapa são adotados valores aleatórios, dentro de uma determinada faixa, para os pesos e **bias** da rede.

### *Passo 2: Apresentação do vetor de entrada e saída desejado*

É apresentado à rede um vetor de entrada-saída tomado a partir do conjunto de treinamento; as componentes deste vetor devem ser normalizadas previamente. A representação deste vetor é escrito como:

$$\text{vetor de entrada: } x = [x_0, x_1, \dots, x_{N-1}]$$

$$\text{o vetor de saída: } d = [d_0, d_1, \dots, d_{M-1}]$$

nas quais, N é o número de componentes do vetor de entrada e M é onúmero de componentes do vetor de saída.

### *Passo 3: Cálculo da saída produzida pela rede*

A partir da entrada apresentada no passo 2, calcula-se a saída real produzida pela rede. Este processo é feito propagando os sinais de saída de cada camada à imediatamente posterior até chegar à camada de saída ("feedforward"). Representaremos o vetor de saída calculado pela rede por:

$$y = [y_0, y_1, \dots, y_{M-1}] \tag{3.36}$$

### *Passo 4: Atualização dos pesos da rede*

Nesta etapa os pesos da rede são atualizados recursivamente efetuando um processo que se inicia na camada de saída e prossegue até a primeira camada da rede, usando para este ajuste a seguinte expressão geral:

$$w_{ij}(k+1) = w_{ij}(k) + \eta \delta_j x_i \quad (3.37)$$

na qual,

$w_{ij}(k)$  é peso no instante  $k$  associado à conexão entre o neurônio  $i$ , localizado numa camada escondida ou na camada de entrada, e o neurônio  $j$  da camada seguinte.

$x_i$  é a saída do neurônio  $i$

$\eta$  é o fator de aprendizado

$\delta_j$  é o termo de erro associado ao neurônio  $j$

Na expressão 3.37, o cálculo do termo de erro  $\delta_j$  depende da localização específica do neurônio. Se ele pertence à camada de saída é escrito como:

$$\delta_j = y_j(1 - y_j)(d_j - y_j) \quad (3.38)$$

na qual,

$d_j$  é a saída desejada no neurônio  $j$  da camada de saída

$y_j$  é a saída real da rede

Para o caso de um neurônio que pertence a uma camada oculta, o termo do erro associado ao neurônio  $j$  é expressado como:

$$\delta_j = x_j(1 - x_j) \sum_k \delta_k w_{jk} \quad (3.39)$$

e a somatória presente nesta equação é realizada para todos os neurônios que pertencem à camada posterior àquela referente ao neurônio  $j$ . Com o objetivo de acelerar a convergência do algoritmo de treinamento, algumas vezes é introduzido um termo que expressa a inércia deste processo, escrito como  $\alpha(w_{ij}(k) - w_{ij}(k-1))$ , expressão utilizada para a atualização dos pesos passa a ser a seguinte:



$$w_{ij}(k+1) = w_{ij}(k) + \eta \delta_j x_i + \alpha(w_{ij}(k) - w_{ij}(k-1)) \quad (3.40)$$

com  $\alpha$  tomando valores no intervalo  $[0,1]$ .

Pelo fato do processo de atualização ser implementado a partir da última camada até chegar à primeira, o que significa que o termo de erro da camada posterior é utilizado para atualizar os pesos dos neurônios da camada atual, o processo de aprendizado recebe o nome de "backpropagation", ou de aprendizado por retropropagação do erro.

### *Passo 5: Volta ao passo 2*


Uma vez cumprido o passo 4 o algoritmo de treinamento volta ao passo 2. Repete-se este procedimento, para cada um dos exemplos presentes no conjunto de treinamento, até satisfazer uma determinada condição de parada. Geralmente, a condição de parada é expressa limitando o número de iterações do processo ou quando o valor da função de custo escolhida atinge o valor de mínimo com a precisão desejada. É importante salientar o fato de que embora o algoritmo de treinamento não garanta que seja encontrado o mínimo global da função de custo, a convergência a um mínimo local é garantida. Como foi dito anteriormente, a função de custo escolhida é, na maioria das vezes, a do erro quadrático médio que neste caso particular pode ser expressa como

$$E = \frac{1}{2} \sum_k (y_j - d_j)^2 \quad (3.41)$$


sendo a somatória realizada para todos os neurônios da camada de saída.

### Exemplo 1


Seja uma Rede Neural Não Recorrente de Múltiplas Camadas, treinada com o algoritmo de algoritmo de aprendizado "backpropagation", que deve representar a função  $Y = \cos(x)$  no intervalo  $[-\pi, \pi]$ . Suponhamos que a rede escolhida possui uma camada de entrada com dois neurônios, uma camada escondida com um total de 8 neurônios e uma camada de saída com um neurônio; como função de ativação foi usada a função tangente hiperbólica. Na Figura 3.8 são mostrados a curva real da função e aquela obtida pela rede para diferentes instantes da execução do treinamento. A curva




(a)



(b)



(c)



(d)

Figura 3.8- Representação da função cosseno utilizando uma Rede Neural de Múltiplas Camadas:(a) 10 iterações (b) 400 iterações (c) 600 iterações (d) 800 iterações

de comportamento do erro quadrático médio em função do número de iterações está mostrada na Figura 3.9. Como pode ser observado à medida que o treinamento da rede neural progride, melhora a aproximação entre a curva real e a representada através da rede, como consequência ocorre a diminuição do erro médio quadrático. Como se observa também, no início do treinamento o erro cai com uma rapidez maior quando comparado com a etapa final do processo em que, praticamente, o erro varia muito pouco e isto é uma característica dos métodos baseados no gradiente descendente. É conhecido que nestes métodos o processo de busca, quando próximo da condição de mínimo fica bem lento, dificultando a convergência. Para eliminar esta desvantagem são usados métodos de segunda ordem que utilizam aproximações quadráticas. Estes métodos são bem eficientes na região próxima do mínimo onde a função de custo pode ser aproximada com um alto grau de precisão por funções quadráticas, mas dependendo da forma da função de custo podem apresentar péssimo desempenho quando se trabalha na região distante do mínimo. Por esta razão, a alternativa mais acertada é a de usar uma combinação de algoritmos baseados em métodos de segunda e de primeira ordem tais como gradiente descendente.




Figura 3.9 - Erro médio quadrático em função do número de iterações.

### 3.3.5. Representação de comportamento dinâmico utilizando Redes Neurais Artificiais.

Na seção anterior foi discutido o aprendizado nas Redes Neurais Artificiais, ilustrado através de um exemplo no qual uma rede não recorrente multi-camadas foi utilizada para representar a função  $Y = \cos(x)$ . Representações do tipo mostrado no exemplo são chamadas, na literatura especializada, de mapeamento estático (*static mapping*). O termo mapeamento indica que a rede pode ser vista no domínio vetorial como um operador que transforma vetores de um espaço de entrada X em vetores de um espaço de saída Y, sendo estes espaços de dimensões arbitrárias. O termo estático encontra-se diretamente relacionado com a teoria matemática de sistemas, indicando que o valor da saída da rede em um instante  $k$  é independente dos valores de entrada e saída nos instantes anteriores.

Particularmente na área de controle, o processo de identificação do comportamento dinâmico de um sistema é de vital importância, principalmente nos casos em que o modelo matemático do sistema não é conhecido com a precisão adequada ou mesmo nos casos em que o modelo possui parâmetros sujeitos à variação. Este é o caso, por exemplo, do modelo matemático do motor de indução que apresenta as resistências de estator e de rotor dependentes dos efeitos da temperatura e da frequência elétrica das correntes, bem como a indutância de magnetização que tem seu valor alterado pelo fenômeno da saturação magnética. Uma vez feita a identificação da dinâmica do sistema é possível elaborar estratégias de controle ótimas para satisfazer determinados índices de desempenho do sistema.

A capacidade de aproximação exibida pelas Redes Neurais Artificiais faz com que elas se configurem como uma ferramenta útil para implementação de algoritmos de identificação da dinâmica de sistemas. Os tipos de Redes Neurais usados com maior frequência para este caso são as redes neurais de múltiplas camadas recorrentes e não recorrentes. Nesta seção, por razões de interesse da implementação feita neste trabalho, é comentado e exemplificado a capacidade de representação de comportamento dinâmico usando redes neurais de múltiplas camadas não recorrentes.

A redes neurais de múltiplas camadas não recorrentes permitem representar comportamento dinâmico de sistemas mediante a incorporação de unidades de atraso unitário na composição do vetor de entrada à rede. Narendra et al [32] apresentam a estrutura de um sistema de identificação para uma planta não linear, como mostrada na Figura 3.10. No modelo desta planta não linear assume-se que a mesma possui a seguinte expressão:

$$y_p(k+1) = f[y_p(k), y_p(k-1), \dots, y_p(k-n+1); u(k), u(k-1), \dots, u(k-m+1)] \quad (3.42)$$

sendo:

$m$  e  $n$ : inteiros positivos com  $m \leq n$ ,  $k$  o instante de tempo discreto ;  $u, y_p$  a: entrada e a saída do sistema respectivamente.

O diagrama do modelo de identificação representado é chamado de modelo série - paralelo no qual a saída real da planta é realimentada à rede neural. Existe também o chamado modelo paralelo no qual o sinal de realimentação é a saída da rede. O sinal de erro entre a saída real da planta e a da rede é usada neste caso como uma medida do desempenho do modelo de identificação, e empregada para o ajuste dos parâmetros da rede, representados pelos pesos.

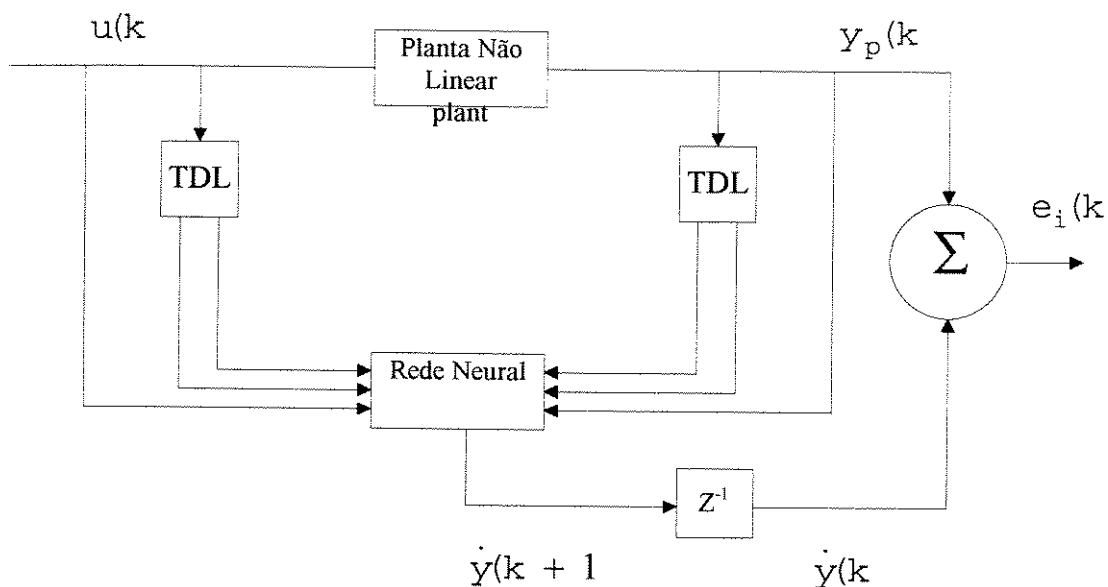


Figura 3.10- Estrutura de um sistema de identificação para uma planta não linear.

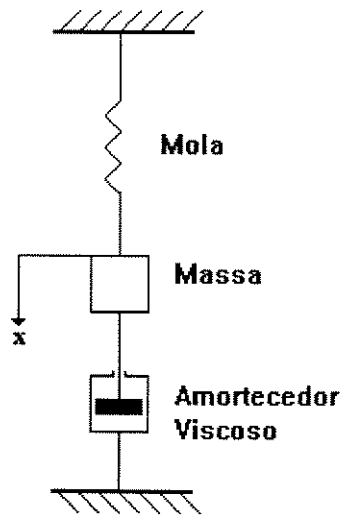
Uma vez terminado o processo de identificação, a rede deve ser capaz de responder de maneira igual à que a planta real responderia para condições iniciais iguais, com qualquer entrada especificada.

Com base no que foi comentado, é feito como exemplo, a representação do comportamento dinâmico para um sistema físico real. O sistema escolhido para o nosso estudo é constituído por uma mola não linear, uma massa e um elemento com atrito viscoso, como mostrado na Figura 3.11 (a). A equação diferencial deste sistema mecânico não linear é escrito como:


$$m \frac{d^2 x}{dt^2} + f \frac{dx}{dt} + kx + k_I x^3 = 0 \quad (3.43)$$

na qual  $m$  é massa do corpo,  $f$  é coeficiente de atrito viscoso do amortecedor,  $x$  é deslocamento da massa e  $kx + k_I x^3$  é a força do mola não linear. Os parâmetros  $m$ ,  $f$  e  $k$  são constantes positivas e a constante  $k_I$  pode ser positiva ou negativa. No caso desta ser positiva a mola é considerada forte; para valores de  $k_I$  negativos a mola é considerada macia. Esta equação diferencial não linear tem sido muito estudada na área da mecânica não linear, sendo conhecido como equação de Duffing [13], onde o grau de não linearidade do sistema é avaliado pelo valor da constante  $k_I$ . A solução do sistema para  $k_I = 0$  e  $k_I > 0$  com condições iniciais não nulas são mostrados na Figura 3.11 (b)-(c).


Observa-se que a solução do sistema apresenta oscilações amortecidas para qualquer um dos casos mostrados e além disso, na condição  $k_I = 0$  ( caso linear ), a frequência mantém-se invariável na medida que a amplitude da oscilação livre do sistema diminui. Por outro lado se  $k_I > 0$  esta frequência diminui com a diminuição da amplitude do sistema. Este tipo de relação frequência - amplitude é uma das características que permite identificar experimentalmente a presença de não linearidades em um sistema físico, assim como também o grau destas. A estrutura usada tanto para o treinamento e o teste da rede da rede neural está mostrada na Figura 3.12.



(a)



(b)



(c)

Figura 3.11- (a) Sistema sob estudo e o seu comportamento

dinâmico ( $x = f(t)$ ) para (b)  $k_I = 0$  (c)  $k_I = 9$ .

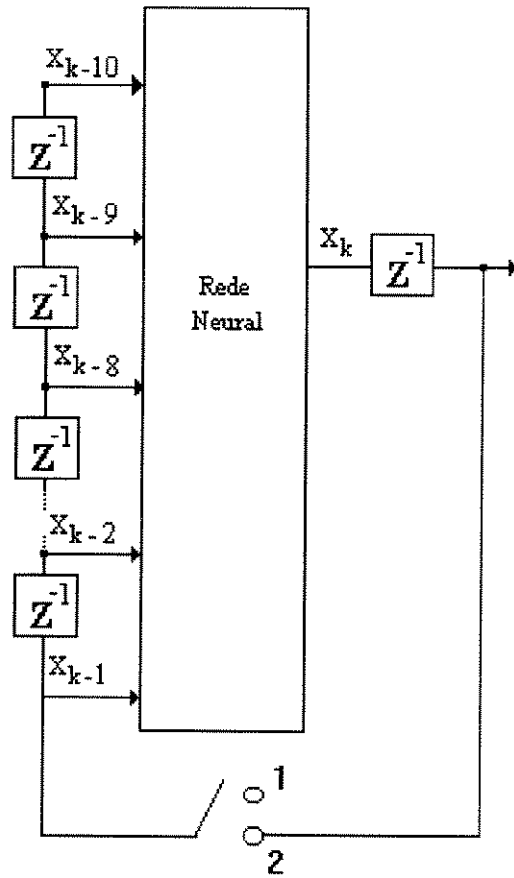


Figura 3.12- Estrutura utilizada para o treinamento e teste da rede neural do exemplo.



O conjunto de dados utilizados no treinamento são tomados da resposta do sistema para as seguintes condições iniciais:  $x_0 = 3$ ,  $x_0 = 5$  e  $x_0 = 7$ . Durante este processo a chave da realimentação permanece na posição 1 e os elementos do vetor de entrada à rede correspondem com 10 estados consecutivos da resposta. A diferença entre dois vetores consecutivos de entrada é que cada elemento pertencente a um deles apresenta uma defasagem em relação ao correspondente do outro por um atraso unitário. A estrutura da rede usada apresenta uma camada de entrada formada por 10 neurônios, uma camada escondida formada por 8 neurônios e uma camada de saída de um neurônio. O algoritmo de treinamento usado foi o "*backpropagation*". Na Figura 3.13 são mostradas a resposta do sistema real para as condições iniciais anteriores, mais uma com condição inicial  $x_0 = 9$ .

Uma vez terminado o treinamento da rede é feito o teste desta para diferentes condições iniciais, tanto para aquelas apresentadas durante o processo de aprendizado como para algumas outras que não foram levadas em consideração. Para efetuar os testes a chave deve estar conectada na posição 2, ou seja, o malha de realimentação passa a ser ativa. Assim que é apresentado um vetor para a condição inicial especificada, a rede utilizando a malha de realimentação atualiza o vetor de entrada fornecendo na sua saída a resposta dinâmica do sistema. Na Figura 3.14 estão mostrados os resultados obtidos nos testes da resposta da rede e do sistema real para as condições iniciais que variam de  $x_0 = 3$  até  $x_0 = 8$ , com passo igual a 1.

A partir das respostas fornecidas pela rede é possível concluir que logo após o processo de treinamento, ela é capaz de representar com certo grau de precisão o comportamento dinâmico do sistema escolhido para o estudo. Os resultados obtidos nos testes realizados para condições iniciais não apresentadas durante a etapa de aprendizado evidenciam a capacidade de generalização das redes neurais diante de situações desconhecidas.

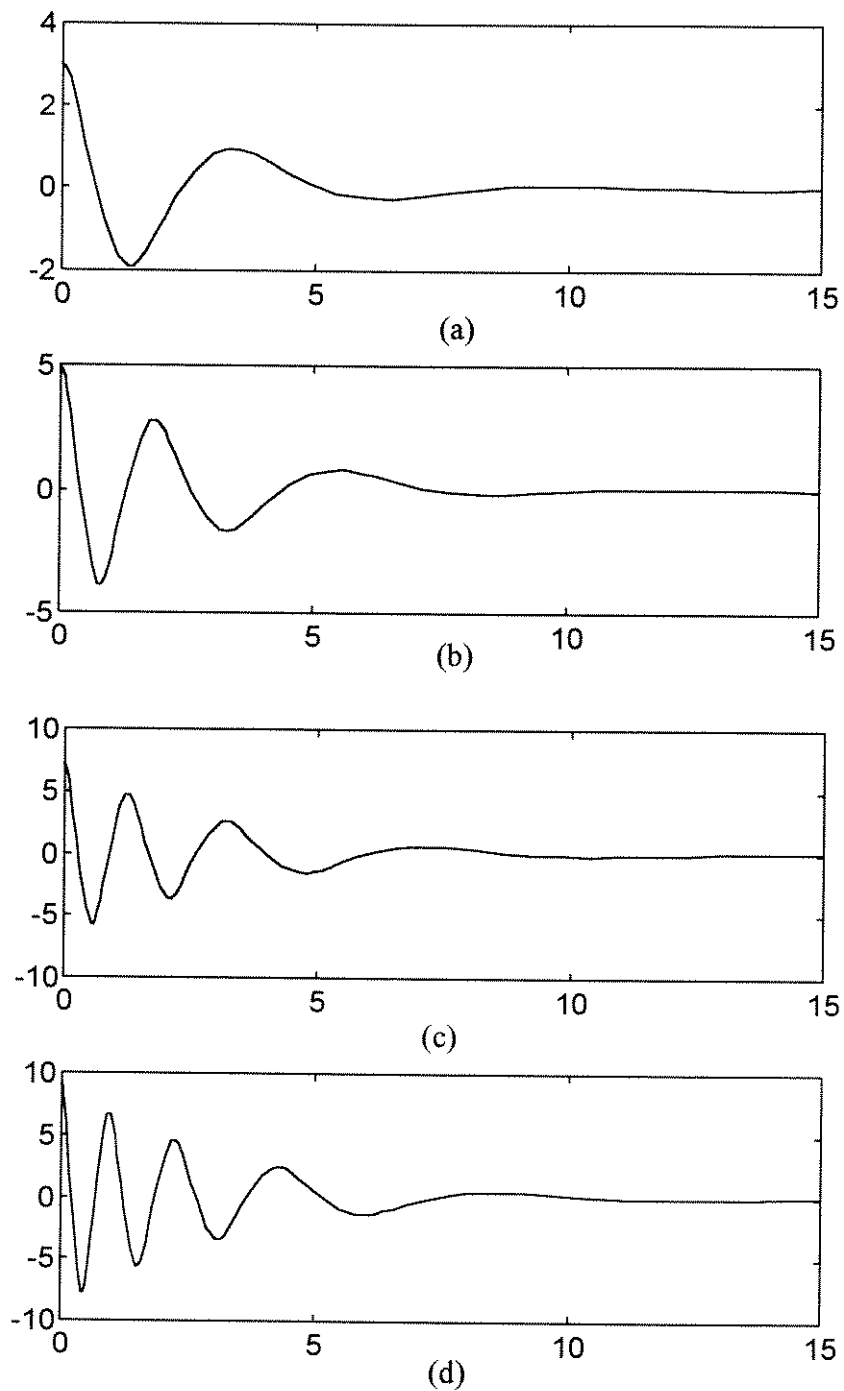


Figura 3.13 - Respostas dinâmicas do sistema real ( $x = f(t)$ ) para distintas condições iniciais.

(a)  $x_0 = 3$  (b)  $x_0 = 5$  (c)  $x_0 = 7$  (d)  $x_0 = 9$

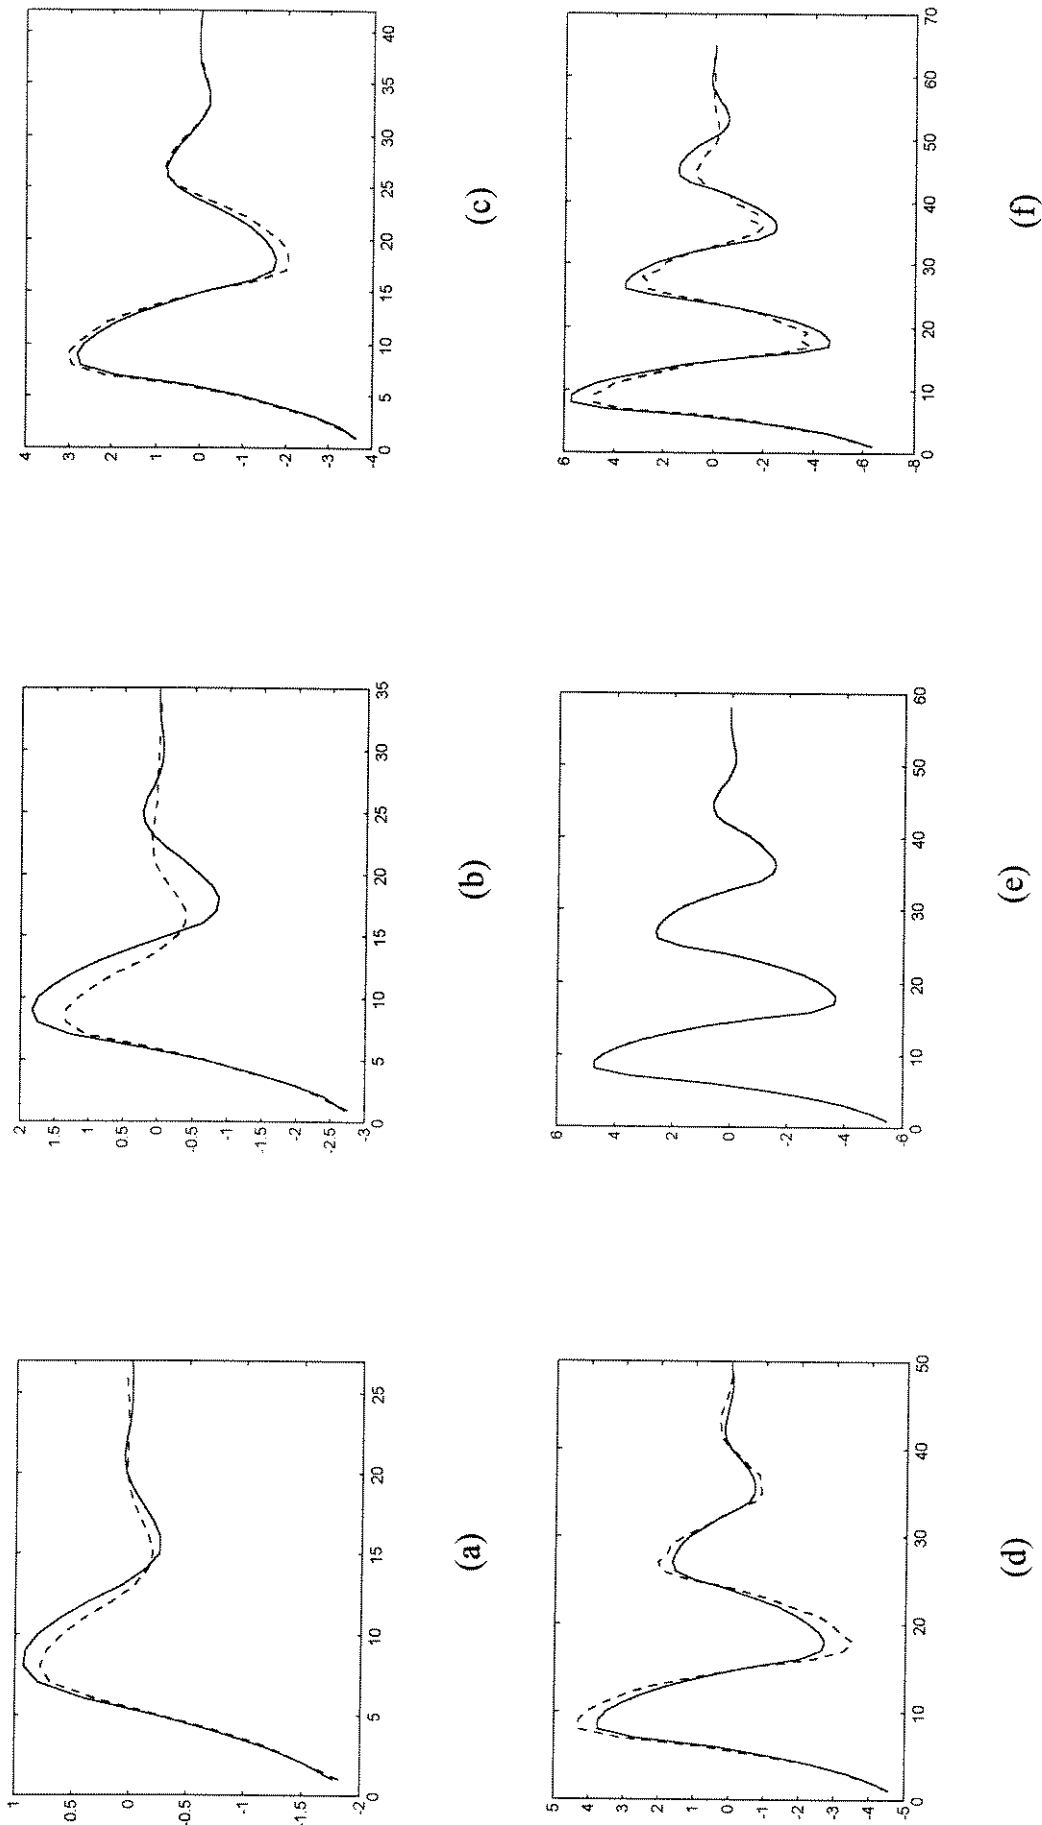


Figura 3.14- Respostas dinâmicas da rede neural e do sistema real ( $x = f(t)$ ) para distintas condições iniciais. (a)  $x_0 = 3$  (b)  $x_0 = 4$  (c)  $x_0 = 5$  (d)  $x_0 = 6$  (e)  $x_0 = 7$  (f)  $x_0 = 8$ .

### 3.3.6. Aplicações na Área de Máquinas Elétricas

Entre os ramos da Inteligência Artificial, a potencialidade exibida pelas Redes Neurais Artificiais sob o ponto de vista de processamento paralelo e mapeamento não linear foi valorizada em grande parte pelas pesquisas na área de máquinas elétricas como uma solução aos principais problemas de controle. O potencial das redes neurais para a implementação de algoritmos de controle rápidos e eficientes em motores elétricos é ainda hoje objeto de estudo. Nesta seção, vamos comentar brevemente alguns dos trabalhos apresentados na literatura especializada da área que usam esta ferramenta no desenvolvimento de técnicas de identificação e controle, com o objetivo de visualizar tendências e potencialidades de aplicação das Redes Neurais nos estudos de controle de Máquinas Elétricas.

#### Observador de fluxo e identificação da constante de tempo de rotor

O sucesso do controle por orientação de campo depende do conhecimento exato da posição espacial do vetor de fluxo ( de estator, de rotor ou de entreferro ). No controle por orientação do fluxo de estator é muito usado a estimação da magnitude e posição deste fluxo a partir das tensões e correntes de estator. Em alguns casos, quando é desejado a orientação segundo o fluxo do rotor, o valor e a posição espacial do mesmo é obtida a partir do cálculo prévio do fluxo do estator. Este processo de cálculo apresenta como principal desvantagem o problema de sensibilidade aos parâmetros, principalmente à resistência de estator; além das dificuldades presentes na estimação em frequências baixas, produto do processo de integração de sinais nesta faixa.

F. J. V. Zuben et al [33], desenvolvem um observador não linear de fluxo de rotor para o motor de indução operando sob o controle vetorial indireto, utilizando Redes Neurais Artificiais. O treinamento da rede baseou-se nos dados obtidos a partir da simulação digital das equações dinâmicas que governam o comportamento do fluxo do rotor. Para a representação do comportamento dinâmico foi usada uma rede neural recorrente, sendo que as variáveis de entrada à rede foram os valores de comando das componentes de corrente  $i_{qs}^e$  e  $i_{ds}^e$ , o valor de comando do escorregamento gerado

pelo controle, assim como os estados anteriores das componentes  $\lambda_{qr}^e$  e  $\lambda_{dr}^e$  do fluxo do rotor. A variável de saída da rede é o valor atual das componentes  $\lambda_{qr}^e$  e  $\lambda_{dr}^e$ .

Como foi visto no capítulo 2, o valor de referência do escorregamento gerado pelo controle depende do valor da constante de tempo de rotor da máquina que se altera devido ao aquecimento dos enrolamentos. Como esta constante é uma das variáveis de entrada à rede neural é necessário atualizar o seu valor. Com este objetivo é desenvolvido um bloco de identificação da constante de tempo do rotor utilizando expressões modificadas da relação entre o conjugado real produzido pela máquina e o conjugado de referência. O bloco de identificação proposto está formado por uma rede neural não recorrente de múltiplas camadas, que tem como entradas os valores atuais e de referência do conjugado eletromagnético. O valor real calculado a partir das componentes do fluxo do rotor  $\lambda_{qr}^e$  e  $\lambda_{dr}^e$  provenientes do observador de fluxo. A rede neural empregada faz neste caso um mapeamento estático, fornecendo na sua saída o valor da relação entre a constante de tempo de rotor real e a de referência. O valor de saída da rede é realimentado então à entrada do observador do fluxo do rotor, assim como também no bloco de cálculo da referência de frequência de escorregamento. Resultados de simulação são apresentados, mostrando o bom desempenho do método de controle usando tanto o estimador de fluxo, assim como o bloco de identificação da constante de rotor.

Profumo et al [34] desenvolvem um método de identificação da constante de tempo de rotor usando em princípio as mesmas equações utilizadas no trabalho de F. J. Zuben. Neste trabalho é mantida a estrutura do observador de fluxo convencional, com os inconvenientes comentados anteriormente.

### Controle de velocidade e do conteúdo harmônico para o motor de indução operando sob controle vetorial

Na seção de aplicações da Lógica Fuzzy na área de Máquinas Elétricas foi comentada a aplicação desta no controle de velocidade para motores de correntes contínua e alternada. As Redes Neurais Artificiais tem sido, da mesma maneira,

utilizadas diretamente como reguladores na malha de velocidade do controle de motores elétricos. Shyh - Jier et al [35] apresentam resultados de simulação do desempenho do controle vetorial, utilizando um regulador de velocidade baseado em Redes Neurais. Neste trabalho, a rede recebe como entrada a diferença ou erro entre a velocidade real do motor e a de referência e como saída fornece o valor do conjugado eletromagnético necessário para a condição de operação dada. No treinamento da rede foram colecionados dados de velocidade e conjugado da máquina para diferentes valores de tensão e frequência. Foi usada uma rede não recorrente de três camadas, com um neurônio na camada de entrada, seis na camada escondida e um na de saída. O algoritmo de treinamento adotado foi "*backpropagation*".

Nos resultados de simulação digital apresentados são estudadas as respostas do sistema para os casos de referência de velocidade constante e aquele em que o sistema é submetido a um sinal variável na referência de velocidade com variações em degraus. Estes resultados são comparados com aqueles obtidos utilizando um regulador PI convencional, mostrando a melhora produzida pela primeira abordagem em relação à diminuição do tempo de resposta à medida que varia o comando de velocidade. Ainda neste trabalho, são comparados o conteúdo harmônico das correntes e tensões do motor para os dois reguladores de velocidade: o regulador de velocidade convencional e aquele que utiliza redes neurais. Aplicando o método da Transformada de Fourier nos sinais de corrente e de tensão constata-se que o número de harmônicos do sistema que empregou redes neurais foi menor.

### Controle do inversor PWM

Um dos aspectos mais estudados na área de controle de máquinas, tem sido sem dúvidas, o controle da alimentação via inversor. A tarefa principal do algoritmo de controle do inversor é a de estabelecer uma lógica de chaveamento adequada, de maneira tal que as correntes de alimentação geradas sigam os valores de referência para produzir o conjugado eletromagnético necessário. Além disto o algoritmo de controle implementado deve ser suficientemente rápido para garantir uma frequência

de chaveamento alta, diminuindo assim o conteúdo de harmônicos nos sinais de alimentação.

As Redes Neurais Artificiais, pela sua inerente característica de processamento paralelo e distribuído, assim como a de mapeamento não linear, representam uma opção interessante na implementação de algoritmos de controle rápidos e eficientes. Com esta idéia em mente, Lorenz et al [36] apresentam resultados de implementação do controle de um inversor PWM utilizando redes neurais. A entrada da rede é, neste caso, o sinal de erro ou diferença entre as correntes de referência e reais, sendo a saída um dos oito possíveis vetores de estados para o chaveamento do inversor. Lorenz utilizou o algoritmo de "backpropagation" no treinamento da rede, e a função de ativação do tipo "threshold". O erro entre a saída real da rede, e a de um bloco paralelo que gera o vetor ótimo de chaveamento, foi utilizado como critério para o ajuste dos pesos no treinamento. Foi feito um estudo comparativo de duas abordagens de implementação do algoritmo de controle: uma inteiramente digital e a outra chamada de híbrida, caracterizada por uma combinação analógica - digital. Constata-se que a segunda abordagem apresentou uma velocidade de processamento maior.

### Identificação e controle do Motor de Indução

É conhecido o potencial das Redes Neurais Artificiais (RNA) nas tarefas de identificação e controle de sistemas dinâmicos não lineares [32]. Recentemente, o emprego destas nas tarefas de identificação e controle adaptativo em motores de indução, tem-se intensificado.

Embora sejam apresentados apenas resultados de simulação, o trabalho de Wishart, M. T.; Harley, R. G. [37] é o maior exemplo deste esforço, pois abandonando o modelo do motor em campo orientado, é feita uma identificação do motor de indução com o objetivo de projetar reguladores adaptativos para as correntes de estator e para a velocidade. A contribuição deste estudo é o fato de que o projeto do regulador, tanto para o caso das correntes de estator como para a velocidade da máquina, baseia-se em uma identificação prévia do modelo matemático através de redes neurais, a partir das medidas de tensão, corrente e velocidade em tempo real do sistema. A grande

vantagem do método de identificação proposto é que no treinamento da rede neural podem ser incorporados os efeitos de incertezas nos parâmetros, assim como os provenientes das perturbações externas dadas pelo conjugado de carga. No projeto do regulador é utilizado uma Rede Neural Artificial, cujos parâmetros são atualizados de maneira adaptativa, de acordo com o erro entre as saídas de um modelo de referência e aquela do modelo de identificação. Com base nesta abordagem são apresentados resultados de simulação para dois reguladores: um para as correntes de estator e outro para a velocidade do motor.



# **CAPÍTULO 4**

## *DESCRIÇÃO FUNCIONAL DO SISTEMA IMPLEMENTADO*

### **4.1. Introdução**

Embora o desenvolvimento das técnicas de controle por orientação pelo campo data do final da década de 60 e início da década de 70 ( Hasse 1969, Blaschke 1972 ), estas só passaram a ser largamente implementadas nos últimos anos, dado os crescentes avanços na área da eletrônica digital, assim como o conseqüente surgimento de microprocessadores com uma alta velocidade de processamento e de características funcionais específicas, facilitando a implementação dos mais diversos algoritmos de controle.

O controle em acionamentos elétricos sempre foi visto com especial interesse pelos fabricantes de microprocessadores, dada a complexidade de cálculo e as especificidades funcionais dos algoritmos de controle a serem implementados. No final da década de 80, o surgimento de microcontroladores tais como 87C196 KD de 16 bits da Intel e o 68332 da Motorola, e o processador digital de sinais da Texas TMS 310C10, deram um grande impulso à implementação digital de controladores vetoriais em acionamentos elétricos e, em particular, ao método por orientação indireta de fluxo. Já, no início dos anos 90, são os processadores digitais de sinais (DSP) tão usuais na área de comunicações, que passam a ser predominantes no controle digital de máquinas elétricas. Isto se deve ao fato deles combinarem flexibilidade operacional, alta velocidade de processamento e um custo declinante.

Neste capítulo é feita uma descrição funcional da implementação do controle indireto pela orientação do fluxo de rotor utilizando o microcontrolador de INTEL 87C196KD. Além disto é discutido a implementação de um algoritmo de identificação da constante de tempo elétrica do rotor utilizando Redes Neurais Artificiais, assim como o projeto e a implementação no controle indireto de um regulador de velocidade com base em Lógica Fuzzy.

#### **4.2 Diagrama de blocos do sistema implementado**

A Figura 4.1 mostra o diagrama geral de blocos do sistema implementado. Nesta seção são comentadas brevemente as características gerais do microcontrolador usado na implementação, para em seguida discorrer sobre os principais blocos que constituem o sistema segundo a sua função.




Figura 4.1- Diagrama geral de blocos do sistema implementado.

### 4.2.1 Características Gerais do Microcontrolador da INTEL 87C196KD

O microcontrolador 87C196KD tem sido projetado principalmente para processar dados de entrada/saída de alta velocidade. Uma das características principais que fazem dele um elemento adequado à implementação de controle para acionamentos elétricos, é a de apresentar em "hardware" funções PWM, além da sua funcionalidade derivada de sua arquitetura de 16 bits e demais características de hardware que serão comentadas posteriormente. O diagrama geral de blocos deste microcontrolador é mostrado na Figura 4.2.

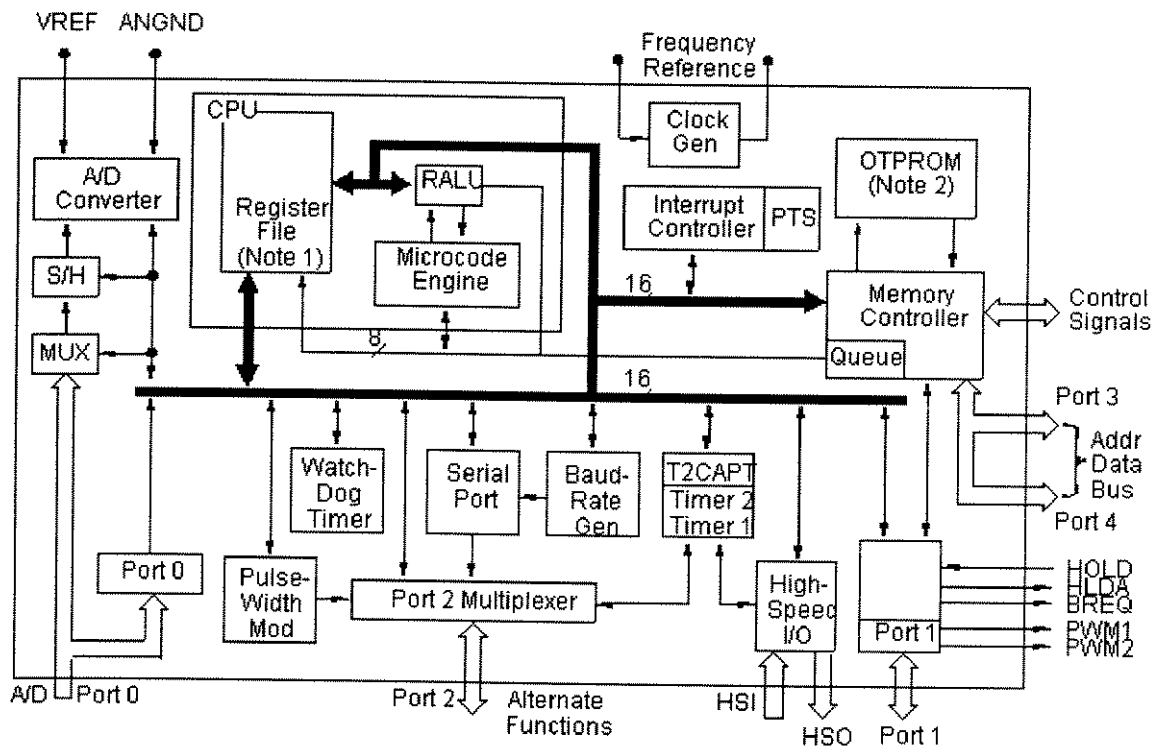


Fig. 4.2 - Diagrama de blocos do microcontrolador INTEL 87C196KD.

As principais características deste microcontrolador são as seguintes:

- **Operação de 20 Mhz.** É a frequência do oscilador externo. Internamente o microcontrolador divide esta frequência por 2 e todas as operações internas são referidas à frequência de 10 Mhz, se define o estado  $T=(1/10 \text{ Mhz})$ .

- **RAM de registros de 1000 bytes.**, dos quais 232 podem ser adquiridos com instruções rápidas (endereçamento direto por registro) e a os restantes pode ser aplicada a técnica "vertical windowing" para transferir porções altas de memória à porções baixas, e assim usar as instruções relativas a registros e definir áreas de RAM independentes para cada rotina.
- **Modos de operação "Powerdown" e "Idle"**. São modos de operação nos quais o consumo de corrente no microcontrolador é reduzido ao 40% do consumo normal.
- **Arquitetura registro a registro.** A maioria das operações são realizadas entre registros do CPU inclusive as operações de entrada/saída (E/S).
- **Memória programável com técnicas "ONE-TIME" (OTPROM).** O microcontrolador fornece vários métodos para programar a memória interna.
- **Subsistema de E/S de alta velocidade.** Tem pinos dedicados de E/S de alta velocidade unidos a uma estrutura FIFO para armazenar os dados e 2 métodos de interrupções para a captura ou envio de dados.
- **Multiplificação de 16x16 bits em 1.4  $\mu$ s.** Tem instruções de multiplificação em ponto fixo com resultado em 32 bits.
- **Divisão de 32/16 bits em 2.4  $\mu$ s.** Também tem instruções de divisão em ponto fixo com resultado em 16 bits.
- **Amplitude de "bus" dinamicamente configurável em 8 ou 16 bits.** Empregando registros do CPU pode-se configurar o bus de saída. No caso de empregar "bus" de 8 bits algumas instruções do microcontrolador são mais lentas.
- **Fontes de interrupção=28, Vetores=16.** O microcontrolador tem interrupções externas e internas que permitem sincronizar eventos com outras operações.
- **Protocolo de "bus" HOLD#/HLDA#.** Estas linhas são usadas para fazer transferências de dados para memória em alta velocidade. O símbolo # indica que o sinal é ativado com nível lógico baixo. ("HLDA= Hold Acknowledge")

- **Porta serial "full duplex"**. É usada para a comunicação com o host (PC) pela ferramenta de desenvolvimento (neste caso "ApBuilder").
- **Timer de 16 bits**. Permite contar "UP/DOWN" e gerar interrupções utilizando como relógio do contador 0.1 ou 0.8  $\mu$ s.
- **Três saídas moduladas por largura de pulso**. Podem ser de 19 ou 38 KHz e a modulação pode ser controlada por um registro do CPU com 256 valores de modulação.
- **Conversor A/D de 8 ou 16 bits com "sample/hold"**. Tem 8 canais analógicos multiplexados com tempos de conversão programáveis de até no mínimo 20  $\mu$ s.
- **Cinco portas de E/S de 8 bits**. Alguns desses "bits" podem assumir outras funções, podem ser bi-direcionais, só entrada ou só saída. Esta múltipla funcionalidade exige um certo cuidado no seu uso.

#### 4.2.2 - Aquisição dos Sinais de Entrada do Microcontrolador

Para a implementação do sistema de controle são adquiridos os valores das correntes nas fases do motor, como também a velocidade mecânica.

- *Aquisição dos sinais de corrente.*

Para medir as correntes do motor, sensores de efeito Hall são colocados em duas fases. Estes sinais de corrente são transformados para o sistema de coordenadas  $\alpha$ - $\beta$ , antes de dar entrada ao microcontrolador. As equações que governam esta transformação são as seguintes:

$$i_{\alpha} = i_{an} \quad (4.1)$$

$$i_{\beta} = \frac{1}{\sqrt{3}} (i_{bn} - i_{cn}) \quad (4.2)$$

nas quais,

$i_{an}$ ,  $i_{bn}$  e  $i_{cn}$  são as correntes instantâneas em cada uma das fases do motor.

A equação 4.2 pode ser expressa em função das correntes de duas fases, neste caso a e b. Considerando que não existe fio de neutro, podemos escrever que:

$$i_{cn} = -i_{an} - i_{bn} \tag{4.3}$$

e substituindo esta equação em (4.2), obtém-se:

$$i_{\beta} = \frac{1}{\sqrt{3}} (i_{an} + 2i_{bn}) \tag{4.4}$$

As equações 4.1 e 4.4 representam a transformação do sistema trifásico ao sistema bifásico estacionário. Este tipo de transformação foi implementada externamente ao microcontrolador através de "hardware", utilizando amplificadores operacionais como mostrado na Figura 4.3. Uma descrição detalhada desta implementação é apresentada na referência [38].




Figura 4.3 - Geração de  $i_{\alpha}$  e  $i_{\beta}$ .

Além de realizar esta transformação o "hardware" deve normalizar os valores de saída do bloco anterior aos níveis adequados, antes destes entrarem no microcontrolador, ou seja na faixa de 0 à 5 V. Dois canais do conversor analógico - digital recebem estes sinais normalizados.

### *- Aquisição do sinal de velocidade.*

A informação referente à velocidade mecânica do motor é obtida a partir da saída do gerador rotativo incremental de pulsos ( "encoder" ), colocado no eixo. O "encoder" gera um trem de pulsos de frequência proporcional à velocidade com amplitude na faixa 0 à 5V. O sinal de saída do "encoder" é introduzido no microcontrolador, neste caso pela Porta #2, mais especificamente no pino #2. Esta entrada ao microcontrolador foi configurada por software para operar em modo de interrupção, e desta forma em cada borda de subida do trem de pulsos é gerada uma interrupção. Na rotina de tratamento da interrupção é feita a contagem do número de pulsos gerados. O algoritmo de controle calcula a velocidade mecânica a partir do conhecimento deste número de pulsos, a constante específica do encoder dado pelo fabricante e o intervalo de tempo dado para o início da rotina de controle. Um outro método de cálculo para a velocidade mecânica testado nesta implementação consistiu na determinação direta do período do trem de pulsos, inicializando uns dos "Timers" do microcontrolador, especificamente o "Timer" #1 de 16 bits. O valor deste foi lido diretamente em um dos registros do microcontrolador. O procedimento de cálculo do período do trem de pulsos é realizado da seguinte maneira: entre uma interrupção e outra gerada pelo encoder, é lido o valor do registro associado ao "Timer" #1, e este valor multiplicado por  $0.8 \mu\text{s}$ , que é o intervalo de tempo no qual é incrementada a conta do registro, resulta no valor do período para a velocidade atual. A partir da constante específica do encoder é possível determinar o ângulo correspondente a um período, e então dividendo este valor pelo período calculado anteriormente determinamos a velocidade

### **4.2.3. Regulador PI de Velocidade**

Na estrutura do controle indireto mediante a orientação do fluxo do rotor, é usado um regulador Proporcional Integral ( PI ) na malha de velocidade, que produz na sua saída o valor da componente de corrente de estator associada à produção de conjugado eletromagnético. O regulador PI usa como entrada o erro entre a velocidade mecânica



de referência da máquina e a velocidade real, sendo esta última obtida a partir da saída do "encoder", como foi descrito anteriormente.

A função de transferência de um regulador PI convencional pode ser expressa como segue:

$$\frac{Y(s)}{E(s)} = K_P + \frac{K_I}{s} \quad (4.5)$$

na qual,

$Y(s)$  : Transformada de Laplace da saída do regulador

$E(s)$  : Transformada de Laplace da entrada ao regulador

$K_P$  e  $K_I$  : Ganhos proporcional e integral do regulador

Arranjando os termos da equação 4.5 podemos escrever que:

$$sY(s) = sK_P E(s) + K_I E(s) \quad (4.6)$$

Aplicando a Transformada Inversa de Laplace à esta expressão obtemos a equação do regulador PI convencional no domínio do tempo:

$$\frac{dY(t)}{dt} = K_P \frac{dE(t)}{dt} + K_I E(t) \quad (4.7)$$

O modelo discreto deste regulador é dado por:

$$Y(k) = Y(k-1) + K_P [E(k) - E(k-1)] + K_I E(k)h \quad (4.8)$$

na qual,

$k$  e  $(k-1)$  representam os instantes de tempo discretos  $k$  e  $(k-1)$  respectivamente.

$h$ : valor do período de amostragens dos sinais.

O diagrama de blocos da Figura 4.4 mostra a estrutura de funcionamento de regulador PI, a partir do seu modelo discreto:




Figura 4.4 - Diagrama de blocos do regulador PI discreto.

#### 4.2.4. Estimação do Ângulo Elétrico

Para realizar a transformação das correntes do motor do sistema de referência síncrono ao estacionário é necessário o conhecimento do ângulo elétrico do fluxo do rotor  $\theta_e$ . No controle indireto por orientação do fluxo de rotor a determinação deste ângulo é feita a partir da estimação da referência de frequência de escorregamento e da medição da velocidade mecânica do motor. Para a determinação da referência da frequência de escorregamento é utilizada a expressão dada no capítulo 2 para  $i_{ds}^e$  constante, e que, por conveniência é reescrita a seguir:

$$\omega_{slip} = \frac{1}{T_r^*} \frac{i_{qs}^e}{i_{ds}^e} \quad (4.9)$$

O diagrama de blocos da Figura 4.5 ilustra o processo de estimação baseado na expressão 4.9.




Figura 4.5 - Estimação da referência de frequência de escorregamento.

O valor de referência da frequência de escorregamento é somado com a velocidade mecânica do motor, resultando então na frequência elétrica:

$$\omega_e = \omega_{slip}^* + \omega_r \tag{4.10}$$

Integrando o valor resultante de (4.10), obtemos o valor do ângulo elétrico:

$$\theta_e = \int_0^t \omega_e dt \tag{4.11}$$

O processo de integração pode ser expresso do domínio do tempo discreto como:

$$\theta_e(k) = \theta_e(k - 1) + \omega_e h \tag{4.12}$$

O processo descrito anteriormente é ilustrado na Figura 4.6.




Figura 4.6 - Estimação do ângulo do fluxo de rotor.

#### 4.2.5. Transformação do Sistema de Referência Síncrono ao Estacionário

O método de controle usado para o inversor tem como entradas as correntes reais e as de referência do motor expressas no sistema estacionário. Como foi explicado na parte referente à aquisição dos sinais do motor, o microcontrolador recebe as correntes reais expressas no sistema estacionário  $i_\alpha$  e  $i_\beta$ . Por outro lado o bloco de controle gera as componentes de correntes do estator de referência segundo um referencial síncrono  $i_{qs}^e$  e  $i_{ds}^e$ . Sendo assim, é necessário expressar as componentes de correntes de

estator de referência no sistema estacionário, de tal forma que possam ser comparadas com as reais no algoritmo de controle do inversor.

Para efetuar esta transformação, além dos valores das correntes de referência no sistema síncrono geradas a partir do controle, é necessária a informação referente ao ângulo elétrico. As equações de transformação entre estes dois sistemas de referência são as seguintes [1]:

$$i_{\alpha}^* = i_{qs}^{e*} \cos(\theta_e) + i_{ds}^{e*} \text{sen}(\theta_e) \tag{4.13}$$

$$i_{\beta}^* = -i_{qs}^{e*} \text{sen}(\theta_e) + i_{ds}^{e*} \cos(\theta_e) \tag{4.14}$$

Como se observa a transformação depende do conhecimento dos valores do cosseno e seno do ângulo  $\theta_e$ . Para o cálculo destes valores foi implementada uma tabela de busca ( "lookup table" ) na memória RAM do microcontrolador 87C196KD, com o objetivo de obter uma maior velocidade no processo de transformação. Na tabela de busca são colocados os valores do seno do ângulo no intervalo de 0 a 450° com passo de um grau entre cada ângulo, empregando uma precisão de 16 bits para cada valor do seno. A maneira com que esta tabela é organizada na memória, está mostrada na Figura 4.7.




Figura 4.7- Estrutura da tabela de busca com os valores do seno.

O algoritmo de busca dos valores do seno e do cosseno pode ser explicado da seguinte maneira. Suponhamos, como exemplo, que tenhamos que procurar os valores de seno e cosseno de  $30^\circ$ . Dois apontadores são inicializados no microcontrolador, indicando a posição de memória RAM onde estão os valores do seno e do cosseno de  $0^\circ$ . Consideremos ainda, sem perda de generalidade, que a tabela da Figura 4.7 comece na posição de memória #0. Sendo assim o apontador do seno referencia a posição de memória #0, enquanto o do cosseno a posição #180. Este procedimento está ligado ao fato das funções seno e cosseno apresentar uma defasagem de  $90^\circ$ . A partir disto o valor do seno de  $30^\circ$  pode ser obtido lendo diretamente o conteúdo da posição de memória #61 e #62, enquanto processo de busca do valor do cosseno, transforma-se na busca do valor do seno do ângulo  $30^\circ + 90^\circ$ , ou seja lendo-se o conteúdo das posições de memória #241 e #242 a partir do apontador do seno, ou equivalentemente lendo o conteúdo dos endereços #61 e #62 tomando como referência o apontador do cosseno.

A partir disto as posições de memória onde se encontram os valores de seno e cosseno para um dado ângulo  $\theta_e$ , podem ser expressas como segue:

- para o seno:

$$\text{Localização do valor do seno} = \text{PSen} + 2 * \theta_e + 1$$

-para o cosseno:

$$\text{Localização do valor do cosseno} = \text{PCos} + 2 * \theta_e + 1$$

nas quais:

PCos e PSen: são os valores de posição de memória associados aos apontadores do cosseno e o seno, respectivamente.

O diagrama da Figura 4.8 ilustra o processo de transformação do sistema de referência síncrono ao estacionário para as correntes de comando.

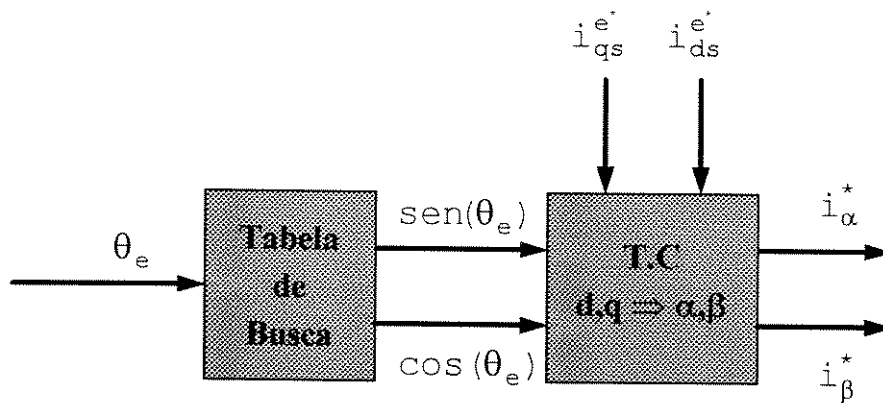


Figura 4.8 - Transformação do sistema de referência síncrono ao estacionário.

### 4.3. Identificação da Constante de Tempo Elétrica do Rotor utilizando Redes Neurais Artificiais

No capítulo 2 foi discutido os efeitos negativos ocasionados pela variação de parâmetros, no desempenho de regime e de estado estacionário do controle indireto mediante a orientação do fluxo de rotor. A maior sensibilidade deste método de controle aos parâmetros, está associada a variação da constante de tempo do rotor, principalmente devido à influência direta da temperatura no valor da resistência do rotor. Dentro do algoritmo de controle o valor da constante de tempo do rotor é empregada na estimação da frequência de escorregamento, esta estimativa é usada conjuntamente com a velocidade para a determinação do ângulo elétrico, empregado logo depois na rotação das correntes.

Neste trabalho é proposto e implementado um método de identificação da constante de tempo do rotor utilizando Redes Neurais Artificiais. O método proposto é baseado no trabalho de Lorenz [44], o qual foi discutido na seção 2.10 do capítulo 2. A capacidade de aproximação das Redes Neurais Artificiais são aproveitadas nesta implementação. O digrama de blocos do sistema implementado para a identificação da constante de tempo do rotor aparece na Figura 4.9.

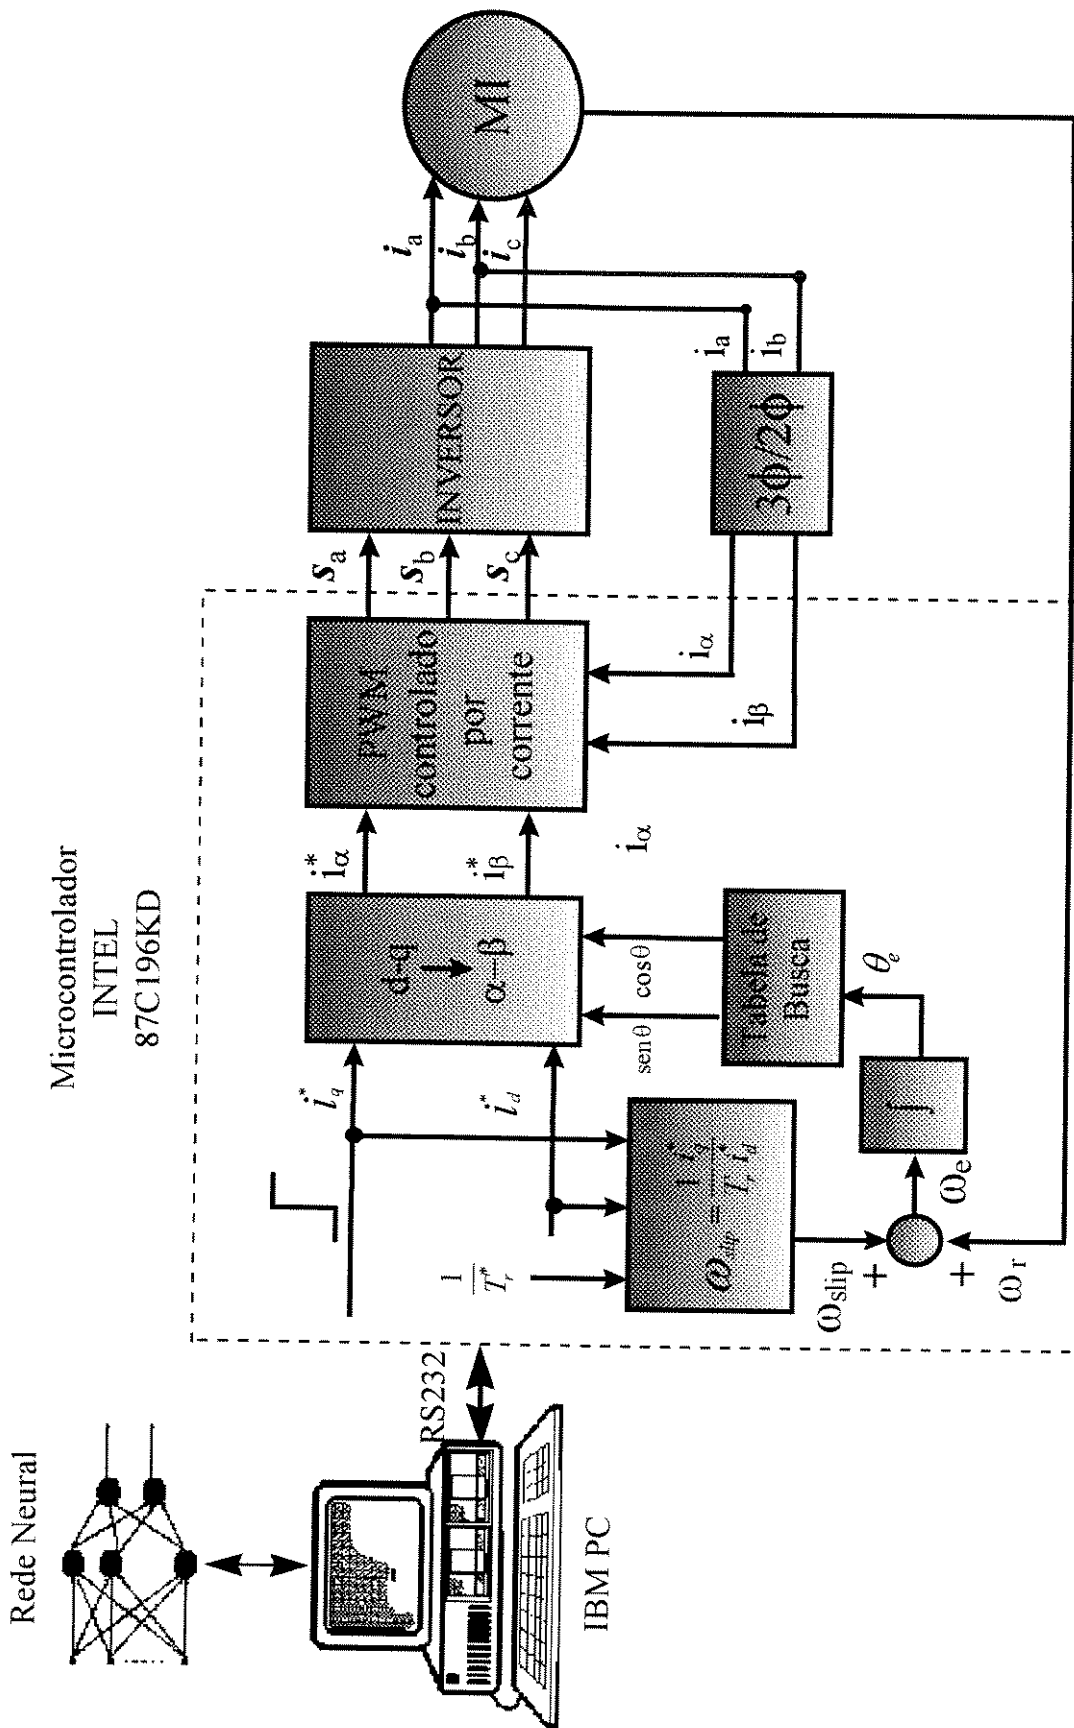


Figura 4.9 - Diagrama de blocos do sistema de identificação da constante de tempo do rotor.

Do diagrama de blocos observa-se que neste caso o sistema de controle opera sem a malha de velocidade. Na estrutura original do controle o regulado PI de velocidade tinha a tarefa de gerar a componente  $i_{qs}^e$  de corrente de estator; neste sistema de identificação é gerada por software dentro do microcontrolador um sinal de  $i_{qs}^e$  do tipo degrau. O uso de um sinal de  $i_{qs}^e$  do tipo degrau é suficiente para identificar a partir da resposta de velocidade o valor da constante de tempo do rotor.

Inicialmente a máquina é excitada pela componente de corrente de estator  $i_{ds}$  necessária para gerar o fluxo nominal e, uma vez alcançado o valor de regime do fluxo, é dado o sinal de degrau na referência de  $i_{qs}$ . O sinal de velocidade obtido na saída do "encoder", entra em um conversor de frequência - tensão, e o sinal de saída deste é introduzido ao microcontrolador através de um dos canais do conversor análogo digital. Uma vez dentro do microcontrolador os dados do transitório de velocidade são enviados, via a porta serial RS232, até o PC que opera como "host" do microcontrolador. No computador encontra-se o "software" de identificação, consistente em uma rede neural não recorrente de múltiplas camadas previamente treinada. A rede neural recebe como entrada os dados temporais do transitório e fornece na sua saída o valor da relação entre a constante de tempo real e a de referência, ou seja  $Tr/Tr^*$ . O processo de normalização dos dados de entrada à rede é feito no computador.

Para o treinamento da rede foram tomados dados referentes a 80 transitórios de velocidade para diferentes valores da relação  $Tr/Tr^*$ , usando o mesmo degrau de conjugado em cada um destes. Para conseguir diferentes valores de  $Tr/Tr^*$ , foi utilizada uma resistência trifásica conectada externamente ao circuito de rotor. A estrutura da rede neural utilizada contém três camadas, com 16 neurônios na camada de entrada, 10 na camada escondida e um neurônio na camada de saída. O treinamento foi feito usando o algoritmo de retro-propagação do erro ("backpropagation"), com um fator de aprendizado de 0.1 e um ganho no termo do momento de 0.25.



#### 4.4. Regulador Fuzzy de Velocidade

Uma análise do desempenho dinâmico do sistema de controle ante variações da constante de tempo do rotor, foi feito no capítulo 2. Foram obtidas através de simulação as respostas de velocidade, quando o sistema submetido a sinais de referência de velocidade do tipo degrau; usando um regulador PI convencional na malha de velocidade. Outros trabalhos [20] fazem um estudo similar, considerando variações no conjugado de carga. Em todos estes estudos, fica evidente a deterioração do desempenho do sistema, no que diz respeito ao tempo de resposta, ante as variações dos parâmetros e perturbações externas. Na teoria de sistemas de controle lineares o ajuste dos ganhos do regulador pode ser analisado analiticamente, usando por exemplo técnicas do domínio da frequência, procurando satisfazer determinados índices diretamente relacionados com o desempenho do sistema, como margem de fase, margem de ganho e largura de banda. Para o caso de sistemas não lineares estes métodos não estão bem estabelecidos, e em muitos casos, quando é desejado estudar analiticamente o sistema, são usadas aproximações que conduzem ao caso linear. O projeto de reguladores robustos é até hoje objeto de constantes estudos na área de sistemas de controle, em especial os projetos de controle ótimo que utilizam a teoria de  $H_2$  e  $H_\infty$ . Reguladores baseados na Lógica Fuzzy tem sido nos últimos anos objeto de diversas implementações, especificamente na área de controle de máquinas elétricas [14].

Neste trabalho é implementado um regulador de velocidade baseado em Lógica Fuzzy para operar na malha de velocidade do controle. O regulador recebe como sinais de entrada a diferença ou erro entre a velocidade mecânica de referência e a velocidade real do motor, sendo a saída deste a variação na componente de corrente de estator  $i_{qs}^e$ , ou seja  $\Delta i_{qs}^e$ . O valor atual da referência de  $i_{qs}^e$  é calculado a partir de  $\Delta i_{qs}^e$  como mostrado na Figura 4.10.




Figura 4.10 - Cálculo da referência atual de  $i_{qs}^e$  a partir do valor de  $\Delta i_{qs}^e$ .

Tanto para as variáveis de entrada do regulador, como para a variável de saída deste, foram empregados 5 conjuntos fuzzy, resultando no total de 25 regras de inferência. As Figuras 4.11 e 4.12 mostram os gráficos das funções de pertinência usadas para cada uma das variáveis do sistema, assim como a interface do regulador.

Os valores do universo de discurso das variáveis de entrada e de saída estão normalizados e, os termos usados para os conjuntos "fuzzy" ( LN, SN, ZE, SP, LP ) tem os seguintes significados lingüísticos:

LN: Grande Negativo.

SN: Pequeno Negativo.


ZE: Zero.

SP: Pequeno Positivo.


LP: Grande Positivo.

As regras de inferência são mostradas na tabela 4.1, onde valores da terceira coluna ("DoS" ), representam o grau de suporte de cada uma das regras. O conjunto de regras usadas são similares às que aparecem em outros trabalhos [20 ,22]. O método de "defuzzificação" empregado foi o método do centro de gravidade. O desempenho do regulador fuzzy foi simulado antes de ser implementado no microcontrolador utilizando o "software" da INTEL fuzzy/TECH [45], que permite gerar em código C as rotinas do regulador. Algumas adaptações tiveram de ser feitas na etapa de compilação do código gerado, dado pelo fato de possuir só uma versão demonstrativa do compilador C

do microcontrolador. Este mesmo "software" é usado pela TEXAS Instruments [26], na geração de código para suas aplicações baseadas em Lógica Fuzzy.




(a)




(b)

Figura 4.10 - Funções de pertinência das variáveis de entrada do regulador fuzzy.



(a)

## Fuzzy PI Controller



(b)

Figura 4.11 - (a) Função de pertinência da variável de saída do regulador fuzzy. (b) Interface do regulador fuzzy.

**Tabela 4.1 - Regras de inferência do regulador fuzzy.**

No	Derivada_Error	Error	DoS	Delta_Iqs
1	LP	LN	1.0	ZE
2	LP	SN	1.0	SP
3	LP	ZE	1.0	LP
4	LP	SP	1.0	LP
5	LP	LP	1.0	LP
6	SP	LN	1.0	SN
7	SP	SN	1.0	ZE
8	SP	ZE	1.0	SP
9	SP	SP	1.0	SP
10	SP	LP	1.0	LP
11	ZE	LN	1.0	SN
12	ZE	SN	1.0	SN
13	ZE	ZE	1.0	ZE
14	ZE	SP	1.0	SP
15	ZE	LP	1.0	SP
16	SN	LN	1.0	LN
17	SN	SN	1.0	SN
18	SN	ZE	1.0	SN
19	SN	SP	1.0	ZE
20	SN	LP	1.0	SP
21	LN	LN	1.0	LN
22	LN	SN	1.0	LN
23	LN	ZE	1.0	LN
24	LN	SP	1.0	SN
25	LN	LP	1.0	ZE

# *CAPÍTULO 5*

## *RESULTADOS EXPERIMENTAIS*

### **5.1 Introdução**

Neste capítulo são apresentados os principais resultados obtidos experimentalmente, a partir do sistema descrito no capítulo 4. A Figura 5.1 mostra uma imagem da instalação utilizada na implementação do sistema de controle do motor de indução.

A apresentação dos resultados vai ser dividida em três partes fundamentais. Na primeira parte são mostrados os resultados referentes à influência da variação dos parâmetros na resposta de velocidade do motor sob ação do sistema de controle. Na segunda parte são mostrados as curvas experimentais de resposta de velocidade para diferentes graus de acoplamento, obtidas utilizando dois tipos de reguladores de velocidade: o regulador PI convencional e um regulador fuzzy. Por último são apresentados os resultados referentes ao sistema de identificação da constante de tempo elétrica do rotor.

As curvas apresentadas foram tomadas utilizando o osciloscópio digital TDS 340 da Tektronix, o qual recebe como entrada o sinal de saída do conversor de frequência em tensão. Este sinal é enviado até o PC utilizando o "software" de aquisição do osciloscópio.




Figura 5.1 - Instalação experimental utilizada na implementação.

## 5.2 Resultados Referentes à Influência dos Parâmetros na Resposta de Velocidade do Sistema de Controle.

As Figuras 5.2, 5.3 e 5.4 mostram as respostas de velocidade do sistema de controle, para uma variação de tipo degrau na referência de velocidade, sendo utilizado na malha de velocidade um regulador PI convencional. As características mostradas encontram-se parametrizadas pelo valor da resistência do rotor. Foram utilizadas três valores de resistência, tais que  $R_{r3} > R_{r2} > R_r^*$ , para  $R_r^*$  correspondendo ao valor nominal da resistência do rotor, ou seja aquele utilizado no controle para a estimação do escorregamento.






Figura 5.2 - Resposta de velocidade para degrau de referência com resistência do rotor  $R_{r1}$ .




Figura 5.3 - Resposta de velocidade para degrau de referência com resistência do rotor  $R_{r2}$ .




Figura 5.4 - Resposta de velocidade para degrau de referência com resistência do rotor  $R_r$ .

As características transitórias mostradas nas Figuras 5.2, 5.3 e 5.4, verificam os resultados de simulação obtidos no capítulo 2. Pode-se concluir que à medida que se aumenta o valor da resistência do rotor em relação ao seu valor nominal, aumenta-se em consequência o grau de acoplamento, e a resposta do sistema piora em termos de velocidade. O tempo aproximado de estabelecimento da velocidade de regime para os casos das Figuras 5.2, 5.3 e 5.4 foi de 0.413 s, 0.586 s e 1.155 s respectivamente.

O último resultado experimental desta seção aparece na Figura 5.5, na qual foi adotado um valor de resistência do rotor levemente superior ao seu valor nominal e os ganhos do regulador PI são alterados convenientemente com o fim de obter a resposta do tipo mostrada. Neste caso os ganhos do regulador não são os adequados, e isto aliado à condição de acoplamento conduziu à presença de sobrepicos ("overshoot") na resposta dinâmica do sistema, como ilustrado na Figura 5.5. Como foi visto no capítulo 2 à medida que se aumenta o grau de acoplamento, os pólos de malha fechada do sistema aproximam-se do eixo imaginário, resultando por tanto, no surgimento de oscilações amortecidas. Com uma seleção adequada nos ganhos do regulador, pode-se compensar de certa maneira este efeito.






Figura 5.5 - Resposta de velocidade para degrau de referência com ganhos inadequados do regulador PI com  $R_r > R_r^*$ .

### 5.3 Resultados referentes ao Regulador Fuzzy de Velocidade.

Os testes experimentais do regulador fuzzy de velocidade foram estruturados da seguinte maneira: o sistema é submetido a dois degraus na referência de velocidade utilizando primeiramente o regulador PI convencional e logo a seguir o regulador fuzzy. Num primeiro teste a resistência do rotor é mantida no seu valor nominal, para depois realizar este mesmo teste com um valor maior da resistência do rotor em relação ao nominal. As Figuras 5.6 e 5.7 mostram as características transitórias obtidas em cada caso.



(a)



(b)

Figura 5.6 - Resposta de velocidade para referência variável de velocidade com resistência de rotor  $R_r^*$ : (a) Regulador PI (b) Regulador fuzzy.





Figura 5.7 - Resposta de velocidade para referência variável de velocidade com.  $R_r > R_r^*$ : (a) Regulador PI (b) Regulador fuzzy.

Das Figuras 5.6 e 5.7 podemos concluir o seguinte: para o caso em que o valor da resistência do rotor é mantida no valor nominal ( Figura 5.6 ), não existe muita diferença entre a resposta do regulador PI e a do regulador fuzzy, apresentando o sistema um transitório satisfatório em ambos casos, em termos de velocidade de resposta. Nos resultados em que a resistência do rotor empregada no teste difere do seu valor nominal ( Figura 5.7 ) fica evidente, das características transitórias de velocidade, que o tempo de resposta quando é utilizado o regulador fuzzy é menor que no caso do regulador PI convencional, mas maior para o teste sob a condição de desacoplamento ideal.


#### **5.4 Resultados Referentes ao Sistema De Identificação da Constante de Tempo Elétrica do Rotor Utilizando Redes Neurais Artificiais.**

Para testar experimentalmente o sistema de identificação da constante de tempo elétrica do rotor descrito no capítulo 4, foram obtidos transitórios de velocidade para diferentes valores da resistência do rotor, e diante um sinal fixo do tipo degrau na referência de  $i_{qs}^e$ . Os dados do transitório de velocidade constituem-se nas entradas da rede neural já treinada, a qual fornece na sua saída o valor da relação  $\frac{T_r}{T_r^*}$ . Uma vez obtido o valor da relação anterior é atualizada a constante de tempo nominal utilizada pelo controle e é repetido o teste com o novo valor de  $T_r^*$ . As Figuras 5.8, 5.9 e 5.10 mostram os resultados dos transitórios de velocidade antes e depois da atualização de  $T_r^*$ . Os dois primeiros casos ( Figuras 5.8 (a) e 5.9 (a) ) correspondem às situações onde o valor da resistência real do rotor é maior que o valor nominal, e estes transitórios foram obtidos mudando o valor da resistência trifásica conectada externamente ao circuito do rotor. A Figura 5.10 (a) mostra o caso em que a resistência nominal do rotor, ou seja aquela utilizada pelo algoritmo de controle, apresenta um valor maior que o real. Este transitório foi obtido modificando o valor de  $T_r^*$  no algoritmo de controle. A


tabela 5.1 mostra para cada um dos testes o valor da relação  $\frac{T_r}{T_r^*}$  obtido logo após de desnormalizar a saída da rede neural.

**Tabela 5.1- Saída fornecida pela Rede Neural para os três casos de teste.**

Nº do Teste	Saída da Rede Neural. ( $T_r / T_r^*$ )
1 ( Figura 6.8 )	0.6578
2 ( Figura 6.9 )	0.5310
3 ( Figura 6.10 )	1.9776




(a)




(b)

Figura 5.8 - Resposta do sistema ao degrau na referência de  $i_{qs}^e$ . (a) antes de atualizar  $T_r^*$ . (b) depois de atualizar  $T_r^*$ .






(a)




(b)

Figura 5.9 - Resposta do sistema ao degrau na referência de  $i_{qs}^e$ . (a) antes de atualizar  $T_r^*$ . (b) depois de atualizar  $T_r^*$ .



(a)



(b)

Figura 5.10 - Resposta do sistema ao degrau na referência de  $i_{qs}^e$ . (a) antes de atualizar  $T_r^*$ . (b) depois de atualizar  $T_r^*$ .

Das curvas experimentais obtidas podemos observar que logo após feita a atualização do valor de  $T_r^*$  a partir da saída da rede neural, a nova resposta apresenta uma característica quase linear, como discutido no capítulo 2. Um outro comentário adicional que diz respeito com a implementação do sistema de identificação, é o fato da atualização do valor de  $T_r^*$  a partir da saída da rede, apresentar problemas de precisão dado que no microcontrolador não é possível representar valores em ponto flutuante e sim valores inteiros. Dado isto, o valor de saída da rede é multiplicado no microcontrolador por um fator de escala, para produzir um valor inteiro e no final do processo de atualização dividido pelo mesmo fator, com a conseqüente perda de precisão associada. De qualquer forma, o valor obtido após a atualização serve como uma aproximação aceitável do valor real da constante de tempo do rotor.

## **CAPÍTULO 6**

### **CONCLUSÕES**

Neste trabalho foi feito um estudo e implementação do controle indireto mediante a orientação do fluxo do rotor para o motor de indução. O problema de sensibilidade aos parâmetros, deste método de controle, foi discutido e resultados de simulação referentes ao desempenho do sistema foram apresentados. Além disto foi proposto e implementado um sistema de identificação da constante de tempo elétrica do rotor, utilizando Redes Neurais Artificiais. Um estudo comparativo foi realizado a partir da resposta do sistema, quando foram utilizados na malha de velocidade dois reguladores: primeiramente um regulador PI convencional e depois um regulador fuzzy. A implementação digital do sistema descrito foi feita utilizando o microcontrolador de INTEL 87C196KD.

Algumas limitações foram encontradas na implementação do algoritmo de controle, sobretudo no tempo de processamento. A máxima frequência de chaveamento do inversor foi de 10 KHz, ou seja o algoritmo de controle do inversor é executado cada 100  $\mu s$ . Esta limitação na frequência de chaveamento do inversor está relacionada à demora no processo de conversão do conversor análogo - digital do microcontrolador, assim como ao tempo associado à entrada e saída das rotinas de interrupção. O algoritmo de controle, o qual gera as referências de corrente de estator, é executado a cada

1.2 ms, e este tempo é elevado quando comparado com uma implementação em hardware ou em um processador de maior capacidade. Por exemplo, a transformação do sistema de referência síncrono ao estacionário que consome na nossa implementação um tempo de 11  $\mu s$ , pode ser realizada em 3  $\mu s$  feita por um integrado dedicado. Fazendo algumas mudanças no "software", pode-se diminuir o tempo de execução do algoritmo de controle até 0.8 ms, com o custo de perda na transparência da estrutura do "software". Mesmo assim consideramos a implementação adequada, dentro dos limites de processamento do microcontrolador utilizado.

Em relação com o regulador fuzzy de velocidade implementado neste trabalho, os resultados experimentais apresentados no capítulo 5 mostram o melhor desempenho deste operando na malha de velocidade do controle, quando comparado com o regulador PI convencional para uma condição de acoplamento dada pela variação da resistência do rotor. A utilização do regulador fuzzy de velocidade levou a um tempo de resposta menor, quando o sistema foi submetido a uma referência variável. As características transitórias de velocidade para a condição de desacoplamento ideal no controle, também mostradas nos testes experimentais, foram satisfatórias com a utilização dos dois reguladores.

A utilização do "software" fuzzyTECH da INTEL acelerou em grande medida o processo de implementação do regulador, mas também algumas limitações deste precisam ser comentadas. Uma das principais limitações, da versão do "software" utilizado, está em que o número máximo de conjuntos fuzzy para cada variável, seja de entrada ou de saída, é igual a cinco. Isto de certa maneira impede aumentar a sensibilidade do regulador em determinadas faixas do universo de discurso das variáveis, além de limitar o máximo número de regras de inferência do sistema. Por outra parte em termos de tempo, o algoritmo fuzzy demora aproximadamente 0.28 ms no microcontrolador 87C196KD a 20 MHz, quando são utilizadas somente 20 regras; aumentando o tempo de execução do algoritmo de controle. Uma das principais vantagens do "software" é o fato de gerar um código C puro, o qual viabiliza a implementação em microprocessadores de maior potência, e este fato deve ser considerado em futuras implementações. Além disto de acordo com as especificações de tempo e memória de que precisa o sis-

tema, uma boa opção seria a utilização de integrados especiais dedicados ao cálculo de algoritmos fuzzy, como o controlador fuzzy de 12 bits SAE 81C991 da Siemens [46].

Uma análise que deve fazer parte de um trabalho futuro é a estudar no sistema implementado, o desempenho do regulador fuzzy de velocidade ante variações do conjugado de carga, sendo comparada para cada caso com o apresentado pelo regulador PI convencional.

No que se refere à implementação do sistema de identificação da constante de tempo elétrica do rotor utilizando Redes Neurais Artificiais ( RNA ), os resultados experimentais do capítulo 5 evidenciam o desempenho satisfatório da RNA utilizada no processo de identificação a partir dos dados temporais do transitório de velocidade, demonstrando a sua capacidade para realizar mapeamentos não lineares de entrada-saída. Uma proposta interessante e que deve ser parte de trabalhos futuros consiste em incorporar informação referente à carga no conjuntos de treinamento da rede, uma vez feito isto o sistema poderia ser capaz de inferir não só o valor da constante de tempo do rotor, mas também o conjugado de carga presente no sistema. A informação referente à carga, obtida na saída do sistema de identificação poderia então ser utilizada no ajuste dos ganhos do regulador empregado. Por outro lado em uma outra implementação deste sistema de identificação, justifica-se a utilização de microprocessadores de uma maior velocidade de processamento, dada a grande quantidade de cálculo computacional envolvido no uso das RNA, configurações para a operação em paralelo de mais de um destes processadores poderiam também ser testadas e avaliado a utilização de técnicas de treinamento "on-line".

As limitações encontradas na implementação utilizando o microcontrolador, referidas anteriormente, tal como o tempo de processamento e, a grande quantidade de cálculos computacionais envolvidos no uso das RNA, apontam no sentido de se utilizar microprocessadores de maior capacidade e velocidade de processamento. Os processadores digitais de sinais ( "DSP" ) apresentam-se como a alternativa mais natural na solução destes problemas de implementação.

## APÊNDICE A

### DADOS DO MOTOR DE INDUÇÃO

#### Condições nominais

Tensão nominal:  $V_{\text{nom}} = 220/380 \text{ V}$

Corrente nominal:  $I_{\text{nom}} = 9,1/5,3 \text{ A}$

Frequência nominal:  $F_{\text{nom}} = 60 \text{ Hz}$

Potência Nominal:  $PE_{\text{nom}} = 3 \text{ HP}$

Velocidade nominal:  $W_{\text{nom}} = 1760 \text{ rpm}$

#### Parâmetros

Número de pólos:  $P = 4$

Resistência de estator:  $R_s = 0.75 \Omega$

Resistência de rotor:  $R_r = 0.983 \Omega$

Indutância de magnetização:  $L_m = 0.10037 \text{ H}$

Indutância de dispersão de estator:  $L_{ls} = 0.00631 \text{ H}$

Indutância de dispersão de rotor:  $L_{lr} = 0.00631 \text{ H}$

## REFERÊNCIAS BIBLIOGRÁFICAS

- [1] LORENZ, R. D.; LIPO, T. A.; NOVOTNY, D. W., "Motion Control with Induction Motors", Proceedings of IEEE-IAS, vol. 82, no 8, pp. 1215-1240, August 1994.
- [2] PLUNKET, B. A., "Direct Flux and Torque regulation in a PWM Inverter Induction Motor Drive", IEEE Transactions on Industry Applications, vol. 13, no 2, pp. 139-146, March/April 1977.
- [3 ] LIPO, T. A., "Flux Sensing and Control of Static AC Drives by use of Flux Coils", IEEE Transactions on Magnetics, vol. 13, pp. 1403-1408, September 1977.
- [4 ] LIPO, T. A.; CHANG, K. C., "A New Approach to Flux and Torque Sensing in Induction Machines", IEEE Transactions on Industry Applications, vol. 22, pp. 731-737, July/August 1986.
- [5 ] MOREIRA, J.C., "Direct Field Orientation Control using the Third Harmonic Component of the Stator Voltage", IEEE Transactions on Industry Applications, vol. IA-13, no 2, pp. 139-146, March/April 1977.
- [6] XU, X.; NOVOTNY, D. W., "Implementation of Direct Stator Flux Orientation Control on a Versatile DSP Based System", IEEE Transactions on Industry Applications, vol. 27, no. 4, pp. 694-700, July/August 1991.
- [7] KRAUSE, P. C., *Analysis of Electric Machinery*, McGraw Hill, 1986.
- [8] KIRSHEN, D. S.; NOVOTNY, D. W.; LIPO, T. A., "On-Line Efficiency Optimization of a Variavel Frequency Induction Motor Drive", IEEE Transactions on Industry Applications, vol. IA-21, no. 4, pp. 610-616, May/June 1985.



- [9] KHATER, F. M. H.; LORENZ, R. D.; NOVOTNY, D. W., "Selection of Flux Level in Field Oriented Induction Machine Controllers with Consideration of Magnetic Saturation Effects", IEEE Transactions on Industry Applications, vol. 23, pp. 276-282, March/April 1987.
- [10] KRISHNAN, R.; DORAN, F. C., "Study of Parameter Sensitivity in High-Performance Inverter-Fed Induction Motor Drive Systems", IEEE Transactions on Industry Applications, vol. IA-23, no 4, pp. 623-635, July/August 1987.
- [11] NORDIN, K. B.; NOVOTNY, D. W.; ZINGER, D. S., "The Influence of Motor Parameter Deviations in Feedforward Field Orientation Drive Systems", IEEE Transactions on Industry Applications, vol. IA-21, no 4, pp. 1009-1015, July/August 1985.
- [12] KAO, Y.; LIU, C., "Analysis and Design of Microprocessor-Based Vector-Controlled Induction Motor Drives" IEEE Transactions on Industrial Electronics, vol. 39, no 41, pp. 46-54, February 1992.
- [13] OGATA, K., *Engenharia de Controle Moderno*, 2ª edição, Prentice Hall do Brasil, 1993.
- [14] BOSE, B. K., "Expert System, Fuzzy Logic, and Neural Network Applications in Power Electronics and Motion Control", Proceedings of IEEE-IAS, vol.82, no 8, pp. 1303-1323, August 1994.
- [15] ZADEH, L. A. "Fuzzy Sets", Informat. Control, vol. 8, pp. 338-353, 1965.
- [16] BELLON, C.; BOSCH, P.; PRADE, H., "Fuzzy Boom in Japan", International Journal of Intelligent Systems, vol. 7, pp. 293-316, 1992.
- [17] TIMOTHY, J. R., *Fuzzy Logic With Engineering Applications*, McGraw Hill, 1ª edição, May 1995.
- [18] ADCOCK, T. A., "What is Fuzzy Logic ?. An Overview of the Latest Control Methodology", *Implementation of Fuzzy Logic*, TEXAS INSTRUMENTS REPORT, pp. 1-7, 1993.

- [19] SOUSA, G. C. D.; BOSE, B. K., "A fuzzy set theory based control of a phase-controlled converter dc machine drive", IEEE Transactions on Industry Applications, vol. 30, pp. 34-44, Jan./Fev. 1994.
- [20] CHENG, F.; YEH, S., "Application of Fuzzy Logic in the Speed Control of AC Servo System and an Intelligent Inverter", IEEE Transactions on Energy Conversion, vol.8, no2, pp. 312-318, June 1993.
- [21] LIAW, C. M.; WANG, J. B.; CHANG, Y. C., "A Fuzzy Adapted Field-Oriented Mechanism for Induction Motor Drive", IEEE Transactions on Energy Conversion, vol.11, no1, pp. 76-83, March 1996.
- [22] MIKI, I.; NAGAI, N.; NISHIYAMA, S.; YAMADA, T., "Vector Control of Induction Motor with Fuzzy PI Controller", IEEE Transactions on Energy Conversion, vol.11, no1, pp. 341-346, March 1991.
- [23] KIRSHEN, D. S.; NOVOTNY, D. W.; LIPO, T. A., "Optimal Efficiency Control of an Induction Motor Drive", IEEE Transactions on Energy Conversion, vol. 2, no 1, pp. 70-76, March 1987.
- [24] SOUSA, G. C. D.; BOSE, B. K.; CLELAND, G. J., "Fuzzy Logic Based On-Line Efficiency Optimization Control of an Indirect Vector-Controlled Induction Motor Drive", IEEE Transactions on Industry Applications, vol. 21, no 4, pp. 610-616, May/June 1995.
- [25] SIMÕES, M. G., "Application of Fuzzy Logic in the Estimation of Power Electronic Waveforms", Industry Applications Society Annual Meeting ( IEEE/IAS ), vol. II, pp. 853-861, Toronto ( Canadá ), October 1993.
- [26] TEXAS INSTRUMENTS REPORT, *Enhanced Control of an Alternating Current Motor Using Fuzzy Logic and a TMS320 Digital Signal Processor*, 1996.
- [27] MINSKY, M. L.; PAPERT, S. A., *Perceptrons*, Expanded Edition, Cambridge, MA: MIT Press, 1988.

- [28] RUMELHART, D. E.; McCLELLAND; eds., *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, vol. 1, Cambridge, MA: MIT Press, 1986.
- [29] KOHONEN, T., *Self - Organization and Associative Memory*, 3<sup>a</sup> ed., New York, Springer - Verlag, 1988.
- [30] HOPFIELD, J. J., "Neural Networks and physical systems with emergent collective computational abilities", *Proceedings of the National Academy of Sciences of the U.S.A.*, vol. 79, pp. 2554 - 2558, 1982.
- [31] HAYKIN, S., *Neural Networks, A Comprehensive Foundation*, 1<sup>a</sup> ed., Macmillan Publishing Company, 1994.
- [32] NARENDRA, K. S., "Identification and Control of Dynamical Systems Using Neural Networks", *IEEE Transactions on Neural Networks*, vol. 1, no 1, pp. 4-27, March 1990.
- [33] ZUBEN, F. J. V.; NETTO, M. L. A.; BIM, E.; SZAJNER, J., "Adaptive Vector Control of a Three-Phase Induction Motor Using Neural Networks", *International Conference on Neural Networks*, Orlando, Florida, USA, pp. 3750-3755, June 1994.
- [34] FODOR, D.; GRIVA, G.; PROFUMO, F., "Compensation of Parameters Variations in INduction Motor Drives using a Neural Network", 0-7823-2730-6/95 -IEEE, pp. 1307-1311, 1995.
- [35] HUANG, S.; HUANG, C.; LIN, Y., "Harmonic and Speed Control Aspects of Neural Network Based Vector-Controlled Induction Drives", *IEE of Japan Power & Energy '96*, pp. 297-302, 1996.
- [36] BUHL, M. R.; LORENZ, R. D., "Design and Implementation of Neural Networks for Digital Current Regulation of Inverter Drives", *IEEE / IAS Annu. Meet. Conf. Rec.*, pp. 415-423, 1991.

- [37] WISHART, M. T.; HARLEY, R. G., "Identification and Control of Induction Machines Using Artificial Neural Networks", IEEE Transactions on Industry Applications, vol. 31, no 3, pp. 612-619, May/June 1995.
- [38] TORRICO, J. A., "Implementação do Método Direto do Controle Vetorial de um Motor de Indução com Orientação de Fluxo do Estator utilizando DSP", Tese de Mestrado, FEEC/UNICAMP, Fevereiro 1997.
- [39] GARCÉS, L. J.; "Parameter Adaptation for the Speed-Controlled Static AC Drive with a Squirrel-Cage Induction Motor", IEEE Transactions on Industry Applications, vol. IA - 16, no 2, pp. 173-178, March/April 1980.
- [40] KOYAMA, M.; YANO, M.; KAMIYAMA, I.; YANO, S., "Microprocessor-Based Vector Control System for Induction Motor Drives with Rotor Time Constant Identification Function", IEEE Transactions on Industry Applications, vol. IA-22, no 3, pp. 453-459, May/June 1986.
- [41] WANG, C.; NOVOTNY, D. W.; LIPO, T. A., "An Automated Rotor Time Constant Measurement System for Indirect Field-Oriented Drives", IEEE Transactions on Industry Applications, vol. 24, no 1, pp. 151-159, January/February 1988.
- [42] SUL, S. K., "A Novel Technique of Rotor Resistance Estimation Considering Variation of Mutual Inductance", IEEE Transactions on Industry Applications, vol. 25, no 3, pp. 578-587, July/August 1989.
- [43] CHAN, C. C.; WANG, H., "A Effective Method for Rotor Resistance Identification for High-Performance Induction Motor Vector Control", IEEE Transactions on Industrial Electronics, vol. 37, no 6, pp. 477-482, December 1990.
- [44] LORENZ, R. D., "Tuning of Field-Oriented Induction Motor Controllers for High-Performance Applications", IEEE Transactions on Industry Applications, vol. IA-22, no 2, pp.293-297, March/April 1986.
- [45] INFORM SOFTWARE CORPORATION, *fuzzyTECH 3.1, MCU-96 Explorer*, 1993.

- [46] EICHFELD, H.; KUNEMUND, T.; MENKE, M., "A 12b General-Purpose Fuzzy Logic Controller Chip", IEEE Transactions on Fuzzy Systems, vol. 4, no 4, pp. 460-475, November 1996.
- [47] SIMÕES, M. G.; BOSE, B. K., "Neural Network Based Estimation of Feedback Signals for a Vector Controlled Induction Motor Drive", IEEE Transactions on Industry Applications, vol. 31, no 3, pp. 620-629, May/June 1995.
- [48] MILLER, W. T.; SUTTON, R. S.; WERBOS, P. J.; ( Eds ), *Neural Networks for Control*, MIT Press, 1995.
- [49] HUNT, K. J.; IRWIN, G. R.; WARWICK, K.; ( Eds ), *Neural Network Engineering in Dynamic Control Systems*, Springer-Verlag, 1995.
- [50] LIPPMANN, R. P., "An Introduction to Computing with Neural Nets", IEEE ASSP Magazine 4, pp. 4-22, 1987.
- [51] HUSH, D. R.; HORNE, B. G., "Progress in supervised neural networks: What's new since Lippmann?", IEEE Signal Processing Magazine 10, pp. 8-39, 1993.
- [52] INTEL CORPORATION, *16-Bit Embedded Controller Handbook*, 1991.
- [53] KHAMBADKONE, A. M.; HOLTZ, J., "Vector-Controlled Induction Motor Drive with a Self-Commissioning Scheme", IEEE Transactions on Industrial Electronics, vol. 38, no 3, pp. 322-327, October 1991.
- [54] HUGHES, A.; CORDA, J.; ANDRADE, D. A., "Vector control of cage induction motors: a physical insight", IEE Proc.-Electr. Power Appl., vol. 143, no 1, January 1996.
- [55] CHAN, C. C.; LEUNG, W. S.; NG, C. W., "Adaptive Decoupling Control of Induction Motor Drives", IEEE Transactions on Industrial Electronics, vol. 37, no 1, pp. 41-47, February 1990.
- [56] HO, E. Y. Y.; SEN, P. C., "Decoupling Control of Induction Motor Drives", IEEE Transactions on Industrial Electronics, vol. 35, no 2, pp. 253-262, May 1988.

- 
- [57] PAN, C.; CHANG, T., "A Microcomputer Based Vector Controlled Induction Motor Drive", IEEE Transactions on Energy Conversion, vol. 8, no 4, pp. 750-755, December 1993.
- [58] TZOU, Y., "DSP-Based Robust Control of an AC Induction Servo Drive for Motion Control", IEEE Transactions on Control Systems Technology, vol. 4, no 6, pp. 614-626, November 1996.
- [59] DOYLE, J. C.; GLOVER, K.; KHARGONEKAR, P. P.; FRANCIS, B. A., "State-Space Solutions to Standard  $H_2$  and  $H_\infty$  Control Problems", IEEE Transactions on Automatic Control, vol. 34, no 8, pp. 831-846, August 1989.
- [60] HO, E. Y. Y.; SEN, P. C., "Control Dynamics of Speed Drive Systems Using Sliding Mode Controllers with Integral Compensation", IEEE Transactions on Industry Applications, vol. 27, no 5, pp. 883-892, September/October 1991.