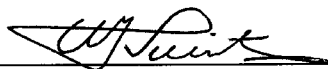


IMPLEMENTAÇÃO DE ESTRATÉGIA DE MINIMIZAÇÃO DE OSCILAÇÕES DE
TORQUE E REMOÇÃO DE SENSOR DE POSIÇÃO PARA UM ACIONAMENTO
DE RELUTÂNCIA VARIÁVEL USANDO TÉCNICA NEURO-FUZZY

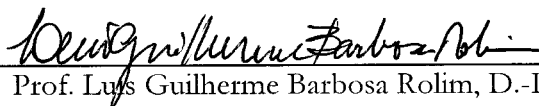
Luís Oscar de Araújo Porto Henriques

TESE SUBMETIDA AO CORPO DOCENTE DA COORDENAÇÃO DOS
PROGRAMAS DE PÓS-GRADUAÇÃO DE ENGENHARIA DA
UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS
REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR
EM CIÊNCIAS EM ENGENHARIA ELÉTRICA.

Aprovada por:



Prof. Walter Isamu Suemitsu, D.Ing.



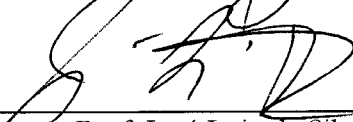
Prof. Luis Guilherme Barbosa Rolim, D.-Ing.



Prof. Paulo José da Costa Branco, D.Sc.



Prof. Antônio Marcus Nogueira Lima, Dr.



Prof. José Luiz da Silva Neto, Ph.D.

RIO DE JANEIRO, RJ – BRASIL

AGOSTO DE 2004

HENRIQUES, LUÍS OSCAR DE ARAÚJO
PORTO

Implementação de Estratégia de Minimização
de Oscilações de Torque e Remoção de Sensor de
Posição para um Acionamento de Relutância
Variável usando Técnica Neuro-fuzzy [Rio de
Janeiro] 2004

XVI, 156 p. 29,7 cm (COPPE/UFRJ, D.Sc.,
Engenharia Elétrica, 2004)

Tese – Universidade Federal do Rio de Janeiro,
COPPE

1. Controle de Máquinas Elétricas
2. Lógica *Fuzzy*
3. Motor de Relutância Variável
4. Eliminação de Sensor de Posição
5. Redes Neurais

I. COPPE/UFRJ II. Título (série)

"A batalha da vida é, na maioria das vezes, montanha acima, e vencê-la sem luta é talvez vencer sem honra. Se não houver dificuldades, não haverá sucesso; e se não houver nada para se lutar não haverá nada para ser conquistado"

Samuel Smiles

Dedico este trabalho a meus pais Flávio e
Maria Carolina

Agradecimentos

O caminho que levou a esta tese começou há algum tempo quando iniciei a minha participação em um projeto de iniciação científica na Universidade Federal de Juiz de Fora. Foi através dela que tomei conhecimento do processo científico e de sua metodologia. Devo aos professores Carmelita Elias Vidigal e Márcio de Pinho Vinagre um agradecimento especial. Foram eles que me ajudaram a dar meus primeiros passos neste universo tão especial do desenvolvimento tecnológico e da pesquisa.

A busca por um terreno mais fértil para meu crescimento profissional fez-me deslocar para a Universidade Federal do Rio de Janeiro. Desde o primeiro momento, fui acolhido de braços abertos pelos professores e funcionários do Programa de Engenharia Elétrica, especialmente pelos professores Edson Hirokazu Watanabe, Richard M. Stephan e Walter I. Suemitsu.

Devo expressar minha perene gratidão ao amigo Paulo Roberto V. Guimarães, que nestes 7 anos de convivência, nunca deixou de me incentivar e estimular a ser muito mais do que um engenheiro com pós graduação e sim um profissional com visões amplas, capaz de solucionar problemas práticos sem deixar de ser acadêmico.

Ao mestre e orientador Walter Issamu Suemitsu, presto meu agradecimento por acreditar desde o início de meu mestrado em minhas potencialidades. O reconhecimento pela sua capacidade de conduzir com sobriedade e serenidade seu papel de orientador, sempre aconselhando e guiando meus passos, muitas vezes frouxos por caminhos inúmeras vezes desconhecidos por mim.

Sou eternamente grato ao Prof. Luís Guilherme B. Rolim, que sempre se colocou em total disposição para me ajudar nos momentos onde meu conhecimento foi insuficiente para transpor naturais dificuldades da investigação científica. Sua jovialidade esconde uma ampla capacidade de trabalho e de reter conhecimento. Devo a ele, inúmeros “puxões de orelha” que me estimularam a vencer minhas fragilidades.

Tive a felicidade de ter, durante todo o doutorado, o prof. Paulo J. Costa Branco como orientador e especialmente como um verdadeiro tutor, conselheiro e em diversos momentos, um colega de trabalho, durante o período que estive cursando meu doutorado sanduíche em Lisboa. Com um inabalável foco de qualidade científica, Paulo estava sempre

lá para me levar de volta ao caminho certo sempre que, nos momentos de desacerto e fraqueza, eu me desviava, sem nunca deixar de ser um centro inesgotável de encorajamento. Seja lá quais forem os frutos deste trabalho, seus resultados são infinitamente melhores do que seriam sem a intuição aguçada, o conhecimento e o julgamento de Paulo, e sem a confiança, o respeito e a amizade que se formaram entre nós.

Agradecimento especial deve ser prestado a todos os colegas e amigos que ganhei na UFRJ cada um dentro de um período de tempo, por seus comentários abertos, honestos e ricos em idéias e críticas: Marcelo Guimarães Rodrigues, Antonio Carlos Siqueira de Lima, João Luiz S. Macacchero, José Andrés Santisteban Larrea, Luciano Souza, Carlos André Carreiro Cavaliere, Fábio Domingues de Jesus, Guilherme Sotelo, Daniel Galiano de Meneses Pimentel, Diogo Rodrigues da Costa Junior, Carlos Fernando Teodósio Soares, João Amin Moor Neto e muitos outros.

Devo agradecer aos meus colegas de trabalho do Centro Federal de Ensino Tecnológico Celso Suckow da Fonseca (CEFET-RJ) que neste último ano de doutorado me apoiaram no término da tese, compreendendo a minha ausência em alguns momentos.

Outra pessoa inestimável é Regiane F. de Oliveira, sua companhia na reta final deste trabalho tem um peso inquestionável. Desde o início de nossa amizade, nunca deixou de me incentivar e me apoiar na empreitada que seria viver sozinho por um ano longe de minha família e de meus amigos. Esta amizade sincera cresceu a ponto de não quisermos mais estar longe um do outro. Desde meu retorno ao Brasil, ela tem sido uma grande conselheira e companheira demonstrando muita coragem em enfrentar junto comigo, dia após dia, as dificuldades naturais da finalização de uma tese de doutorado.

Agradeço a meus parentes, pelo entusiasmo com que acompanharam este trabalho, mesmo não tendo conhecimento amplo do que se tratava.

Agradeço a meus irmãos, Leonardo e Flaviane, pelo estímulo constante e incessante e pelo orgulho de meu êxito.

Agradeço aos meus amigos, Júlio César R. Ferraz, Zulmar S. Machado Júnior, Ricardo Mota Henriques e José de Alencar Silva Júnior que dividiram comigo alegrias e tristezas.

Agradeço a CAPES, ao CNPq e ao GRICES/Portugal (Gabinete de Relações Internacionais da Ciência e do Ensino Superior) pelo apoio financeiro dado durante o doutorado na UFRJ e no doutorado sanduíche no IST/UTL de Portugal.

E finalmente, o mais importante, agradeço a Deus pelas oportunidades colocadas em minha vida, permitindo meu êxito profissional e pela proteção dada a mim a cada minuto de minha vida.

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D.Sc.)

IMPLEMENTAÇÃO DE ESTRATÉGIA DE MINIMIZAÇÃO DE OSCILAÇÃO DE TORQUE USANDO CONTROLE *NEURO-FUZZY* E REMOÇÃO DE SENSOR DE POSIÇÃO PARA UM ACIONAMENTO DE RELUTÂNCIA CHAVEADO

Luís Oscar de Araújo Porto Henriques

Agosto/ 2004

Orientadores: Walter Issamu Suemitsu, Dr. Ing.
Luís Guilherme Barbosa Rolim, D.-Ing.
Paulo José da Costa Branco, D.Sc.

Programa: Engenharia Elétrica

Motores de relutância variável possuem grandes vantagens na sua aplicação, porém há duas desvantagens que prejudicam o seu amplo uso no mercado de acionamentos elétricos: torque eletromagnético oscilante e a necessidade do uso de um sensor de posição conectado ao seu eixo. Inúmeras técnicas têm sido propostas para solucionar estes dois problemas. Esta tese contribui na análise e solução destes problemas através da proposta de duas novas abordagens onde se tratou de usar técnicas de controle com aprendizagem (redes neurais e lógica *fuzzy*) objetivando-se: a redução automática das oscilações de torque no eixo do motor de relutância variável e a eliminação do sensor de posição deste mesmo motor através de um observador *Neuro-fuzzy*. De acordo com esta modelagem, um sistema de acionamento elétrico composto por conversor, motor de relutância variável e carga foi idealizado, projetado, simulado, executado experimentalmente e validado. Os resultados apresentados comprovam o sucesso das técnicas propostas e implementadas.

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

IMPLEMENTATION OF A TORQUE OSCILLATION STRATEGY
MINIMIZATION USING NEURO-FUZZY CONTROL AND ELIMINATION OF A
POSITION SENSOR FOR A SWITCHED RELUCTANCE MOTOR

Luís Oscar de Araújo Porto Henriques

August/ 2004

Advisors: Walter Issamu Suemitsu, Dr. Ing.
Luís Guilherme Barbosa Rolim, D.-Ing.
Paulo José da Costa Branco, D.Sc.

Department: Electrical Engineering

Switched reluctance motors have great advantages in some applications, however it has two disadvantages that they harm its ample use in the electrical drives market: electromagnetic torque ripple and the necessity to use a position sensor hardwired to the axis. Innumerable techniques have been proposed to solve these two problems. This thesis contributes in its analysis and solution of these problems through the proposal of two new approaches that employ techniques of control with learning (neural nets and fuzzy logic) objectifying: the automatic ripple torque reduction and the elimination of the position sensor in the same motor through a neuro-fuzzy observer. In accordance with this model, a system composed by a power electronics converter, a switched reluctance motor, and a load was idealized, projected, simulated, executed experimentally and validated. The presented results prove the success of the proposed and implemented techniques.

Índice Geral

CAPÍTULO 1 INTRODUÇÃO	1
1.1 MOTIVAÇÃO.....	1
1.2 OBJETIVOS.....	3
1.3 DEFINIÇÃO E DELIMITAÇÃO DO OBJETO DE TRABALHO	4
1.4 CONTRIBUIÇÕES ORIGINAIS.....	5
1.5 ESTRUTURA DA TESE	5
CAPÍTULO 2 MÁQUINA DE RELUTÂNCIA VARIÁVEL (MRV): CARACTERÍSTICAS FUNDAMENTAIS	8
2.1 INTRODUÇÃO.....	8
2.2 ESTRUTURA BÁSICA	9
2.3 CARACTERÍSTICAS ELETROMECÂNICAS DA MRV	13
2.4 EFEITOS DA NÃO-LINEARIDADE MAGNÉTICA	18
2.5 OPERAÇÃO DINÂMICA	20
2.5.1 Operação a pulso único	21
2.5.2 Operação através de <i>PWM</i> de tensão	22
2.5.3 Operação através de regulação de corrente.....	24
2.6 CONVERSORES	25
2.7 CONSIDERAÇÕES FINAIS.....	30
CAPÍTULO 3 REVISÃO DAS ESTRATÉGIAS DE REDUÇÃO DE OSCILAÇÕES DE TORQUE DA MRV	31
3.1 INTRODUÇÃO.....	31
3.2 USO DE TABELAS CARACTERÍSTICAS.....	33
3.3 USO DE MODELOS MATEMÁTICOS.....	36
3.4 CONTROLE ADAPTATIVO <i>ONLINE</i>	38
3.4.1 Controle Clássico.....	38
3.4.2 Redes Neurais.....	41
3.4.3 Lógica <i>Fuzzy</i>	43
3.4.4 Outras técnicas.....	45
3.5 CONSIDERAÇÕES FINAIS.....	45
CAPÍTULO 4 REVISÃO DAS ESTRATÉGIAS DE ELIMINAÇÃO DE SENSOR DE POSIÇÃO	47
4.1 CONSIDERAÇÕES INICIAIS	47
4.2 REGIÃO 1 – VELOCIDADES PRÓXIMAS A ZERO	50
4.3 REGIÃO 2 - VELOCIDADES MUITO BAIXAS	51
4.4 REGIÃO 3 - BAIXAS VELOCIDADES (REGIÃO DE TORQUE CONSTANTE).....	54
4.5 REGIÃO 4 - ALTAS VELOCIDADES.....	56
4.6 REGIÃO 5 - ULTRA-ALTAS VELOCIDADES.....	57
4.7 CONSIDERAÇÕES FINAIS.....	58
CAPÍTULO 5 CONTROLE COM COMPENSAÇÃO AUTOMÁTICA DAS OSCILAÇÕES DE TORQUE DA MRV	59
5.1 CONSIDERAÇÕES INICIAIS	59
5.2 CONTROLADOR DE VELOCIDADE PI	61
5.3 COMPENSADOR <i>NEURO-FUZZY</i>	62
5.4 TREINAMENTO E OPERAÇÃO.....	64
5.4.1 Introdução	64
5.4.2 Modelização por aprendizagem supervisionada.....	64
5.5 RESULTADOS.....	72
5.5.1 Método com sinal de torque	72
5.5.2 Método sem sensor de torque.....	76
5.5.3 Considerações sobre a metodologia.....	77
5.6 OPERAÇÃO DA MRV COM COMPENSAÇÃO <i>NEURO-FUZZY</i> DE CORRENTE SOB CONDIÇÃO DE INTERRUPÇÃO EM UMA DAS FASES DA MÁQUINA.	82
5.6.1 Resultados obtidos e casos estudados.....	83
5.6.2 Resultados.....	84
a) Sem carga, com 3 fases e com treino.	84
b) Sem carga, com 2 fases e com treino.....	85
c) Sem carga, com 3 fases e sem treino.	86
d) Sem carga, com 2 fases e sem treino.....	87

e) Com carga, com 2 fases e sem treino.....	89
f) Com carga, com 3 fases e sem treino.....	90
g) Com carga, com 3 fases e com treino.....	90
h) Com carga, com 2 fases e com treino.....	91
5.7 CONCLUSÕES.....	93
CAPÍTULO 6 DESENVOLVIMENTO DE TÉCNICA DE ELIMINAÇÃO DE SENSOR DE POSIÇÃO ANGULAR DO ROTOR E VERIFICAÇÃO EXPERIMENTAL DO MODELO EM MÁQUINAS DE RELUTÂNCIA VARIÁVEL.....	95
6.1 CONSIDERAÇÕES INICIAIS.....	95
6.2 TREINAMENTO E OPERAÇÃO.....	95
6.3 RESULTADOS DE SIMULAÇÃO DE TREINO <i>OFFLINE</i>	103
6.4 RESULTADOS EXPERIMENTAIS DE TREINO <i>OFFLINE</i>	104
6.5 TREINAMENTO E APRENDIZAGEM <i>ONLINE</i>	110
6.6 RESULTADOS EXPERIMENTAIS COM TREINAMENTO <i>ONLINE</i>	110
6.7 CONSIDERAÇÕES FINAIS.....	118
CAPÍTULO 7 CONCLUSÕES E PROPOSTAS DE TRABALHOS FUTUROS.....	120
7.1 CONCLUSÕES.....	120
7.2 PROPOSTAS DE TRABALHOS FUTUROS.....	123
CAPÍTULO 8 BIBLIOGRAFIA.....	124
APÊNDICE A SISTEMA EXPERIMENTAL.....	131
A.1 CONSIDERAÇÕES GERAIS.....	131
A.2 DESCRIÇÃO DETALHADA DO SISTEMA DE ACIONAMENTO.....	131
A.2.1 Conversor.....	132
A.2.2 Proteção de sobrecorrente e controle de corrente de histerese.....	133
A.2.3 Sensor de posição.....	134
A.2.4 Placa de aquisição de dados.....	135
APÊNDICE B LÓGICA FUZZY E REDES NEURAIS.....	136
B.1 CONSIDERAÇÕES GERAIS.....	136
B.2 LÓGICA FUZZY.....	136
B.2.1 Considerações Iniciais.....	136
B.2.2 Sistema Lógico <i>Fuzzy</i>	137
B.2.3 Números <i>fuzzy</i> e <i>crisp</i>	137
B.2.4 Conjunto <i>fuzzy</i>	138
B.2.5 Função de Pertinência.....	139
B.2.6 Operações com conjuntos <i>fuzzy</i>	140
B.2.7 Variáveis lingüísticas <i>fuzzy</i>	141
B.2.8 Lógica <i>Fuzzy</i>	142
B.2.9 Inferência <i>fuzzy</i>	143
B.2.10 Defuzzificador.....	144
B.3 REDES NEURAIS.....	145
APÊNDICE C DEMONSTRAÇÃO DA CONFIABILIDADE DO ALGORITMO DE BUSCA DO VALOR DE TORQUE.....	150
C.1 INTRODUÇÃO.....	150
C.2 ALGORITMO DE BUSCA DO VALOR DE TORQUE.....	150
C.2.1 Resultados de simulação.....	152
C.2.2 Resultados Experimentais.....	152
C.3 CONSIDERAÇÕES FINAIS.....	154
APÊNDICE D PUBLICAÇÕES CIENTÍFICAS DO AUTOR.....	155

Glossário

ANFIS (*Adaptive Neuro-fuzzy Inference System*): Técnica para ajuste automático de sistemas de inferência tipo-Sugeno, baseado em dados de treinamento.

Base de regras *fuzzy*: Conjunto de regras que definem o algoritmo de controle *fuzzy*.

Bias: Refere-se a um valor numérico constante que é uma das entradas do neurônio.

Conjunto *fuzzy* (ou subconjunto *fuzzy*): conjunto cujos elementos possuem graus de pertinência variando entre 0 (não membro) e 1 (membro). É geralmente caracterizado por uma função matemática, associada a termos lingüísticos, como por exemplo: PEQUENO, MÉDIO, LONGE, FRIO, etc.

Controle *fuzzy*: Processo de controle baseado na lógica *fuzzy* e que é geralmente caracterizado por regras do tipo “SE-ENTÃO”.

Época: Apresentação de um conjunto de dados de treinamento para a rede e conseqüente cálculo dos novos pesos e bias. Em uma época pode-se apresentar o conjunto todo ou um elemento de cada vez para o treinamento.

Função de pertinência: Função que define o subconjunto *fuzzy*, através da associação de cada elemento no conjunto com um numérico entre 0 e 1.

Grau de pertinência (μ): número entre 0 e 1 que expressa o quanto um determinado elemento pertence ao conjunto *fuzzy*.

Lógica crisp: lógica booleana clássica. Possui somente dois valores: 0 e 1.

Lógica *fuzzy*: Lógica que admite infinitos níveis lógicos (entre 0 e 1), utilizada em situações que apresentam incertezas.

Modelo *fuzzy*: Regras *fuzzy* e funções de pertinência que descrevem o modelo de um determinado sistema.

Rede neural: Rede computacional que representa matematicamente o sistema de neurônios do cérebro humano.

Regra $fuzzy$: As regras SE-ENTÃO relacionam as variáveis $fuzzy$ de entrada (condições) com as variáveis $fuzzy$ de saída (ações).

Sistema de inferência $fuzzy$: Nome dado a um sistema que utiliza a teoria da lógica $fuzzy$ para mapear um espaço de entrada em um espaço de saída.

Sistema de Inferência SUGENO: Tipo de inferência $fuzzy$ onde o conseqüente de cada regra é uma combinação linear das entradas.

Universo de discurso: Faixa de valores associados à variável $fuzzy$.

Simbologia e Abreviaturas

\tilde{T}	Torque oscilante	
γ	Taxa de aprendizagem	
θ	ângulo	$[\theta]=\text{graus}$
θ_i	Ângulo genérico i	$[\theta_i]=\text{graus}$
θ_{off}	Ângulo de desenergização da corrente	$[\theta_{\text{off}}]=\text{graus}$
θ_{on}	Ângulo de energização da corrente	$[\theta_{\text{on}}]=\text{graus}$
λ	Enlace de fluxo	$[\lambda]=\text{Wb}$
λ_{fase}	Enlace de fluxo em uma fase	$[\lambda_{\text{fase}}]=\text{Wb}$
λ_s	Enlace de fluxo de saturação do motor	$[\lambda_s]=\text{Wb}$
Δt	Tempo de amostragem	$[\Delta t_s]=\text{s}$
$\Delta\omega_{\text{ref}}$	Variação da velocidade de referência	
$\mu_A(x)$	Função de pertinência de x em um conjunto A	
$\mu_j(\theta)$	Função de pertinência do j -ésimo conj. <i>fuzzy</i> da variável de entrada θ	
$\varphi_i(\cdot)$	Função de ativação não linear do neurônio i	
$\phi_j(\theta)$	Função de ativação normalizada de cada regra	
η	Taxa de aprendizagem	
ΔI_{ref}	Variação da corrente de referência	
Δi	Valor adicional de corrente	$[\Delta i]=\text{A}$
$\Delta\tilde{T}_{el}$	Valor médio do torque oscilante	$[\Delta\tilde{T}_{el}]=\text{N.m}$
ΔS_{ref}	Variação do sinal de referência	
a_i^j	Valor máximo da função gaussiana,	
A	Conjunto	
ANFIS	“ <i>Adaptive Neuro-fuzzy Inference System</i> ”	
ART	“ <i>Adaptive Resonance Theory</i> ”	
b_i^j	Centro da função gaussiana	
B	Densidade de Campo magnético	$[B]=\text{T}$
c_n	Valor de torque na tabela característica	$[c_n]=\text{N.m}$
c_i^j	abertura da função gaussiana	
C	Capacitância	$[C]=\text{F}$
CA	Corrente Alternada	
CC	Corrente Contínua	

$\epsilon\omega$	Variação do erro de velocidade	
DSP	“ <i>Digital Signal Processor</i> ”	
$\epsilon\omega$	Erro de velocidade	$[\epsilon\omega]=\text{rpm}$
$f_i(\theta)$	Função de contorno $i, i=1,2,\dots,n$	
FEM	Força eletromotriz	
FM	Frequência modulada	
GMDH	“ <i>Group Method of Data Handling</i> ”	
hp	“ <i>horse power</i> ”	
i	Corrente instantânea	$[i]=A$
i_i	Corrente genérica i	$[i_i]=A$
i_{ref}	Corrente de referência	$[i_{ref}]=A$
i_{fase}	Corrente em uma fase	$[i_{fase}]=A$
i_{sens}	Corrente de sensoriamento	$[i_{sens}]=A$
$i_{desejada}$	Corrente desejada	$[i_{desejada}]=A$
I_{pi}	Corrente produzida pelo PI	$[i_{pi}]=A$
IGBT	“ <i>Insulated Gate Bipolar Transistor</i> ”	
J	Momento de Inércia	$[J]=\text{Kg.m}$
K_i	Ganho da parcela integral	
K_p	Ganho da parcela proporcional	
L	Indutância	$[L]=H$
$L_{m\acute{a}x}$	Indutância máxima	$[L_{m\acute{a}x}]=H$
$L_{m\acute{i}n}$	Indutância mínima	$[L_{m\acute{i}n}]=H$
LQV	“ <i>Learning Vector Quantisation</i> ”	
MRV	Motor de relutância variável	
N	Tempo de simulação	$[N]=s$
n	Número de fases do motor	
PI	Proporcional-Integral	
PWM	“ <i>Pulse Width Modulation</i> ”	
RBF	“ <i>Radial Basis Function</i> ”	
R	Resistência	$[R]=\Omega$
RMS	“ <i>Root Mean Square</i> ”	
SLNF	Sistema lógico <i>Neuro-fuzzy</i>	
SLF	Sistema lógico <i>fuzzy</i>	
S_{ref}	Sinal de referência	
S_c	Sinal do compensador	$[S_c]=A$
S_{pi}	Sinal do PI	$[S_{pi}]=A$
T	Torque	$[T]=\text{N.m}$

t	Tempo	$[t]=s$
T^*	Torque de referência	$[T]=N.m$
T_c	Torque de carga	$[T_c]=N.m$
T_e	Torque elétrico	$[T_e]=N.m$
T_{est}	Torque estimado	$[T_{est}]=N.m$
T_j	Torque em uma fase j	$[T_{fase}]=N.m$
T_{inst}	Torque instantâneo total	$[T_{inst}]=N.m$
t_d	Tempo de desenergização	$[t_d]=s$
u_k	Variável interna de uma rede neural	
v	Tensão	$[v]=V$
v_i	Tensão na fase i	$[v_i]=V$
VA	Volt Ampere	
V_{filt}	Tensão filtrada	$[V_{filt}]=V$
V_{fases}	Tensão nas fases	$[V_{fases}]=V$
V_s	Tensão na saída do retificador	$[V_s]=V$
y_k	Saída de um neurônio k	
ω	Velocidade	$[\omega]=rpm$
ω_i	Velocidade genérica	$[\omega_i]=rpm$
w_j	j-ésimo singleton fuzzy de saída	
W'	Co-energia	$[W']=J$
ω_{ref}	Velocidade de referência	$[\omega_{ref}]=rpm$
W	Watt	

Capítulo 1

Introdução

1.1 Motivação

As máquinas elétricas são amplamente utilizadas nas mais variadas atividades, incluindo aplicações residenciais, comerciais e industriais. Embora as primeiras aplicações fossem restritas ao seu funcionamento em velocidade constante, hoje a tecnologia existente permite um controle preciso de velocidade, tanto de máquinas de corrente contínua (CC), como de corrente alternada (CA), sendo amplamente reconhecido que o controle de velocidade propicia uma maior flexibilidade de operação, um uso mais eficiente da energia elétrica e também uma melhoria no transitório de partida destas máquinas.

Embora as máquinas de indução sejam largamente utilizadas na indústria e dificilmente possam ser substituídas em aplicações gerais, a busca por máquinas ainda mais eficientes e principalmente mais robustas tem motivado pesquisas de novas máquinas, acionamentos e sistemas de controle.

Dentre os acionamentos pesquisados recentemente, o de relutância chaveado tem recebido bastante atenção[1], [2], devido às suas potenciais vantagens dadas pela simplicidade de construção, alta confiabilidade, baixo custo de fabricação e de manutenção, além de perdas relativamente baixas no rotor. Tal acionamento é constituído por uma máquina de relutância variável, um conversor eletrônico, e um sistema de controle que necessita do sinal de posição do rotor, possibilitando um comando de velocidade ou posição mais eficiente.

Um dos grandes problemas do acionamento de relutância chaveado, e que tem impedido a sua utilização em grande escala, é a presença de oscilações de torque devido tanto à sua forma construtiva quanto à sua característica eletromagnética não linear; torque este dependente da corrente e do ângulo do rotor. Em certas aplicações industriais, como o acionamento de veículos utilizados em fábricas ou em sistemas de transporte de matéria-prima em mineradoras, as oscilações de torque não representam problema algum sendo filtradas pela inércia elevada, geralmente acoplada ao rotor da máquina. No entanto, se a aplicação exige elevado desempenho em termos de controle de posição, como é o caso do

acionamento de braços de robô, ou uma variação precisa de velocidade, como em máquinas ferramenta [3], oscilações significativas no torque não podem ser toleradas e o controle instantâneo do conjugado com objetivo de redução das suas oscilações torna-se essencial. Para resolver este problema, várias estratégias de controle têm sido propostas [4], [5]. Um dos obstáculos para se obter uma estratégia eficiente de controle instantâneo do torque deve-se, principalmente, à dificuldade de modelar adequadamente a máquina de relutância variável, devido à sua não-linearidade magnética intrínseca. Esta característica tem conduzido à pesquisa de métodos de controle utilizando técnicas que não necessitam de um modelo preciso do sistema a ser controlado, basicamente, empregando sistemas que possuam alguma capacidade de aprendizagem e possam se adaptar como, por exemplo, as redes neurais e os sistemas com lógica *fuzzy* [6], [7], [8].

A utilização da lógica *fuzzy* em sistemas de controle, incorporada a um sistema com capacidade de aprendizagem [9],[10] como o das redes neurais, potencializa um controle com adequada adaptação à característica de conjugado necessária, ou seja, a uma minimização das oscilações de torque. Neste sentido, a proposta deste trabalho consiste na obtenção de um controle de velocidade para um motor de relutância variável que possua as seguintes características:

- Reduzida oscilação de torque;
- Resposta dinâmica adequada;
- Boa estabilidade;
- Eliminação do sensor de posição.

Os atuais controles de velocidade de máquinas elétricas em geral ainda são, em sua grande maioria, sistemas de controle do tipo Proporcional-Integral (PI). Este controle também se aplica ao acionamento do motor de relutância variável como ilustra o esquema da Figura 1. Entretanto, quando a entrada do controlador PI é zero, como deve ocorrer, por exemplo, no caso em que a velocidade de saída ω iguala a referência ω_{ref} em regime permanente, sua saída será um valor constante, porém não nulo. Quando esta saída - em nosso caso, a referência de corrente - for introduzida no bloco do motor/conversor, aparecerá uma oscilação de torque na máquina, como conseqüência da dinâmica natural do sistema de

relutância. Para evitar este problema, propõe-se então adicionar um sinal de compensação à saída do controlador PI como se mostra na Figura 1.

São discutidas nesta tese algumas formas de se obter este sinal, bem como as entradas utilizadas pelo compensador para a geração do sinal adicional de compensação. Propõe-se também uma técnica para a eliminação do sensor de posição e a conseqüente operação do acionamento.

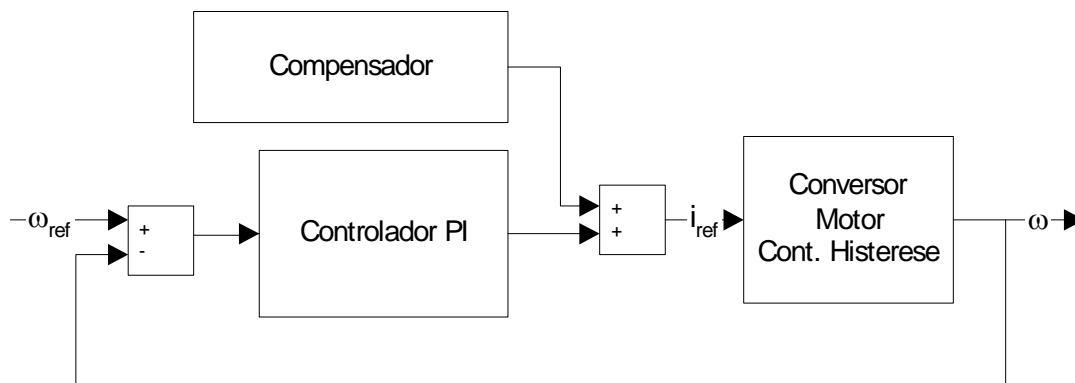


Figura 1 - Sistema com sinal de compensação

1.2 Objetivos

- Avaliar os trabalhos existentes na literatura, tanto na redução das oscilações de torque quanto na eliminação do sensor de posição.
- Implementar um sistema de compensação de oscilação de torque para o acionamento;
- Investigar em condições de falha de uma fase, o desempenho do acionamento e sua robustez;
- Avaliar a possibilidade de treinar o compensador usando medições de velocidade no lugar do sinal de torque;
- Desenvolver uma nova técnica para eliminação de sensor de posição usando método *Neuro-fuzzy*.

1.3 Definição e delimitação do objeto de trabalho

Este trabalho tem como proposta principal, o estudo teórico e prático de melhoria e qualidade de operação de um motor de relutância variável, de modo a obter a eliminação do sensor de posição e a redução de oscilação de torque utilizando-se técnicas de controle baseadas em inteligência artificial. Como objetivos secundários podemos apontar o desenvolvimento de um modelo matemático de controle dentro do estado-da-arte.

Define-se como um trabalho inovador baseado na busca de um caminho novo dentro da área de atuação no acionamento de máquinas de relutância variável: controle com aprendizagem automática. O controle com aprendizagem automática aplica técnicas baseadas em inteligência artificial como redes neurais, lógica *fuzzy* e algoritmos genéticos em sistemas de controle, em nosso caso, controle de máquinas elétricas.

Dentro deste novo enfoque proposto para o estudo de acionamento de máquinas elétricas situam-se, além do motor de relutância variável, as seguintes máquinas: motores CC de ímãs permanentes sem escovas, motores de passo, motores híbridos, etc.[11].

Para atingir os objetivos propostos, foi utilizada no presente trabalho, a seguinte metodologia:

Revisão bibliográfica: Inicialmente, buscou-se situar o presente trabalho dentro do universo de pesquisa na área de acionamento de máquinas elétricas, para isto foi feita uma revisão ampla da bibliografia disponível sobre o assunto. O resultado desta busca é apresentado nos capítulos 3 e 4.

Simulação do processo: O processo foi simulado utilizando-se o programa de simulação MATLAB. O objetivo primordial desta fase foi a comprovação teórica da potencialidade da técnica de treinamento com lógica *Neuro-fuzzy* do controle inteligente para a minimização das oscilações [12] e o desenvolvimento de técnicas de sensoriamento automático da posição angular do MRV.

Caracterização da máquina: O projeto da máquina de relutância foi feito através de um programa de análise por elementos finitos, desenvolvido por um doutorando da Universidade Técnica de Berlim [13].

Implementação do processo: O processo foi implementado em uma bancada experimental composta por um conversor eletrônico de potência e um motor de relutância variável fabricado sob encomenda, com a finalidade de utilização em pesquisas. O objetivo primordial desta etapa foi comprovar experimentalmente a validade dos estudos feitos no item da simulação do processo.

Este trabalho foi realizado no âmbito de um projeto de cooperação entre Brasil e Portugal. Portanto, durante o período de dezembro de 2000 a dezembro de 2001, o trabalho de tese foi desenvolvido no Instituto Superior Técnico de Lisboa, Portugal sob orientação do Prof. Doutor Paulo José da Costa Branco. Isto foi possível devido ao projeto bilateral de cooperação CAPES-GRICES (antigo ICCTI).

1.4 Contribuições Originais

Esta tese propõe na sua primeira parte uma nova técnica de minimização das oscilações de torque do motor de relutância variável sem o uso de sinal de torque, seja medido ou estimado, usando-se para isto um sistema de compensação com aprendizagem automática baseada na técnica *Neuro-fuzzy*.

Outro aspecto que caracteriza a originalidade deste trabalho refere-se a uma nova metodologia de estimação de posição/velocidade do rotor. Ela se baseia na eliminação total do sensor de posição do rotor de um motor de relutância variável, utilizando modelagem por aprendizagem supervisionada em tempo real. Todo este desenvolvimento foi comprovado através de simulações e de resultados experimentais.

1.5 Estrutura da Tese

Esta tese está estruturada em 8 capítulos e 4 apêndices. O primeiro capítulo apresenta a motivação para o desenvolvimento deste trabalho, bem como os objetivos a que ele se propõe. Define e delimita estes objetivos e apresenta as contribuições originais.

O capítulo 2 apresenta o motor de relutância variável, sua estrutura física e elétrica. Considera-se neste capítulo a análise linear e não linear do projeto desta máquina. Mostra os aspectos da operação dinâmica do motor e também os conversores eletrônicos de potência disponíveis para alimentá-lo.

No capítulo 3, é apresentada uma revisão das estratégias de redução de oscilações de torque em um motor de relutância variável. São mostradas técnicas baseadas em tabelas características, em modelos matemáticos lineares e usando controle adaptativo inteligente.

É apresentada no capítulo 4, uma revisão das estratégias para eliminação de sensor de posição em um motor de relutância variável. Esta revisão baseou-se em 5 regiões de operação, do motor parado até as altas velocidades.

O capítulo 5 tem como objetivo mostrar como foi desenvolvido o algoritmo de controle para a minimização das oscilações de torque. O sistema é baseado na modelagem por aprendizagem supervisionada. Os controladores *neuro-fuzzy* serão apresentados. Também neste capítulo, resultados de simulação e experimentais serão apresentados, bem como, a utilização ou não do sinal de torque elétrico obtido na condição de não haver um torquímetro disponível. Além disto, uma avaliação da robustez do controle é feita ao se retirar eletricamente uma das fases do motor.

O capítulo 6 apresenta o desenvolvimento de uma técnica de eliminação de sensor de posição angular do rotor de máquina de relutância variável. Detalhes do treinamento do sistema *Neuro-fuzzy* e da operação do sistema são apresentados. Resultados de treino *offline* confirmam a capacidade da técnica. Neste mesmo capítulo é verificado experimentalmente o modelo de eliminação do sensor de posição angular do rotor proposto. Casos reais são apresentados e comprovam a confiabilidade do modelo.

O capítulo 7 apresenta as conclusões finais do trabalho e propostas de trabalhos futuros. Finalmente, o capítulo 8 apresenta a bibliografia utilizada para o desenvolvimento do trabalho.

Os dois primeiros apêndices mostram separadamente o sistema experimental do acionamento de relutância variável com uma descrição detalhada deste sistema. O segundo apêndice apresenta uma revisão de lógica *fuzzy* e de redes neurais.

O apêndice C apresenta um algoritmo de busca por valores de torque médio. Resultados de simulação e experimentais são mostrados para validar o algoritmo. Algoritmo este, que foi utilizado no estudo para a compensação automática das oscilações de conjugado, com o objetivo de minimizar estas oscilações.

O apêndice D apresenta os trabalhos desenvolvidos pelo doutorando dentro do escopo do estudo desta tese.

Capítulo 2

Máquina de Relutância Variável (MRV): Características Fundamentais

2.1 Introdução

A mais antiga referência a uma máquina de relutância variável é apresentada em 1838, na construção de uma locomotiva que fazia o trajeto entre Glasgow e Edimburgo na Escócia [14], portanto, o conceito de uma máquina elétrica de relutância variável é conhecido há bastante tempo. No entanto a sua utilização só se tornou possível graças a alguns avanços tecnológicos na década de 70, como o advento da eletrônica de potência, a redução dos preços de microcontroladores e o desenvolvimento de ferramentas matemáticas computacionais [15]. Estes avanços permitiram a construção de acionamentos com máquinas de relutância variável de elevado desempenho.

Atualmente, a máquina de relutância variável já possui uma pequena parcela do mercado de acionamentos de velocidade variável de baixa e média potência, devido à sua simplicidade construtiva e robustez. A sua utilização tem englobado desde eletrodomésticos a equipamentos industriais. Uma das primeiras aplicações comerciais foi o servo motor utilizado na *plotter* Draftmaster da Hewlett-Packard. Em aplicações industriais, podemos encontrar o motor de relutância variável em minas de carvão [16], bauxita e ferro; em acionamentos de ônibus elétricos (Inglaterra), assim como em aplicações aeronáuticas, como o motor para bombeamento de combustível de 120 HP e 25000 rpm descrito por Radun [17]. Outra importante aplicação aeronáutica é a eliminação da central hidráulica do F-16 [18].

Esta máquina possui, entretanto, algumas desvantagens: a necessidade, para determinados tipos de estratégia de controle, de um sensor de posição[19]; a oscilação de torque gerado pela máquina; e um alto nível de ruído sonoro em relação a outras máquinas de sua classe de potência. Além disto, a modelagem matemática da MRV é dificultada pelo fato de possuir expressiva não-linearidade magnética. Durante a operação, o perfil de magnetização das fases irá determinar a amplitude das oscilações de torque.

A seguir, abordaremos os aspectos mais significativos sobre a estrutura, a análise linear e a influência da não-linearidade magnética nas características eletromecânicas da máquina de relutância variável.

2.2 Estrutura Básica

As máquinas de relutância variável possuem características distintas das máquinas convencionais como, por exemplo, a máquina assíncrona. Sua estrutura básica consiste de pólos salientes no estator e no rotor, e é construída com material ferromagnético laminado. Os pólos do estator têm enrolamentos concentrados, enquanto no rotor não há enrolamentos nem ímãs permanentes. Os enrolamentos de pólos diametralmente opostos são ligados em série para produzir um campo magnético que passe pelos dois pólos. A Figura 2 mostra a estrutura básica de uma MRV com 6 pólos no estator e 4 no rotor. Outras possibilidades de construção incluem esquemas com 6 pólos no estator e 2 no rotor (6/2), 10/4, 12/8, 12/10, entre outras. A escolha de uma configuração ou outra irá depender essencialmente da aplicação a que se destina o motor e do número de fases no conversor disponíveis para a operação da máquina de relutância variável.

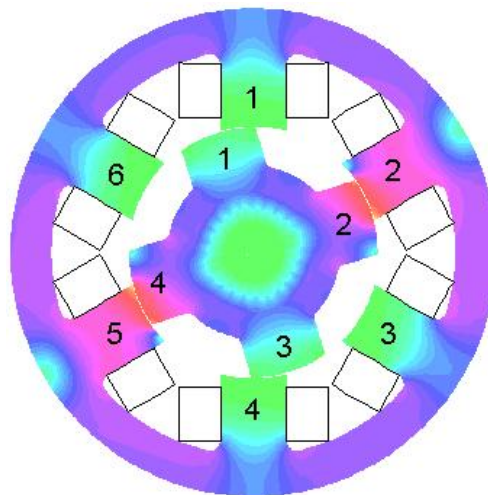


Figura 2 - Estrutura básica de uma máquina com 6 pólos no estator e 4 no rotor

Esta estrutura é chamada de motor de relutância variável regular, por possuir simetria a partir de seus centros e ser igualmente espaçada em torno do rotor e do estator. Uma desvantagem de se possuir um número reduzido de pólos no rotor é que se tem uma alta oscilação de torque. Por outro lado, o custo de um conversor para esta máquina é inferior ao conversor utilizado para máquinas de quatro e cinco fases, além de possuir um valor de

razão entre a indutância na posição alinhada e a indutância na posição desalinhada bastante maior aos valores encontrados em máquinas de número de pólos superiores a quatro [14].

Diferentemente de outros tipos de máquinas, este tipo de estrutura também se caracteriza por não apresentar um modo de operação, onde todas as variáveis de estado sejam constantes. A operação ocorre através de inúmeros e contínuos transitórios. Já no motor de corrente contínua, quando em estado permanente, o fluxo e a corrente permanecem constantes no tempo e no espaço. No motor de corrente alternada esta afirmação também é verdadeira, quando se utiliza o referencial síncrono.

A operação da MRV é baseada no princípio de relutância mínima. Quando o enrolamento sobre um par de pólos do estator é energizado, os pólos do rotor são atraídos para uma posição que represente relutância mínima no circuito magnético (posição alinhada). Para criar um movimento de rotação contínua, os enrolamentos do estator devem ser seqüencialmente energizados, em sincronismo com a posição do rotor.

Podemos destacar algumas características positivas e negativas da máquina de relutância variável.

Pontos positivos:

a) *Baixo custo de fabricação:* Por ser uma máquina bastante simples, o custo de produção e de material é considerado em trabalhos comparativos, para aplicações específicas, de 60% do custo de produção de máquinas CC e CA. A ausência de ímãs e de enrolamentos no rotor permitem a queda de custo de material.

b) *Efeitos mínimos com a temperatura:* Na MRV a influencia da temperatura está essencialmente limitada à variação da resistência estatórica. Motores de indução apresentam grande dificuldade de diminuição das perdas rotóricas, que influenciam no aumento do escorregamento e na degradação da integridade mecânica pela indução de fratura nas barras rotóricas.

c) *Operação em altas velocidades:* A velocidade máxima desenvolvida pela MRV é limitada por cinco fatores principais:

- Perdas no núcleo e ventilação
- Resistência mecânica do material do rotor
- Dinâmica do eixo do rotor

-
- Rolamentos dos mancais
 - Capacidade VA do conversor

d) Tolerância a faltas: Caso ocorra um curto circuito em um enrolamento da fase ou o rompimento deste enrolamento, não haverá grandes conseqüências danosas à máquina. Em máquinas permanentemente excitadas ou em motores de indução, o fluxo rotórico pode induzir altas correntes nas bobinas curto-circuitadas. Em motores de indução de grande potência, a constante de tempo associada ao fluxo de rotor bloqueado pode ser duradoura o suficiente para causar danos na máquina. Nas máquinas de relutância variável esta possibilidade é descartada.

e) Baixa inércia: A baixa inércia é devida à inexistência de material no espaço interpolar do rotor do motor.

f) Facilidade de reparo: Simplicidade do enrolamento do estator. Em alguns casos é possível retirar o enrolamento de uma fase sem atrapalhar os outros enrolamentos.

Pontos negativos:

a) Diâmetro de eixo pequeno: Possuir um diâmetro de eixo pequeno faz com que a máquina tenha uma baixa velocidade crítica e aumenta a possibilidade de deflexão lateral que pode causar o contato do rotor no estator sob a influência de forças magnéticas desbalanceadas.

b) Entreferro pequeno: Possuir um pequeno entreferro é desejável para se ter uma alta razão de indutância. Porém, as máquinas de relutância variável são mais sensíveis a variações no entreferro do que, por exemplo, os motores de indução. Qualquer variação afeta o balanço entre as fases e pode gerar um aumento no nível de ruído.

c) Impossibilidade de operação direta na rede elétrica: A máquina de relutância variável necessita de um conversor para que opere corretamente. Conversor este que adiciona custo ao acionamento como um todo.

d) Estrutura duplamente saliente: Esta construção física com pólos no rotor e estator gera oscilações de torque e aumento do ruído audível.

e) Uso de sensor de posição: As MRV necessitam de um sensor de posição para o correto chaveamento das fases e conseqüentemente a perfeita operação da máquina.

f) *Altas perdas por ventilação a velocidades superiores*: A própria conformação do rotor facilita a ventilação do interior da máquina, porém a altas velocidades isto não é suficiente.

A tabela 1 apresenta resumidamente estes pontos característicos da máquina de relutância, dividindo-se em um conjunto positivo e outro negativo.

Pontos positivos	Pontos negativos
Baixo custo de fabricação e do material	Aparentemente elevada perda por ventilação à alta velocidade
Efeitos com a temperatura mínimos	Pequeno entreferro
Possibilidade de operação a altas velocidades	Estr. duplamente saliente pode causar ruído e osc. de torque
Tolerância à faltas	Não pode ser operado diretamente na rede elétrica
Baixa inércia	Necessidade de sensor de posição
Facilidade de reparo	Diâmetro do eixo pequeno

Tabela 1- Características do motor de relutância variável

O motor de relutância variável (Figura 3) utilizado neste trabalho foi projetado através de um programa de análise por elementos finitos, desenvolvido por um doutorando da Universidade Técnica de Berlim [13], e possui como características básicas os seguintes dados apresentados na Tabela 2:

Número de pólos no estator	6
Número de pólos no rotor	4
Número de fases	3
Resistência por fase do enrolamento do estator	1.3Ω
Potência nominal	750W
Tensão nominal	150V
Corrente por fase máxima (RMS)	5.5 A
Velocidade nominal	1800 rpm
Arco do pólo do estator no entreferro	30 graus
Arco do pólo do rotor no entreferro	30 graus

Tabela 2 – Dados de projeto do motor de relutância variável



Figura 3 – Fotografia da máquina de relutância variável: rotor e estator

Não se deve confundir o acionamento do MRV com a máquina síncrona de relutância clássica (síncrono), em que o estator possui enrolamentos distribuídos, que são energizados por uma fonte trifásica senoidal.

2.3 Características eletromecânicas da MRV

As características eletromecânicas da MRV dependem de alguns fatores principais, como: estrutura do motor (número de fases, número de pólos, magnitude dos arcos dos pólos), característica de magnetização, configuração do inversor e da estratégia de controle a ser empregada.

O estudo do perfil de indutância da MRV baseia-se na análise da relação entre a posição do rotor e do estator, assim como do valor da corrente que percorre os enrolamentos do estator. A relutância do circuito magnético irá variar de tal maneira que a indutância dos enrolamentos do estator é função da posição do rotor e do valor da corrente. No intervalo de um passo polar, duas posições em particular podem ser identificadas: alinhada e desalinhada. Quando os pólos do estator e do rotor estão alinhados, a relutância é mínima e, portanto, a indutância é máxima. Quando os pólos do estator e do rotor estão desalinhados, a relutância é máxima e a indutância do enrolamento é mínima. Entre essas duas posições, a indutância varia linearmente com a posição do rotor. Isto irá definir o perfil de indutância ideal que geralmente é usado para caracterizar em uma primeira aproximação a interação magnética entre o estator e o rotor de uma dada MRV (Figura 4(a)).

O princípio fundamental da operação da MRV é baseado na variação do fluxo em função da posição angular do rotor. A equação básica de tensão por fase é dada por:

$$V_j = Ri_j + \sum_{k=1}^m \left\{ i_k \frac{\partial L_{kj}}{\partial i_k} \frac{di_k}{dt} + L_{kj} \frac{di_k}{dt} + i_k \frac{\partial L_{kj}}{\partial \theta} \omega \right\} \quad (1)$$

Onde: n é o número total de fases, v_j é a tensão aplicada na fase j , i_j é a corrente aplicada na fase j , R é a resistência do enrolamento por fase, L_{kk} representa o fluxo próprio no estator, L_{kj} ($k \neq j$) representa o fluxo mútuo no estator, ω é a velocidade, θ é a posição rotórica e t é o tempo.

O torque do MRV é produzido energizando-se seqüencialmente os enrolamentos nos períodos em que suas indutâncias próprias são crescentes. Portanto, para se obter um conjugado ótimo, livre de oscilações ([20], [21], [22]), o fornecimento de corrente deve estar sincronizado com a posição obtida através de um sensor de posição acoplado ao eixo do motor.

Um modo de se comandar a MRV é energizando uma fase por vez. O torque de saída é o resultado médio da contribuição das fases, uma após a outra. Logo, a análise pode ser feita durante a operação de uma fase e então repetida para outras fases[23].

O torque produzido durante a operação de uma fase pode ser calculado pela variação de co-energia do sistema:

$$T_j = \frac{\partial}{\partial \theta} W'(\theta, i) \Big|_{i=\text{const}} \quad (2)$$

onde W' é a co-energia dada por:

$$W'(\theta, i) = \int_0^i \lambda \cdot di \quad (3)$$

Obviamente, este torque não é constante. O torque instantâneo total é dado pela soma dos torques individuais de cada fase.

$$T_{\text{inst}}(\theta, i) = \sum_{\text{fases}} T_j(\theta, i) \quad (4)$$

Considerando o sistema magneticamente linear, a co-energia é igual a

$$W'(\theta, i) = \frac{1}{2} L(\theta) \cdot i^2 \quad (5)$$

Logo, o torque instantâneo, por fase é dado por:

$$T_{\text{inst}j}(\theta, i) = \frac{1}{2} \frac{dL_j}{d\theta} \cdot i^2 \quad (6)$$

Assim, o torque do motor é proporcional à variação da indutância com a posição do rotor ($dL_j/d\theta$) e ao quadrado da corrente.

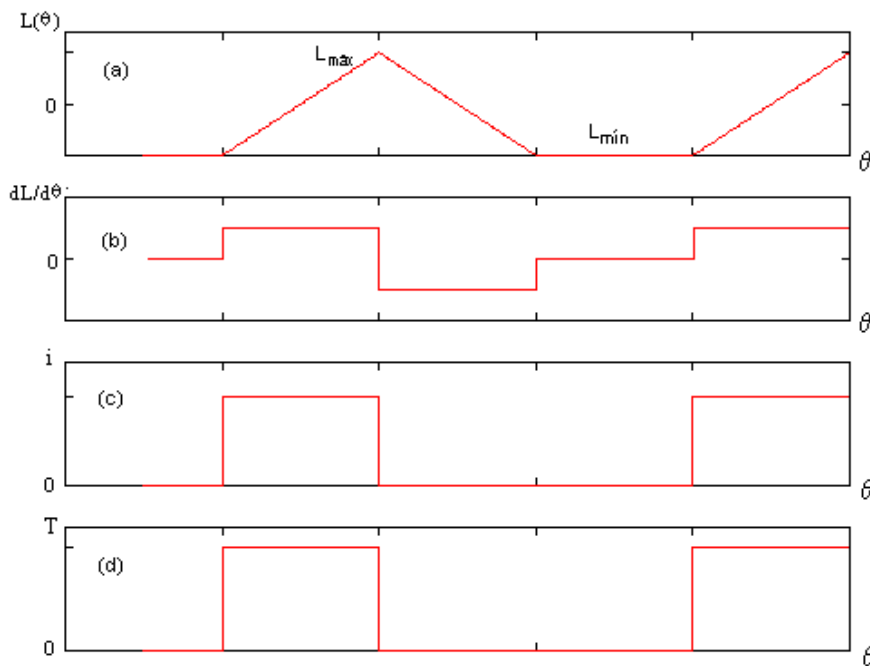


Figura 4 - Formas de onda ideais ilustrando o princípio de produção de torque no MRV. (a) Indutância linear, (b) Variação da indutância com a posição, (c) corrente, (d) Torque.

Para produzir torque positivo, a corrente tem que ser aplicada no enrolamento quando a indutância for crescente. Nota-se que o torque independe da direção da corrente, então correntes unidirecionais podem ser usadas e com isso pode-se simplificar o conversor de potência como veremos mais adiante.

Como já foi dito, a oscilação de torque é inerente às máquinas de relutância variável devido à sua estrutura duplamente saliente. O princípio de relutância para a produção de torque é utilizado por estas máquinas, nas quais as fases são alimentadas de forma independente e em sucessão. O torque é definido pela característica não-linear torque-corrente-posição (Figura 5) e pela curva de magnetização (Figura 6).




Figura 5 - Torque de fase - $T(\theta, i)$.




Figura 6 – Enlace de Fluxo – $\psi(\theta, i)$

A diferença básica no mecanismo de geração de torque entre a MRV e outras máquinas CA ou CC é a dependência da operação da máquina com a posição do rotor. Nas máquinas CC, as duas forças magnetomotrizes são constantes e os comutadores e escovas mantêm a ortogonalidade entre elas. A situação é similar nas máquinas CA senoidais, sejam elas de ímã permanente, com excitatriz, ou do tipo de indução. Os dois fluxos que interagem entre si são aparentemente variáveis, porém, podemos torná-los constantes se fizermos uma transformação de referência. Infelizmente, não existe também para a MRV uma

transformação de referencial que vá eliminar a dependência nas equações, entre posição e torque. Tudo isto devido à estrutura duplamente saliente [24].

Esta é a razão porque a minimização de torque nestas máquinas, utilizando controle eletrônico, é altamente dependente das características não-lineares torque-corrente-posição.

O modelo eletromecânico de uma máquina de relutância variável pode ser descrito como a equação de torque (7), a equação de tensão-corrente (8) relativa a cada fase j , e a equação mecânica, que relaciona o torque eletromecânico com o fluxo magnético (9). Nestas equações: v_j é a tensão aplicada na fase j , R é a resistência do enrolamento por fase, λ representa o fluxo no estator e t é o tempo. Na equação mecânica J_{MRV} é o momento de inércia da MRV, J_c é o momento de inércia da carga, T_e é o torque elétrico, B é o coeficiente de atrito viscoso e finalmente $d\theta/dt$ é a variação da posição no tempo.

$$T_e(\theta, i) = \frac{\partial W'(\theta, i)}{\partial \theta} \quad (7)$$

$$v_j = Ri_j + \frac{d\lambda}{dt} \quad (8)$$

$$(J_{SRM} + J_c) \frac{d^2\theta}{dt^2} = T_e - T_c - B \frac{d\theta}{dt} \quad (9)$$

Assim, como uma aproximação inicial, as seguintes considerações são feitas para tornar a análise mais adequada ao trabalho:

- Os enrolamentos do motor são alimentados por correntes contínuas.
- As indutâncias mútuas entre as fases são desprezadas.
- A comutação de uma fase para outra é instantânea.

Com essas considerações, é possível obter o perfil de indutância ideal e calcular as características ideais de torque que podem ser usadas para explicar a operação da MRV e desenvolver estratégias de comando.

2.4 Efeitos da não-linearidade magnética

As características ideais obtidas na análise magnética linear são convenientes para explicar o princípio de operação da MRV e desenvolver estratégias de controle. Por outro lado, características mais realísticas são necessárias para o projeto do conversor e do sistema de controle. As características reais diferem significativamente das características ideais devido às curvas de magnetização das laminações que formam o estator e o rotor. A não linearidade magnética afeta tanto o perfil de indutância quanto a forma de onda do torque.

Através de um programa de análise por elementos finitos, podemos obter um modelo aproximado que represente a não-linearidade magnética baseado na função de enlace de fluxo $\lambda(\theta, i)$, visto na Figura 7.

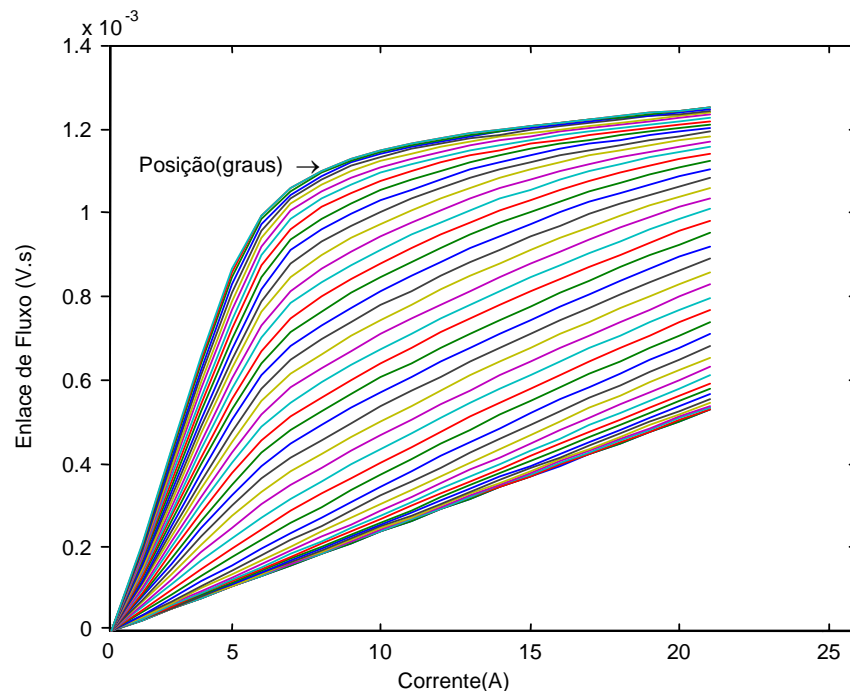


Figura 7 – Fluxo magnético em uma fase em relação à corrente variando entre 0 e 90°.

Diante da não-linearidade magnética do motor, temos que, ao utilizarmos uma corrente constante alimentando o motor e variando a posição do rotor em relação ao estator, obtendo-se assim uma curva de torque oscilante (Figura 8). Por extensão, supõe-se que se alimentarmos o motor com uma corrente oscilante em um certo padrão, poderemos obter um torque constante (Figura 9). Pode-se analisar estas duas situações na Figura 10, onde se nota a curva de torque oscilante real do sistema, proveniente de uma corrente constante, e

a curva de torque ideal constante obtida de uma corrente oscilante. Esta busca por um sinal constante de torque seria o ideal, mas imperfeições quanto à comutação das fases e quanto à regulação da corrente podem dificultar esta obtenção de sinal de torque constante.




Figura 8 – Diagrama com entrada constante e saída oscilante




Figura 9 – Diagrama com entrada oscilante e saída constante

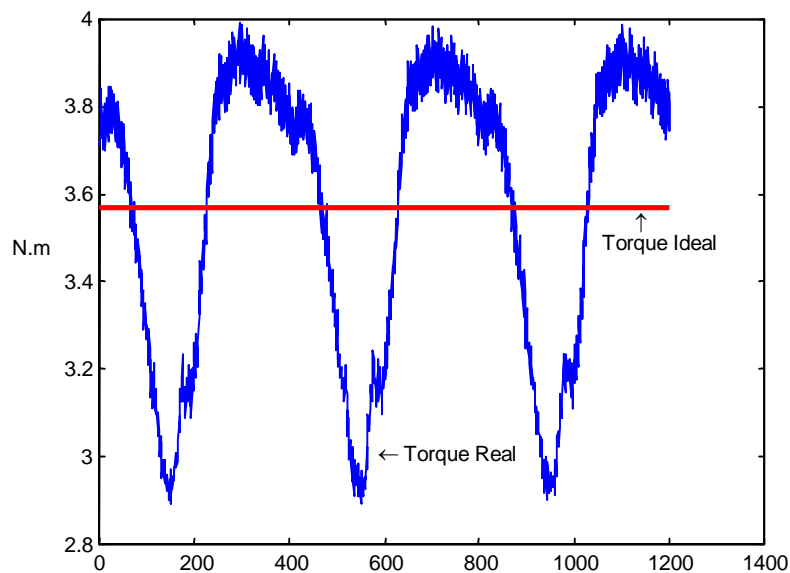


Figura 10 – Curvas de Torque Real e Torque Ideal

A título de exemplo, consideremos um sistema de regulação de velocidade com controlador PI em regime permanente [12]. Como o controlador PI irá gerar um sinal constante e desejamos uma saída de torque idealizado constante, devemos somar ao sinal

constante do PI, um sinal adicional oscilante que deverá ser produzido pelo compensador, como mostrado na Figura 1. A Figura 11 apresenta com detalhes este esquema.




Figura 11 – Detalhe do sistema de compensação

2.5 Operação Dinâmica

O acionamento da máquina de relutância variável pode ser feito através de diferentes estratégias, conforme [14]:

- Operação a pulso único
- Operação através de *PWM* de tensão
- Operação através de regulação de corrente

O fluxo do motor de relutância variável não é constante, mas deve ser estabelecido a cada chaveamento. Na operação como motor, o chaveamento deve coincidir com o período que os pólos do rotor estão se aproximando dos pólos do estator da fase que está sendo alimentada. Este processo de chaveamento é controlado pelos ângulos de energização (θ_{on}) e de desenergização (θ_{off}).

Em operação como motor, caso o fluxo não se reduza a zero antes que os pólos comecem a se separar, o torque elétrico muda de sinal e se cria um torque de frenagem (Figura 12). Para que isto não aconteça, a tensão deve ser revertida em θ_{off} , o que é feito através dos diodos, quando as chaves são abertas, levando a tensão na fase para $-V_s$ como exemplificado na Figura 13.

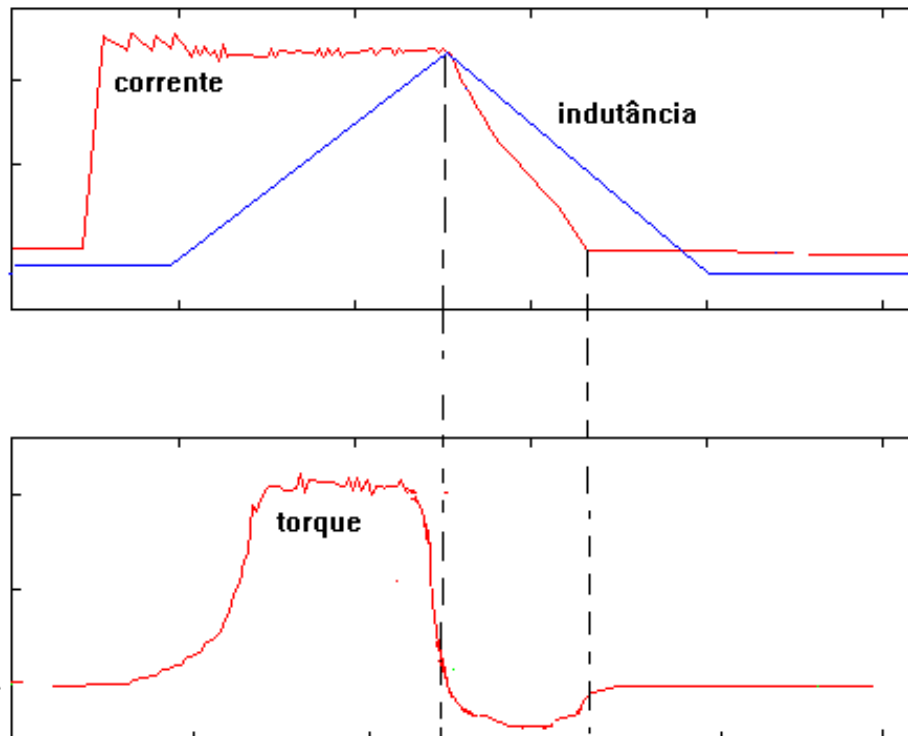


Figura 12 – Curvas de Indutância, Corrente e Torque

2.5.1 Operação a pulso único

Na Figura 13, temos mostradas as curvas de indutância ideal, de tensão, de enlace de fluxo e de corrente para esta estratégia de operação a altas velocidades.

Nota-se na Figura 13 que a corrente decresce antes mesmo de alcançarmos θ_{off} , devido à força contra-eletromotriz que limita a corrente em altas velocidades. Por este motivo, as chaves semicondutoras devem ser ligadas antes do período de indutância crescente (antes do início da sobreposição entre fases), para que haja tempo da corrente se estabelecer e crescer a um determinado nível enquanto a indutância ainda é baixa.




Figura 13 – Curvas para operação em pulso único

2.5.2 Operação através de *PWM* de tensão

Existem duas técnicas de operação através de *PWM* de tensão (ou de modulação por largura de pulso): operação unipolar e operação bipolar (Item 2.6 Conversores).

Na unipolar, uma chave fica fechada e a outra é acionada em alta frequência com um ciclo de trabalho fixo. Na bipolar, as duas chaves são acionadas em alta frequência. A vantagem da operação unipolar é que ela produz menos ruídos acústicos, diminuindo substancialmente a necessidade de filtros capacitivos, além das perdas por efeito Joule serem menores.

Em ambas as técnicas de operação, a curva de enlace de fluxo cresce com passo regular de crescimento com um valor médio de inclinação constante. Antes de começar a superposição dos pólos do rotor e estator, a taxa de crescimento da curva de corrente (Figura 14) é aproximadamente constante como o crescimento do enlace de fluxo.

As curvas da Figura 14 e Figura 15 mostram que o ângulo de energização (θ_{on}) está na posição de desalinhamento e o ângulo de desenergização (θ_{off}) está na posição de

alinhamento. Isto ilustra o fato de que a baixas velocidades, situação onde este tipo de controle é bastante usado, é utilizada toda a zona de torque útil do motor.




Figura 14 – *PWM* de Tensão – Operação Unipolar




Figura 15 – *PWM* de Tensão – Operação Bipolar

2.5.3 Operação através de regulação de corrente

Em baixas velocidades, a máquina geralmente não possui força contra-eletromotriz suficiente para limitar a corrente, então o controle de corrente por histerese é utilizado para obtenção aproximada de um pulso retangular de corrente.

Neste caso, as chaves são operadas de acordo com a corrente de fase. Se a corrente de fase for maior ou menor que a referência de corrente, a saída do comparador de corrente irá permitir o acionamento ou não das chaves.

Pode-se operar em modo unipolar ou bipolar. Porém, o bipolar permite operação nos quatro quadrantes, possibilitando a regeneração de energia para o sistema (Figura 16).

O controlador de histerese mantém a corrente entre dois limites, que definem a chamada banda de histerese. Como a tensão é fixa, o resultado é que a frequência de chaveamento decresce juntamente com o aumento da indutância. Esta estratégia de operação é utilizada neste trabalho para acionar a MRV.




Figura 16 – Regulação de corrente – operação bipolar

2.6 Conversores

Existem inúmeras topologias de conversores desenvolvidas atualmente para MRV. Cada topologia é proposta para aplicações específicas, possuindo vantagens e desvantagens que irão, naturalmente, indicar qual aplicação é mais indicada para cada uma delas.

Outra consideração é a necessidade do enrolamento da máquina estar em série com as chaves semicondutoras, diferentemente dos acionamentos de máquinas CA. A indústria de chaves semicondutoras ainda não possui ampla variedade de módulos semicondutores produzidos especialmente para a aplicação em MRV, tornando a montagem do conversor mais cara e menos compacta do que aquelas disponíveis para conversores aplicados a máquinas CA, tornando mais difícil a inserção da MRV no mercado de acionamentos [25].

Um conversor para MRV deve apresentar as seguintes características:

- ser capaz de aplicar pulsos de tensão contrária na fase que tenha acabado de ser desenergizada, com o intuito de levar o mais rápido possível a corrente nesta fase a zero, desmagnetizando tal fase no menor tempo possível, e assim não gerar torque negativo após passar pela sua posição de alinhamento.
- permitir a sobreposição de corrente de fase, ou seja, permitir que mais de uma fase conduza ao mesmo tempo. Isto é normalmente desejado quando a máquina opera em altas velocidades, quando o tempo de comutação entre fases é muito pequeno. Esta superposição permite uma operação menos oscilante da máquina.
- ser capaz de controlar a amplitude e forma de onda das correntes de fase e finalmente,
- ser capaz de suprir pulsos de corrente unipolar em cada fase, sincronizada com a posição angular instantânea do rotor.

Os conversores são classificados segundo sua operação e seu projeto. Eles são inicialmente divididos em *hard-switching* (comutação brusca) e *soft-switching* (comutação suave).

Soft-switching é o chaveamento onde as chaves são comutadas com tensão zero ou corrente zero evitando perdas no chaveamento e aumentando a eficiência do conversor. Para que se tenha o cruzamento das tensões ou correntes por zero, temos que utilizar capacitores e indutores ressonantes, o que irá aumentar o custo do conversor.

O *hard-switching* por outro lado, tem um custo inferior ao *soft-switching*, mas tem como desvantagem o aumento das perdas e também da diminuição da eficiência do conversor. Neste item iremos tratar dos conversores *hard-switching* mais comuns, resumindo para cada um, suas principais características:

Conversor clássico ou ponte assimétrica: Tem como característica uma grande flexibilidade no controle de corrente, onde cada fase é controlada independentemente das outras, permitindo uma operação com qualquer nível de superposição de corrente, além de ser uma configuração bastante confiável, por não permitir curtos-circuitos no barramento CC do conversor. Entretanto, esta configuração não é a mais barata, por necessitar de duas chaves semicondutoras por fase (Figura 17).

Quando se constrói um conversor, costuma-se relacionar o custo das chaves semicondutoras como a capacidade VA do conversor. O conversor clássico tem uma capacidade VA igual a $2n$, onde n representa a capacidade VA de cada chave. Portanto, para redução deste valor, muitos autores sugerem topologias inovadoras que buscam reduzir o número de chaves controladas por fase de forma a diminuir a taxa VA e consequentemente o custo. Existem topologias que conseguem utilizar menos de duas chaves por fase, porém apresentam limitações em relação a esta configuração chamada clássica como será destacado a seguir (Figura 17).




Figura 17 – Conversor “clássico”

Conversor C-dump: Este conversor é apresentado na Figura 18. Ele apresenta somente uma chave por fase, utilizando uma chave adicional, um capacitor e um reator em uma configuração de *chopper*, com o intuito de se dar retorno da energia à fonte. A operação

deste conversor se inicia com a ligação da chave da fase A. Quando esta chave ligada em série com a fase A é desligada, o diodo é bloqueado e a energia da fase é transferida para o capacitor C com uma tensão superior à da fonte. A tensão é mantida em $2*V_{cc}$ de maneira a aplicar $-V_{cc}$ nas outras fases para uma rápida desmagnetização. A chave adicional é operada em frequência superior à das outras chaves.

Como vantagens deste conversor, podemos dizer que permite a operação independente das fases com um número inferior de chaves que o conversor clássico. Em contrapartida, uma avaria no *chopper* irá afetar a operação de todo o conversor, sendo que também as perdas neste *chopper* faz com que o conversor C-dump seja menos eficiente (ele necessita sempre de operar em *hard-chopping*).




Figura 18 – Conversor C-dump

Conversor trifásico *Pollock*: Esta configuração foi proposta por Pollock e Williams [26], sendo apresentada na Figura 19. Esta topologia aponta uma forma de reduzir o número de chaves semicondutoras através do compartilhamento de chaves entre fases. Este tipo de conversor é uma boa escolha para motores de grande número de fases pois neste caso é possível trabalhar com um número inferior a uma chave por fase. Entretanto, este conversor sofre com a restrição de controle de corrente para motores de três fases. O motivo é que dois enrolamentos adjacentes precisam compartilhar a mesma chave semicondutora no conversor Pollock trifásico. O controle deste conversor perde a praticidade tornando seu desenvolvimento mais complicado. Outra desvantagem é haver

maior estresse elétrico nas chaves semicondutoras, indicando este conversor somente para aplicações de baixa potência.




Figura 19 – Conversor Trifásico “Pollock”

Este conversor é melhor explorado quando usado com uma MRV de quatro fases, pois pode-se usar dois blocos de chaves de maneira separadas, mantendo-se fases adjacentes separadas uma das outras. Este conversor é indicado para conversores com número par de fases.

Conversor de Miller: Neste conversor uma única chave é responsável por controlar a corrente em todas as fases. Todas as outras chaves têm o objetivo de escolher qual fase deve ser energizada de acordo com a posição angular do rotor. Sua característica principal é a baixa taxa VA em relação ao conversor clássico em uma taxa de $(n+1/2n)$. Outra vantagem é necessitar de $n+1$ chaves/diodos para um motor de n fases.

A desvantagem é não permitir um controle totalmente independente de fases, não sendo possível aplicar tensão positiva numa fase e negativa em outra simultaneamente. Assim sendo, em altas velocidades, onde a superposição de fases é importante para maximizar o torque, o desempenho da máquina é profundamente limitado. Por este motivo, esta configuração é habitualmente usada em aplicações que necessitam de velocidades baixas.




Figura 20 – Conversor de Miller

Neste trabalho, um conversor foi construído na forma modular com o intuito de possibilitar a montagem de inúmeras configurações para *hard-switching*. Como o objetivo da presente tese era dar ênfase ao controle, sem se preocupar com a configuração do conversor, foi escolhida uma configuração mista entre o conversor clássico e o conversor de Miller (Figura 21) apresentada no Apêndice A e usou-se esta configuração para a obtenção de todos os resultados. Buscou-se um controle *PWM* com controle de corrente por histerese (*CR-PWM*).

Analisando-se as configurações apresentadas, conclui-se que não existe um conversor único que possa ser utilizado em todas as aplicações possíveis. Dependendo da potência, das características físicas do motor e das necessidades da carga, uma configuração pode ser melhor que outra. É necessário pois, antes de se escolher o conversor, analisar todos estes aspectos.




Figura 21 – Conversor clássico modificado

2.7 Considerações Finais

Neste capítulo apresentou-se a máquina de relutância variável com suas características elétricas e mecânicas, bem como os conversores usualmente aplicáveis. No próximo capítulo será apresentada uma revisão das técnicas de minimização das oscilações de torque em um motor de relutância variável.

Capítulo 3

Revisão das Estratégias de Redução de Oscilações de Torque da MRV

3.1 Introdução

Devido à sua natureza não-linear, a máquina de relutância variável possui, intrinsecamente, oscilações de torque no eixo do rotor. Estas oscilações são produzidas majoritariamente na região de superposição de fases, quando a responsabilidade de geração do torque é transferida de uma fase para outra. Existem inúmeras estratégias e métodos para a redução das oscilações de torque neste tipo de máquina. Essencialmente podemos apresentar duas abordagens para o problema da redução da oscilação de torque: a primeira consiste em melhorar o projeto magnético da máquina, enquanto a outra é baseada no uso de controle eletrônico. Embora o projeto magnético não seja objeto deste trabalho, o assunto é brevemente discutido a seguir. Adiante, passamos a tratar exclusivamente do controle eletrônico.

Os projetistas levam em consideração, durante o projeto das máquinas elétricas, as suas características magnéticas, e projetam a estrutura dos pólos do estator e do rotor para que a máquina possa operar em uma determinada velocidade sem oscilações de torque. Existem muitos trabalhos nesta área. Porém, estas estratégias restringem a faixa de operação para a minimização das oscilações de torque, pois o desenho da estrutura mecânica da máquina é fixa e não se modifica com a velocidade da MRV [14].

Um estudo que apresenta modificações mecânicas nos pólos para uma operação mais suave é apresentado por Kavanagh et al. em [27] onde se mostra um motor que possui uma característica estática torque-ângulo próxima à senoidal quando operado na saturação. Esta solução não é muito adequada devido à necessidade de utilização de um motor altamente especializado. Há também soluções onde são projetadas máquinas com geometria otimizada para produzir um torque mais suave [28]. Trabalhos como o [29] desenvolvem um conjunto de equações analíticas para o projeto das máquinas de relutância variável. Este projeto inclui também o efeito da saturação na máquina. As aproximações e simplificações

são justificadas através de um modelo computacional detalhado. Estas equações facilitam significativamente o projeto. Atualmente, com o desenvolvimento de programas de elementos finitos, projetos de máquinas elétricas estão ficando mais detalhados e completos permitindo a simulação de toda a operação do motor [13], [30].

A abordagem pelo controle eletrônico concentra-se no projeto do conversor e na estratégia de controle da corrente, e baseia-se na seleção de uma combinação ótima dos parâmetros de operação que incluem a tensão de alimentação, ângulos de energização e desenergização e o perfil do sinal de corrente de cada fase da máquina.

A técnica mais básica de operação de uma máquina de relutância variável, sem levar em consideração a busca pela redução das oscilações de torque, é manter a corrente constante durante o período de condução. Porém, isto gera oscilações no perfil de torque, devido ao torque produzido pela MRV ser uma função não linear da corrente e da posição como visto no capítulo anterior. Esta não será abordada, por não ser uma técnica de redução de oscilações, sendo simplesmente uma técnica de operação para o motor.

Têm sido apresentadas na literatura, inúmeras propostas para a redução das oscilações de torque utilizando-se diversos tipos de controle e modelagem [27], [31], [32], [33]. Algumas propostas se baseiam em modelos estáticos do sistema com o uso de tabelas que contêm as características magnéticas da máquina para somente uma determinada condição de operação (carga e velocidade) [27], outras têm a vantagem de serem capazes de se adaptarem em tempo real a alterações nas características do sistema, além de outras propostas apresentarem a oportunidade de estimar algumas variáveis usadas pelo controle da máquina como: velocidade, torque ou posição do rotor [31]. Adicionalmente, há trabalhos que empregam apenas um modelo linear do motor, sendo tal modelo inadequado para aplicações de alta performance, pois são necessárias inúmeras aproximações matemáticas.

Outros trabalhos utilizam um perfil de corrente modelado para produzir picos de corrente, quando o rotor está posicionado em regiões de baixa variação da indutância em função da posição [32]. Há também métodos altamente dependentes da posição do rotor, onde qualquer erro na leitura da posição pode levar a uma falha do controle. E também há outros que são limitados a baixas velocidades [23].

Pode-se concluir que existe uma ampla gama de possibilidades. O objetivo deste capítulo é, portanto, discutir as vantagens e desvantagens de algumas das propostas apresentadas, além de propor um novo enfoque de ação de controle para redução das oscilações de torque, baseado no sistema *neuro-fuzzy* com aprendizagem.

Propor uma classificação única para todas as estratégias de controle e minimização das oscilações de torque de um motor de relutância variável é bastante complexo. Portanto, podemos dividi-las em alguns subgrupos, apresentados no diagrama da Figura 22:

Nas seções subsequentes serão discutidas algumas destas estratégias.

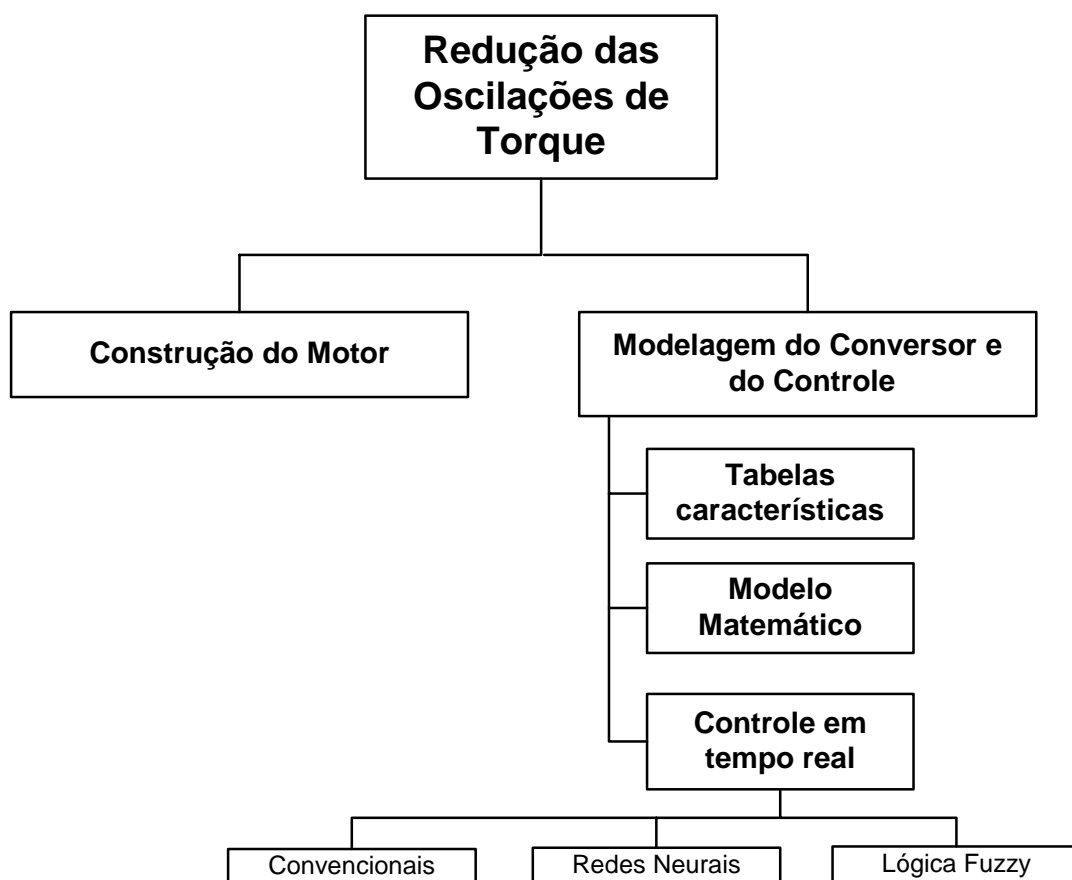


Figura 22 - Diagrama de classificação dos principais métodos de redução de oscilação de torque para a máquina de relutância variável.

3.2 Uso de Tabelas Características

Esta estratégia de controle foi uma das primeiras implementadas na redução das oscilações de torque [34]. Baseia-se na utilização de tabelas com a característica magnética da máquina, nomeadamente as relações $L(\theta,i)$ e $T(\theta,i)$ (apresentadas na Figura 23 e Figura 24 para a nossa máquina). Estas informações são armazenadas em um formato tabular, de forma que

um perfil de pulso de corrente ótimo para cada fase possa ser determinado a partir da informação de posição e do torque requerido. Esta característica estática geralmente é obtida de ensaios experimentais *offline* [34] e os dados são guardados em memória para serem utilizados durante a operação do motor. Elementos finitos também podem ser usados para obtenção destes dados em uma primeira aproximação, em lugar de dados obtidos experimentalmente através de ensaios [34], [35]. Geralmente os dados são guardados para a máquina em intervalos de 1° de resolução e 10 valores de corrente, permitindo uma precisão suficiente para o controle. Os valores intermediários são obtidos através de interpolação.




Figura 23 - Perfil de Indutância – $L(\theta, i)$

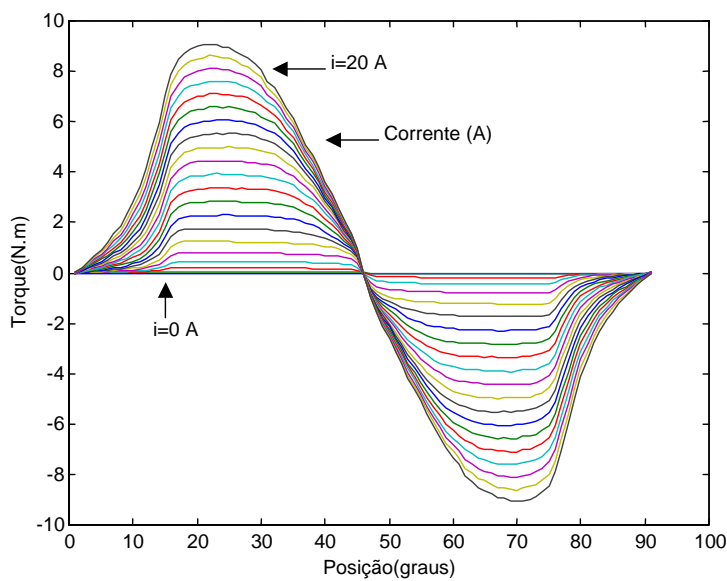


Figura 24 - Torque de fase - $T(\theta, i)$.

A desvantagem do uso destas tabelas estáticas é não incluir as perdas que ocorrem durante a operação dinâmica, visto serem obtidas com a máquina parada. Além disto, a obtenção destas tabelas não é trivial, exige muito tempo computacional e o número de passos do algoritmo de obtenção é significativo.

O método descrito por [33] é baseado na estimação do torque instantâneo do motor de relutância através da curva característica fluxo-posição-corrente. Estas curvas são obtidas pela medição do fluxo e corrente para diversas posições do rotor e depois pela interpolação dos valores obtidos, usando-se um método de interpolação bi-cúbica (Apêndice C). Neste método, a estimação do torque é obtida através da utilização de equações polinomiais de 3ª ordem, onde os coeficientes são pré calculados e guardados na memória do DSP usado na implementação (Figura 25). Em seguida, o torque estimado é comparado com um torque de referência, e o resultado é então usado no regulador de corrente que controlará as correntes de fase do motor (Figura 26). O algoritmo deste método envolve a operação de polinômios de 3ª ordem e não leva em consideração a vantagem da superposição de fases quando a variação da indutância de fase é positiva. Os resultados obtidos mostram redução da oscilação de torque, porém, há degradação do rendimento da máquina.

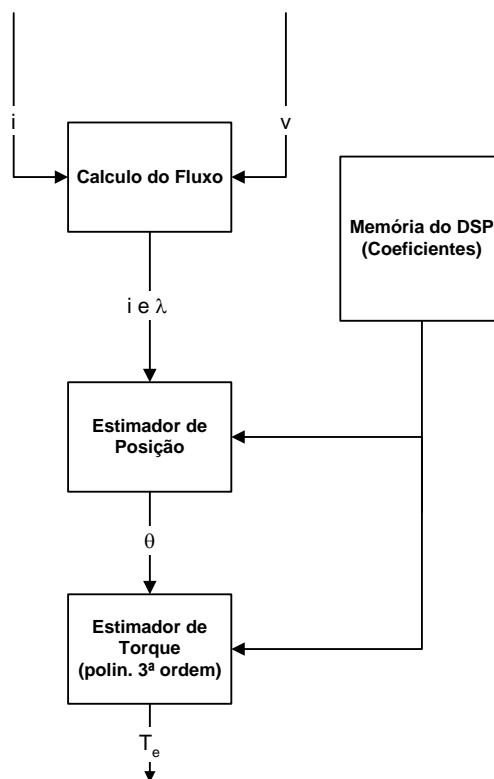


Figura 25 – Estimação de torque e posição

O método de redução da oscilação de torque apresentado em [32] é obtido com a superposição das correntes durante a comutação. Baseia-se em definir um ponto central de comutação, onde duas fases possuem correntes iguais, tal que os torques gerados por fase, somados, sejam iguais ao torque total desejado. Este método também usa as curvas estáticas torque-corrente-posição obtidas experimentalmente.

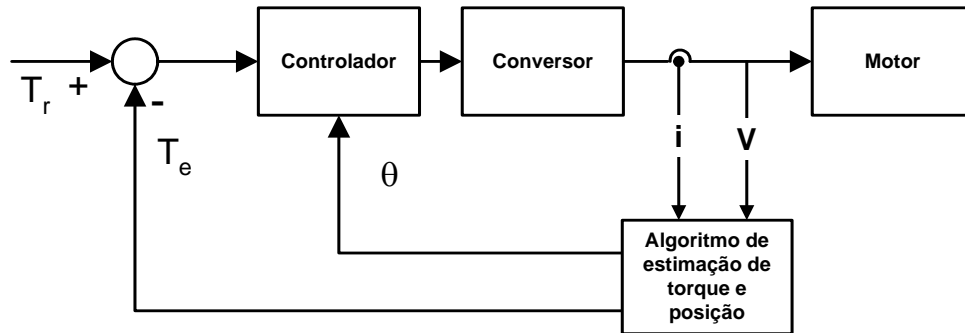


Figura 26- Estimação e controle do motor de relutância variável

3.3 Uso de Modelos Matemáticos

Uma alternativa à utilização de tabelas de torque no controlador é o uso de expressões analíticas para descrever a curva característica torque-corrente-posição. A representação da máquina através de seu modelo matemático linear ou não-linear pode trazer vantagens no controle das máquinas de relutância variável. Ela permite levar em conta a velocidade da máquina e usar uma aproximação em tempo real em vez de utilizar uma tabela pré-definida. Assim, o modelo usado pelo controlador da MRV pode ser atualizado em tempo real [8]. Porém, é muito difícil descrever com precisão a distribuição de torque até mesmo com modelos matemáticos complexos devido às não-linearidades da MRV. Além disto, as expressões de torque não podem ser invertidas ou rearranjadas para obter o valor de corrente para determinado torque sem apelar a algoritmos numéricos complexos.

Entretanto, existem trabalhos que pré-calculam as funções de torque otimizadas para minimizar a oscilação [4], [36]. Eles fazem uma parametrização da tensão que é dependente da posição e dos perfis de correntes. Esta aproximação reduz significativamente a carga computacional do controlador e permite a realização em tempo real do controle mais facilmente. Este método também permite a inclusão de objetivos secundários de controle como a maximização do rendimento, minimização da tensão de alimentação, entre outros. Entretanto, o cálculo *offline* das funções leva à perda de robustez no sistema e também à

impossibilidade de se atualizar as funções de torque de acordo com o ponto de operação do motor. Outro problema é a necessidade de um grande espaço de memória para armazenar toda a tabela para uma vasta faixa de velocidade e vários níveis de torque.

Uma possibilidade de se implementar um controle adaptativo foi investigado em [37], onde o controlador de corrente possui bom comportamento dinâmico para rejeição de ruídos. No entanto, o controlador encontrado apresenta uma estrutura complexa para operação *online*, tornando impraticável a sua realização e implementação.

O trabalho proposto em [38] obtém uma aproximação matemática das relações fluxo-corrente-posição e torque/corrente-posição para a obtenção do modelo algébrico que representa estas características. O uso deste modelo permite um controle de torque eficiente e em tempo real através das malhas de controle de velocidade e posição. O trabalho apresenta resultados de simulação e experimentais. Como desvantagens deste método [38], temos a linearização de grande parte do sistema.

Em [39], propõe-se um modelo analítico não-linear com estimação de parâmetros *online* usando identificação recursiva (equação (10)).

$$\lambda_{fase} = \lambda_s (1 - e^{-f(\theta)i}) \quad (10)$$

onde $f(\theta) = a + b\cos\theta + c\cos2\theta + d\sin\theta + e\sin2\theta$

Desta relação, pode-se gerar o diagrama apresentado na Figura 27

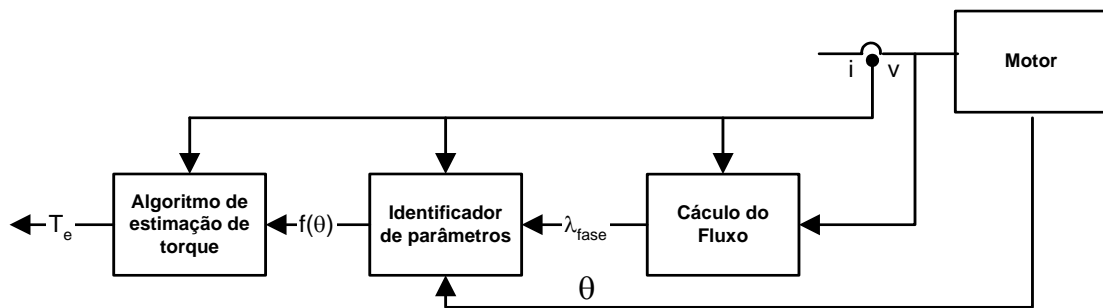


Figura 27 - Diagrama de Blocos do método de identificação *online* do torque

substituindo a equação de fluxo (10) na equação de torque (2) temos:

$$T_j = \frac{\lambda_s \frac{df(\theta)}{d\theta}}{f(\theta)^2} \left[1 - (1 + i_j f(\theta)) e^{-i_j f(\theta)} \right] \quad (11)$$

As equações (10) e (11) representam o modelo não-linear da MRV, que é atualizado em tempo real com identificação de parâmetros.

Este trabalho de Mir et al. [39] não faz redução da oscilação de torque, somente modela o sistema. Entretanto, a estimação do torque permite uma adequada avaliação do controle, facilitando uma posterior busca da redução da oscilação de torque baseada neste trabalho.

O trabalho de Inanç et al. [40] propõe reduzir a oscilação de torque na região linear e em presença de indutância mútua. Porém, negligencia as perdas por correntes parasitas e perdas no ferro, além do valor da indutância mútua ser não significativo. A técnica de redução da oscilação é baseada na soma dos quadrados das correntes, mas isto só é possível se for aplicada a máquinas que possuem no mínimo uma fase conduzindo como, por exemplo, a MRV 8/6. A expressão da corrente de referência é dada por:

$$i_{ref}^2 = i_1^2 + i_2^2 + i_3^2 + i_4^2 + \dots + i_{n/2}^2, \text{ sendo } n \text{ o numero de pólos no estator.} \quad (12)$$

Uma restrição desta estratégia é termos somente dois sensores de corrente, forçando o sistema a operar duas fases por vez.

3.4 Controle Adaptativo *Online*

É possível desenvolver o controle do motor utilizando técnicas de controle adaptativo em tempo real. Algumas utilizam algoritmos complexos que permitem a atualização em tempo real dos parâmetros do controlador, outras lançam mão de técnicas ditas inteligentes como redes neurais, lógica *fuzzy* e algoritmos genéticos com os respectivos sistemas de aprendizagem.

3.4.1 Controle Clássico

Através de técnicas clássicas de identificação, podemos obter a atualização dos parâmetros do controlador em tempo real, usando um algoritmo de identificação recursiva baseado no método dos mínimos quadrados [41]. Este algoritmo utiliza os parâmetros do modelo não linear da máquina de relutância variável e durante o processo de operação, as constantes de controle são ajustadas em tempo real. O único parâmetro de entrada requerido pelo

controlador é o valor de resistência de fase da máquina. O controlador tem a capacidade de se ajustar em tempo real a qualquer mudança da característica da máquina.

Os resultados indicam, entretanto, que esta técnica funciona bem para uma faixa de velocidades baixas. Para velocidade acima da nominal, a modelagem não é possível devido à necessidade de grande tempo computacional utilizado para o cálculo do torque e do sistema de identificação no mesmo DSP.

A Figura 28 mostra o diagrama de blocos do controlador proposto. O controle de velocidade é um controlador PI convencional que gera um sinal de torque de referência T^* . Com o sinal de T^* , e após a estimação do torque da máquina, o controlador envia as correntes de referência para o comando por histerese. O grande mérito deste trabalho está na identificação dos sistemas e não na minimização das oscilações de torque. Porém, quanto melhor a identificação do sistema, melhor será a minimização.

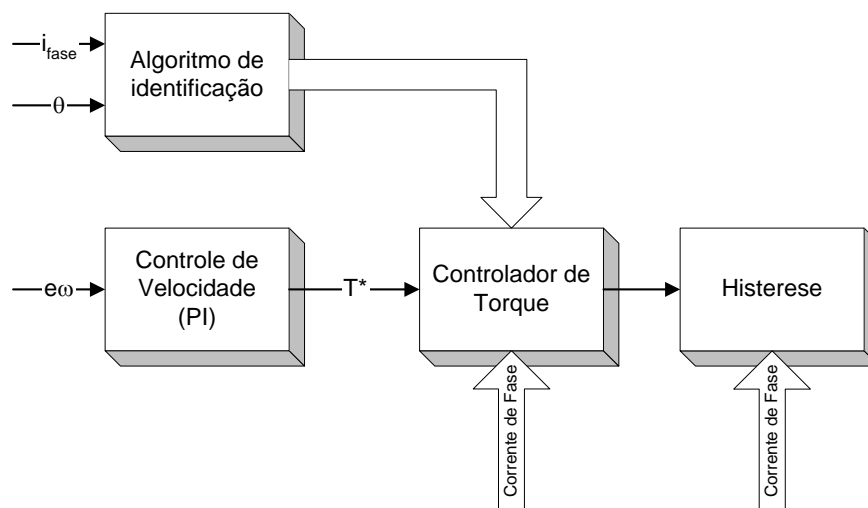


Figura 28 – Diagrama de Blocos do controlador com a adaptação dos parâmetros.

Um outro trabalho que utiliza técnicas de controle clássico é apresentado em [31]. Este apresenta a otimização das curvas de corrente nas fases, principalmente nos momentos de comutação, para a redução da oscilação. A estratégia é baseada em gerar o contorno das correntes de forma que a soma dos torques gerados por cada fase seja constante e igual ao torque desejado. Os perfis de corrente otimizados escolhidos determinam se o torque será realmente constante ou não. Para esta escolha, os autores definem uma função de contorno $f_i(\theta)$. Existem inúmeros conjuntos de funções de contorno que servem para o motor de relutância variável (no caso apresentado, um motor de 4 fases). Como exemplo podemos ter as funções mostradas na Figura 29.




Figura 29 – Funções de contorno de corrente

A função correspondente à fase 1 seria:

$$\begin{aligned}
 f_1(\theta) &= 0.5 - 0.5 \cos 4(\theta - \theta_0), & \theta_0 \leq \theta < \theta_1 \\
 &= 1, & \theta_1 \leq \theta < \theta_2 \\
 &= 0.5 + 0.5 \cos 4(\theta - \theta_2), & \theta_2 \leq \theta < \theta_3 \\
 &= 0, & \text{outros valores}
 \end{aligned}$$

O algoritmo do controle é realizado utilizando as curvas características de torque-corrente-posição. Primeiro calcula-se $f_i(\theta_i)$ usando a tabela. Depois, calculam-se os valores de torque relativos a cada fase. Com estes valores, consulta-se a tabela e obtêm-se os valores das correntes i_{desejada} . Depois se regula a corrente para manter os valores desejados.

A utilização destas funções de contorno, porém, possui algumas restrições:

1. A soma das funções para todas as fases deve ser unitária em todos os instantes, e
2. A corrente deve ser capaz de seguir o contorno definido pela função.

Portanto, apesar de ser possível o uso de diversas formas de contorno, deve-se fazer uma escolha criteriosa das funções de acordo com o nível de tensão disponível para a excitação de cada fase.

3.4.2 Redes Neurais

O artigo apresentado por Elmas et al. [42] faz uso da técnica de aprendizagem *backpropagation* associada a funções de ativação. As vantagens deste método estão no fato dele não necessitar de conhecimento anterior do modelo ou equação e não ter funções matemáticas com alto nível de complexidade. Entretanto, uma rede pode ter alta carga computacional dependendo da quantidade de neurônios da rede. Também, a coleta de dados para o treinamento é crítica de forma a permitir uma aprendizagem eficiente. Além disto, o período de treino é muito lento.

Este trabalho simplesmente modela o motor, não busca compensar as oscilações de torque. Ele substitui as tabelas que representam o motor.

O trabalho apresentado por Reay et al. [43] utiliza uma rede neural para controlar o motor de relutância variável. A técnica é baseada na especificação de um perfil de torque de referência. Este perfil é obtido da tabela $T(\theta, i)$. O trabalho apresenta a geração da relação inversa torque/corrente/posição em tempo real. Isto é interessante por permitir que sejam levadas em conta as interações magnéticas entre as fases que estão conduzindo ao mesmo tempo. Esta situação não é obtida quando se trabalha com o sistema estático.

O artigo apresenta uma rede neural com duas entradas (torque e θ) e uma saída (corrente). É importante salientar a necessidade da utilização do sensor de torque durante todo o tempo de operação, e o fato de que, se as condições iniciais da rede forem desfavoráveis, a aprendizagem da rede será bastante influenciada por estas condições.

A Figura 30 mostra como foi implementado o sistema. Os ângulos θ_A e θ_B são os ângulos de fase, e são calculados por um sistema de lógica de comutação, a partir da corrente de referência em duas fases e da posição do rotor.

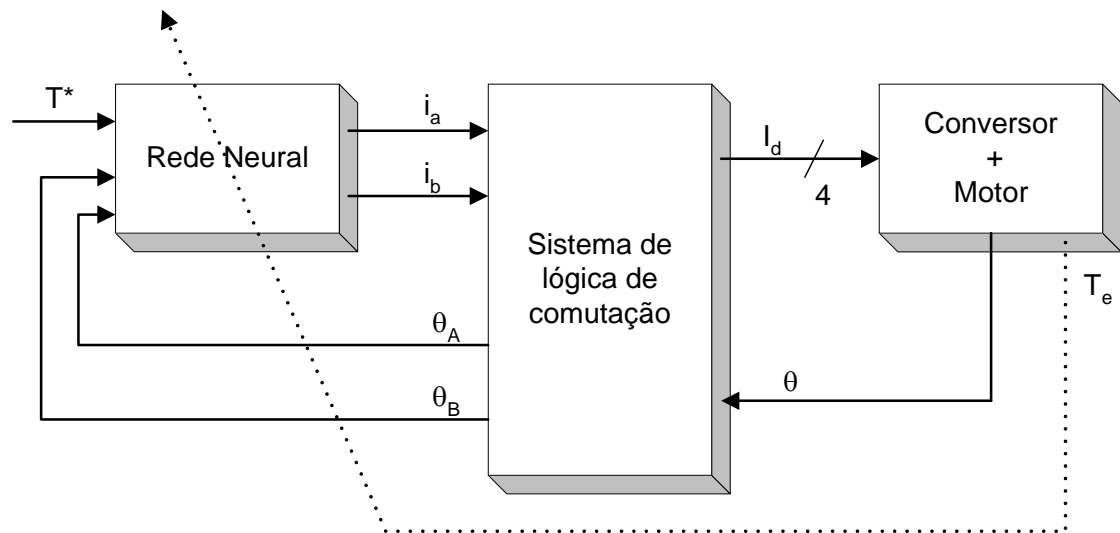


Figura 30 - Sistema Implementado

O artigo [44] tem como princípio básico o uso de uma rede neural *feedforward* com algoritmo *backpropagation*. Os dados de treino com a característica fluxo-corrente-posição foram usados para gerar uma aproximação matemática do fluxo baseada em redes neurais (Figura 31). A técnica minimiza o erro entre o torque de referência e o torque predito do motor usando o *backpropagation* para atualizar os comandos de corrente das duas fases adjacentes capazes de produzir torque positivo.

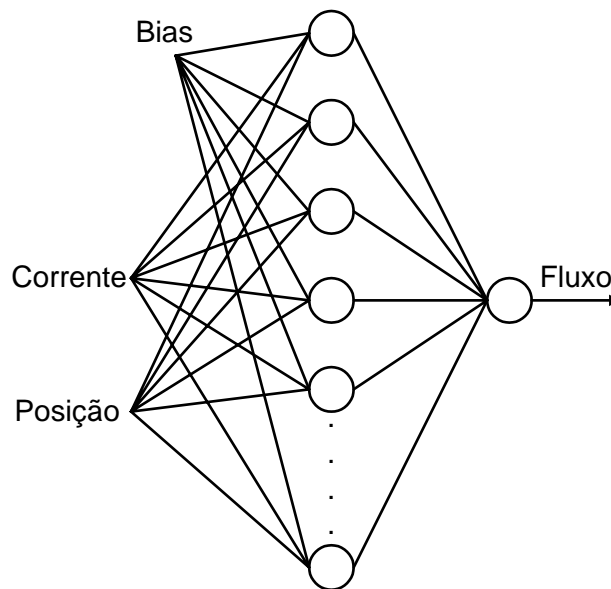


Figura 31 – Estimação do fluxo utilizando-se uma rede neural com *backpropagation*

3.4.3 Lógica *Fuzzy*

O trabalho [45] apresenta uma aplicação da utilização de um sistema lógico *fuzzy* que substitui um controlador PI convencional. A MRV apresenta uma estrutura de controle não linear multivariável, que necessita de um projeto complexo de controle para se alcançar uma alta performance dinâmica.

O artigo é dividido em 2 partes:

1ª- As não linearidades magnéticas são modeladas usando lógica *fuzzy*.

2ª- O controle de velocidade é feito com lógica *fuzzy*.

Como entradas do controlador de velocidade tem-se: $e\omega$ e $ce\omega$ (erro de velocidade e variação do erro de velocidade) e a saída será Δi . As regras foram obtidas heurísticamente.

As restrições a este trabalho seriam a necessidade de se saber previamente como devem ser as regras *fuzzy* e também a incapacidade de se ajustar estas regras.

O artigo [7] apresenta um controle adaptativo *fuzzy*. Os parâmetros iniciais são escolhidos aleatoriamente e depois são ajustados para otimizar o controle. Este artigo tem como características não ser dependente de propriedades predeterminadas da máquina e ser capaz de se adaptar a qualquer mudança destas. É robusto em relação a erros de posição e evita a produção de torque negativo durante a comutação.

O controlador usa como entrada somente a posição e como saídas as correntes de fase. Ele utiliza uma base de conhecimento que tem como método de adaptação a diferença entre o torque desejado e o torque real. Esta diferença será o sinal de erro para a atualização do controlador. O torque desejado é estimado utilizando-se a técnica proposta em [39].

A estrutura do sistema *fuzzy* pode ser assim apresentada:

A saída (corrente de referência i_{fases}) do controlador é descrita como:

$$i_{fases} = \frac{\sum_{j=1}^n \mu_j(\theta) w_j}{\sum_{j=1}^n \mu_j(\theta)} \quad (13)$$

onde $\mu_j(\theta)$ denota a função de pertinência do j-ésimo conj. *fuzzy* da variável de entrada θ , e w_j denota o j-ésimo singleton *fuzzy* de saída.

Para simplificar a notação podemos escrever a função de ativação normalizada $\phi_j(\theta)$ de cada regra como:

$$\phi_j(\theta) = \frac{\mu_j(\theta)}{\sum_{j=1}^n \mu_j(\theta)} \quad (14)$$

assim, a saída do controlador pode ser descrita como:

$$i_{\text{fases}} = \sum_{j=1}^n \phi_j(\theta) w_j \quad (15)$$

A adaptação é feita da seguinte forma:

$$w_j^{\text{nov}} = w_j^{\text{antigo}} + \eta \cdot (T^* - T) \phi_j(\theta) \quad (16)$$

onde η representa a taxa de aprendizagem e T^* é o torque de referência.

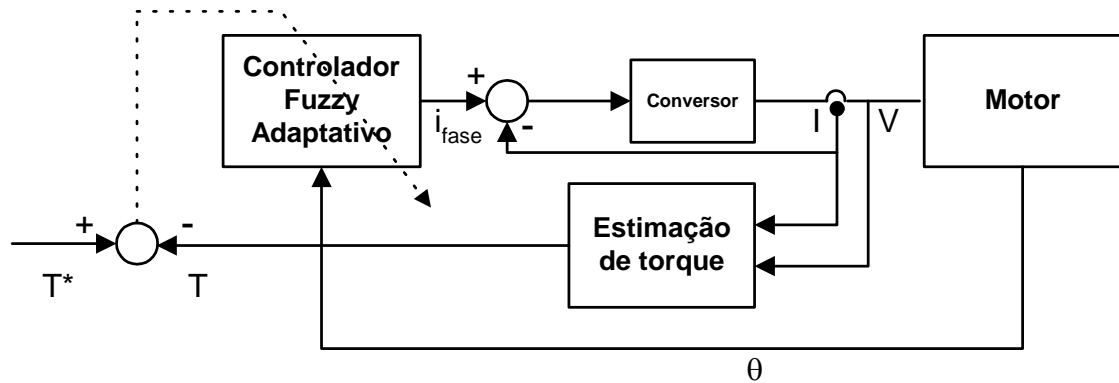


Figura 32 - Controle adaptativo *fuzzy* para o controle de torque do MRV

O erro de torque (T^*-T) é usado para fazer a adaptação e na saída temos as correntes de fase de referência.

A comutação normalmente é feita perto da posição de alinhamento do estator com o rotor, onde a indutância de fase é alta e a desmagnetização da fase é lenta, aumentando a densidade de torque e evitando picos de corrente.

O método apresentado por Bolognani et al. em [46] é uma tentativa de redução de oscilações de torque através de uma modelagem *fuzzy* onde o sinal da oscilação de torque é obtido indiretamente, a partir do sinal de aceleração do motor.

A estratégia é baseada em regras que acionam funções diferentes de acordo com a fase que deve ser energizada. Estas funções são formuladas com referência ao controle de velocidade de modo deslizante.

As entradas da operação são: erro de velocidade e a aceleração. Este aspecto de buscar obter a informação de oscilação de torque através do sinal de aceleração é bastante interessante. Além disto, o sistema lógico *fuzzy* aqui apresentado é estático, ou seja, se houver mudanças na carga, ou em qualquer parâmetro da máquina, o controle não sofrerá nenhuma mudança. Isto é indesejável, pois o SLF (Sistema Lógico *Fuzzy*) pode estar sintonizado numa dada condição ótima de operação, mas para outra condição de operação, esta sintonia pode não ser satisfatória.

Outro trabalho utilizando lógica *fuzzy* é apresentado em [47]. Ele apresenta um compensador *fuzzy* para a obtenção do melhor valor do ângulo de desenergização da máquina de relutância variável, para que haja redução da oscilação de torque. Melhores resultados seriam obtidos se houvesse um sistema de auto-sintonia do compensador.

3.4.4 Outras técnicas

Um método baseado no controle das rampas de fluxo em lugar das rampas de corrente ou torque é apresentado por [48]. Algoritmos genéticos são utilizados para determinar as rampas de fluxo para um controle de torque constante. Este método possui a necessidade do conhecimento exato das características da máquina e da posição do rotor.

3.5 Considerações Finais

Este capítulo apresentou diversas técnicas de redução de torque em um motor de relutância variável. Viu-se que as potencialidades destas técnicas são diversas. Vantagens e desvantagens de cada uma foram discutidas, bem como se buscou encontrar uma forma classificatória para elas. As técnicas propostas não suprem todas as lacunas da faixa de operação das MRV. A superposição de algumas destas técnicas apresentadas anteriormente pode facilitar a melhoria da operação destas máquinas. Buscou-se nesta revisão encontrar como ponto comum entre todos os métodos, a utilização do sinal de torque seja ele

medido ou estimado. O estudo proposto para este trabalho visa não utilizar o sinal de torque fazendo assim uma contribuição importante para cobrir esta lacuna no estudo. Além disto, o método a ser apresentado busca uma maior flexibilidade com a adaptabilidade ao sistema permitindo a variação de parâmetros da máquina. Este aspecto será apresentado no capítulo 5.

Capítulo 4

Revisão das Estratégias de Eliminação de Sensor de Posição

4.1 Considerações Iniciais

O perfeito funcionamento de uma máquina de relutância variável depende essencialmente da correta excitação das fases em sincronismo com a posição do rotor. Um *resolver* ou *encoder* pode solucionar plenamente esta necessidade. Eles são capazes de nos dar a informação necessária da posição do rotor para uma correta aplicação dos pulsos.

Em algumas aplicações, estes sensores não são desejáveis por diversas razões: custo, tamanho, peso, inércia e confiabilidade. Também há determinadas aplicações, tais como os compressores, onde as condições ambientais não permitem o uso de sensores de posição externos.

A eliminação do sensor de posição pode ter duas finalidades básicas: somente saber em que momento se deve comutar as fases da máquina, sem a preocupação de realimentar este sinal em uma malha de controle ou estimar a posição com determinado grau de exatidão, para que se possa utilizar este sinal no controle da máquina. Esta seção trata de apresentar uma revisão das principais estratégias de eliminação de sensores em máquinas de relutância variável[49].

O princípio fundamental da operação da MRV é baseado na variação do fluxo em função da posição angular do rotor. A dependência do fluxo com a posição rotórica é o ponto chave para a operação desta máquina sem sensores. Invariavelmente, todas as técnicas existentes de eliminação de sensores de posição são baseadas neste princípio fundamental para a obtenção da informação de posição.

As variáveis tipicamente medidas são: tensão, corrente, tempo de crescimento ou diminuição da corrente na fase. As variáveis derivadas são: indutância, fluxo magnético e força contra-eletromotriz.

Diversos métodos de controle sem sensor foram relatados na literatura nas últimas duas décadas [50]-[59]. Os vários métodos de eliminação de sensores podem ser classificados da seguinte maneira:

- Métodos de uso intenso de hardware que requerem circuitos externos para a injeção de sinal de sensoriamento [50],[51], [52] e [53];
- Métodos de uso intenso de software tais como a técnica da integração do fluxo, que exigem grandes tabelas para armazenar as características magnéticas do SRM [54], [55];
- Métodos baseados em modelos como o método de observador de estado[56], [57], o método da medida da potência [58], técnica baseada na indutância [59], e métodos baseados em redes neurais e lógica fuzzy.

A Figura 33 descreve um diagrama esquemático de tal classificação.

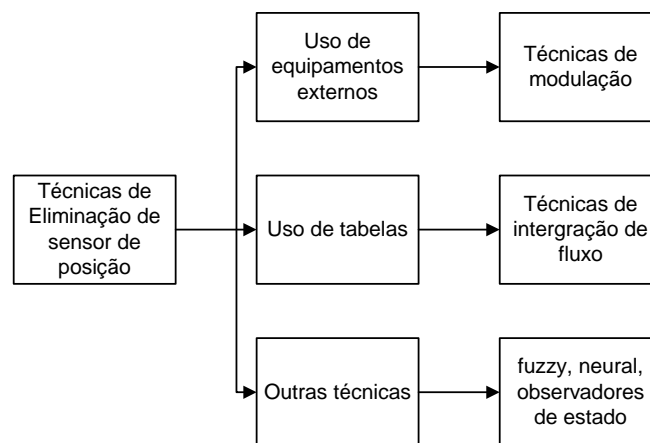


Figura 33 – Classificação das várias técnicas de eliminação de sensores

Os vários métodos sugeridos na literatura têm seus próprios méritos e deméritos, dependendo de seus princípios de operação. Idealmente, é desejável ter um esquema sem sensor, que use somente medidas terminais (tensão e/ou corrente) e não requiera hardware adicional ou grande capacidade de memória. Além disso, deseja-se ter a operação confiável em uma ampla faixa de velocidade. Entretanto, estas considerações não são totalmente disponíveis para muitos destes esquemas propostos. A curva característica torque-velocidade pode ser dividida em 5 regiões conforme ilustrado na Figura 34. Ela é aqui apresentada para facilitar a separação em classes dos diversos tipos de técnicas de eliminação de sensor de posição.




Figura 34 - Modos de operação em controle sem sensores de MRV.

Como é mostrado na Figura 34, abaixo da velocidade base (menor velocidade em que se pode extrair o máximo de potência) o torque permanece constante. Estas regiões oferecem a flexibilidade para o controle de corrente, dentro das limitações térmicas da máquina, permitindo obter a performance desejada para ela. Vale notar que nas regiões 1 e 2, a f_{cm} é muito menor que a tensão do barramento CC e pode ser negligenciada. À medida que a velocidade cresce, a FEM cresce e se torna maior que a tensão CC, e assim o motor deve começar a operar em pulso único (seção 2.5.1 Operação a pulso único) (região 4). Neste modo, a corrente é limitada pela FEM e não alcança valores de referência acima deste limite. Portanto, o controle de corrente não é possível e o torque é mantido no valor desejado pelo controle dos ângulos de energização e desenergização. Esta região 4 é chamada de “região de potência constante” por ser o torque inversamente proporcional à velocidade.

A operação na região 5, correspondente às ultra-altas velocidades, irá requerer algoritmos de alta eficiência no tempo, devido à limitação física para efetuar os cálculos do controle em tão alta velocidade.

Para se fazer uma classificação dos vários métodos de controle sem sensor, diversas formas de se escrever a equação de tensão para cada fase são consideradas. Esta sistematização é feita segundo níveis de velocidade apresentados na Figura 34.

Nos próximos itens abordaremos cada nível.

4.2 Região 1 – Velocidades Próximas a Zero

Nesta região e na região 2, a f_{cem} é muito pequena e como foi dito anteriormente, pode ser desprezada.

A equação da tensão nesta condição, sem saturação é:

$$V_j = Ri_j + L(\theta) \frac{di_j}{dt} \quad (17)$$

Há sempre, durante a seqüência de comutação, um intervalo de tempo onde determinada fase não está energizada. Durante este período, injeta-se um sinal de pulso de tensão no enrolamento com o objetivo de se medir a indutância. Dependendo do tempo de queda da corrente e de seu valor, pode-se estimar o valor da posição rotórica. Como limitações a estes esquemas de estimação estão os efeitos de correntes parasitas no núcleo do ferro da máquina e do acoplamento mútuo magnético entre as fases. Uma outra restrição é que esta estratégia produz torque de frenagem significativo.

Trabalhos mais recentes apresentam esta técnica combinada com observadores de estados [57]. O estudo inclui o que os trabalhos anteriores possuíam como limitação, o efeito das correntes parasitas, além do acoplamento magnético mútuo entre as fases do motor. A combinação desta técnica com um observador teve êxito; porém, como já mencionado, a amplitude da corrente de diagnóstico usada foi significativamente elevada a ponto de produzir torque de frenagem.

Sabendo-se a posição inicial do rotor e a direção desejada de rotação, a seqüência de rotação pode ser facilmente encontrada. Apesar desta técnica (injeção de sinal de tensão de diagnóstico) fornecer uma inicialização confiável para a MRV, é necessária uma tabela onde será armazenada a informação necessária de fluxo. Além disto, a operação sem sensores a baixa velocidade usando integração de fluxo é passível de acumulação de erros de posição, sendo necessário o uso em conjunto de outras técnicas, como a modulação de amplitude [50], durante o processo de inicialização. Esta técnica é bastante eficiente, porém, na forma que foi implementada neste artigo, apresenta a desvantagem de necessitar de um circuito externo, o qual adiciona mais custos e complexidade ao sistema. Uma alternativa viável para a implementação seria fazer a integração do fluxo computacionalmente, pelo próprio processador que faz o controle, dispensando o uso de circuitos externos ou sensores adicionais.

4.3 Região 2 - Velocidades muito baixas

Em [60], um método de medição das tensões é apresentado. O princípio de funcionamento é baseado na medição da tensão induzida em uma das fases desenergizadas. Esta tensão é induzida pela corrente que passa pela fase energizada, que dependendo da posição do rotor, faz variar a sua amplitude. Um circuito eletrônico captura este valor, que é processado por um microcontrolador a fim de se determinar os instantes de comutação.

O trabalho [61] é baseado na técnica apresentada em [60] e verificaram-se algumas restrições para a sua aplicação. O uso em operação *PWM* só deve ser feito em um limite de velocidade baixa devido aos termos dependentes do sinal de velocidade que aumentam o erro de posição estimado quanto maior a velocidade. Finalmente, devido à tensão induzida ser produzida somente quando o motor está girando, é necessário um algoritmo de inicialização em malha aberta. Depois que o motor alcança cerca de 15 rpm de velocidade este algoritmo é substituído pelo método sem sensor.

Esta região, como já foi dito no item anterior, possui baixa f_{cm} , ficando assim a equação de tensão:

$$V_j = Ri_j + \sum_{k=1}^m \left\{ i_k \frac{\partial L_{kj}}{\partial i_k} \frac{di_k}{dt} + L_{kj} \frac{di_k}{dt} \right\} \quad (18)$$

Onde L_{kj} representa a indutância mútua da fase k em relação à fase j .

O princípio básico desta técnica foi apresentado em [62]. A posição do rotor é detectada a partir da medição do tempo de crescimento ou decrescimento da corrente tanto em um enrolamento ativo quanto excitando um enrolamento de uma fase inativa.

Podemos dividir métodos de sensoriamento em dois tipos:

- Métodos de sensoriamento indireto se referem aos métodos que observam as correntes que produzem torque; são também chamados de métodos passivos, pois o sensoriamento não influencia de forma alguma o sistema.
- Métodos de sensoriamento direto se referem aos métodos onde há injeção de sinais nos enrolamentos das fases, também chamados de métodos ativos de sensoriamento.

Se escolhermos uma fase ativa para a medição da tensão, podemos negligenciar as indutâncias mútuas. Assim a equação (18) pode ser escrita como:

$$V_j = Ri_j + i_j \frac{\partial L_j}{\partial i_j} \frac{di_j}{dt} + L_j \frac{di_j}{dt} \quad (19)$$

A disponibilidade da função $L_j(i, \theta)$ juntamente com a medição terminal de i_j , V_j e di_j/dt nos possibilita a conversão da equação (19) em uma equação algébrica (23) para calcular θ [59].

$$a \cos \theta + b \cos 2\theta + c \sin \theta + d \sin 2\theta + e = 0 \quad (20)$$

$$\text{sendo } a = L_1 \frac{di}{dt}; b = L_2 \frac{di}{dt}; c = -L_1 i \frac{d\theta}{dt}; d = -L_2 i \frac{d\theta}{dt}; e = -V + Ri + L_0 \frac{di}{dt} \quad (21)$$

L_1 , L_2 e L_0 , são obtidas da expansão em série de Fourier de $L(i, \theta)$ apresentada na equação (22).

$$L(i, \theta) = L_0(i) + L_1(i) \cos N_r \theta + L_2(i) \cos 2N_r \theta \quad (22)$$

Assim sendo, a equação a ser utilizada é:

$$V_{sens} = Ri_j + \sum_{k=1}^m \left\{ L_{kj} \frac{di_k}{dt} \right\} \quad (23)$$

Durante o processo de chaveamento, a corrente na fase tem uma taxa de variação dependente do valor da indutância da fase neste instante. Assim, como a indutância é dependente da posição do rotor, podemos obter a posição através do processo de chaveamento. Existem diversas técnicas para este tipo de estimação, como, por exemplo o trabalho [63], onde duas técnicas de detecção são apresentadas: *WD (waveform detection)* e técnica *PWM*. Em ambas, o método de detecção é proposto de forma que a taxa de variação positiva da corrente de referência é modificada de forma adaptativa, dependendo da velocidade, de maneira a variar o ângulo de condução para cancelar o efeito da FEM. Existem ainda técnicas que trabalham com o tempo de decrescimento da corrente e também através de técnica combinada de controle *PWM* com modulação síncrona. O sistema pode se tornar complexo, mas a estimação de posição irá obter sucesso em uma ampla faixa de velocidade.

Entretanto, por causa do sinal de ruído presente na medição de corrente, técnicas de filtragem são necessárias, o que, por conseguinte, nos impõe o uso de processadores rápidos com adequada capacidade computacional.

Por outro lado, no sensoriamento direto, se escolhermos uma fase desenergizada para medirmos a tensão, devemos aplicar uma tensão de baixa amplitude como sinal de diagnóstico (para evitar a conseqüente geração de torque negativo).

Uma forma é a injeção de um sinal FM. Esta técnica é aplicada da seguinte forma: um oscilador de alta frequência é conectado ao enrolamento e é projetado para que a frequência seja inversamente proporcional à indutância de fase. A frequência é convertida em tensão e comparada com uma referência [51], [64].

O artigo [52] utiliza-se de um circuito ressonante R, L(θ), C, onde L(θ) é a indutância de fase que varia segundo a posição, de forma a termos uma frequência ressonante para $L_{\min}C\omega^2=1$, onde L_{\min} é a indutância mínima de fase.

Se escolhermos uma tensão de diagnóstico que minimize o efeito das mútuas [53], podemos escrever:

$$V_{sens} = Ri_j + L_j \frac{di_j}{dt} \quad (24)$$

Ao aplicarmos uma tensão senoidal, teremos uma corrente na fase desenergizada tal que:

$$i_{sens} = \frac{V_m}{\sqrt{R^2 + \omega_s^2 L_j^2(\theta)}} \text{sen} \left(\omega_s t - \text{tg}^{-1} \left(\frac{\omega_s L_j(\theta)}{R} \right) \right) \quad (25)$$

$$V_{sens} = V_m \text{sen}(\omega_s t) \quad (26)$$

A equação (25) apresenta intrinsecamente a idéia básica das técnicas de modulação. Como se pode constatar, a amplitude e a fase da corrente i_{sens} contém a informação da posição do rotor. Com esta informação podemos extrair a posição e usá-la para a comutação da máquina. Vale ressaltar que para a implementação deste método é requerido o uso de hardware externo ao sistema.

Analisando-se as equações (18) e (19) podemos também utilizar a proposta de usar como sinal de diagnóstico a tensão gerada pelas mútuas.

Fazendo-se (18) - (19) temos:

$$V_{mútua} = \sum_{k=1}^m \left\{ L_{kj} \frac{di_k}{dt} \right\}, \quad k \neq j \quad (27)$$

Nesta equação, a tensão terminal de diagnóstico representa a tensão induzida criada pelas mútuas. Como os fluxos possuem a informação de posição, a medição destas mútuas pode ser usada para comutar as fases do motor. É importante salientar que, o sucesso desta técnica está baseada na capacidade da estrutura magnética da MRV de gerar tensões mútuas significativas. Se por exemplo, o motor tiver grande superposição entre fases operadas sequencialmente, isto reduzirá significativamente a precisão do método. No entanto verifica-se que o valor das indutâncias mútuas costuma ser pouco significativo, da ordem de 2% da indutância máxima da fase.

4.4 Região 3 - Baixas velocidades (região de torque constante)

À medida que a velocidade aumenta, maior será a parcela de contribuição da FEM na MRV. Isto nos leva a utilizar a equação de tensão em sua forma original.

$$V_j = Ri_j + \sum_{k=1}^m \left\{ i_k \frac{\partial L_{kj}}{\partial i_k} \frac{di_k}{dt} + L_{kj} \frac{di_k}{dt} + i_k \frac{\partial L_{kj}}{\partial \theta} \omega \right\} \quad (28)$$

Como se pode ver, para esta situação também podemos usar fases não energizadas para obtermos o sinal de posição. As técnicas baseadas em sinais de diagnóstico começam no entanto, a apresentar limitações quanto à exatidão e precisão a partir deste nível de velocidade [53], pois o sinal não pode ser injetado em uma fase não energizada por muito tempo para que a corrente nela não atinja a região de torque negativo e isto ocorre em velocidades maiores onde a janela de tempo disponível fica muito pequena para detectar o sinal. Portanto, a utilização de técnicas que se aplicam a fases energizadas começa a ser indicada acima desta velocidade.

Uma aproximação bastante freqüente para eliminação de sensor de posição nesta faixa de velocidade é a integração de ambos os lados da equação de tensão (17):

$$\int_0^{T_s} (V_j - Ri_j) dt = L(i_j(T_s), \theta) i_j(T_s) \quad (29)$$

Esta equação pode ser usada junto com uma tabela contendo as características da MRV. A posição é estimada a partir da indutância obtida da relação tabelada entre fluxo e corrente. O cálculo é feito baseando-se nas relações de indutância/fluxo/corrente[54].

Pode-se equacionar para múltiplas fases de corrente, incluindo indutância mútua, porém aumenta-se a complexidade dos cálculos.

Uma alta resolução, neste caso, requer um considerável espaço de memória no controlador. Para superar esta dificuldade, a utilização de um modelo analítico de indutância na medição do fluxo é recomendável. Isto também mostra que esta técnica não deve ser utilizada a velocidades baixas devido a erros de integração gerados serem significativos.

O artigo [55] apresenta estimação de posição usando modelo de correção fluxo/corrente para a correção no erro de posição. A Figura 35 apresenta o diagrama do algoritmo proposto. V_{fase} é a tensão nas fases, i_m é a corrente medida, N_b é a melhor fase para a estimação, Ψ_c é o fluxo corrigido, Ψ_p é o fluxo estimado e θ_c é a posição corrigida.

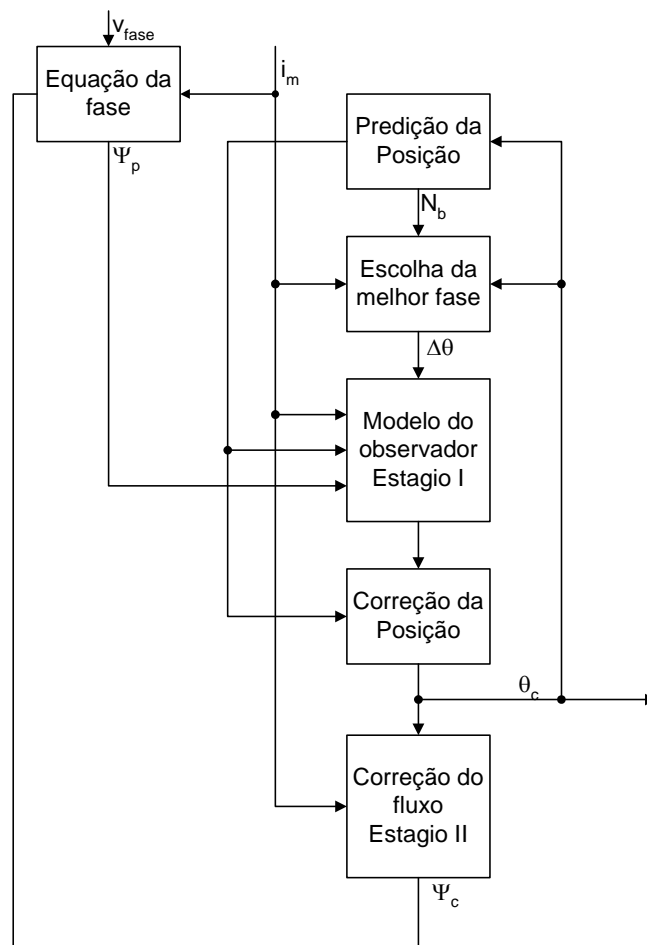


Figura 35 – Diagrama geral do algoritmo de estimação de posição

O método apresentado pelo artigo [65] para a estimação da posição do rotor é baseado na medição do fluxo e da corrente e caracteriza-se por uma ampla faixa de operação sendo aplicável tanto para baixas velocidades, quanto para altas. Ele compara o valor medido com o valor armazenado em uma tabela pré-calculada para obter o valor de posição. Como desvantagem podemos citar a necessidade de se injetar um pulso de corrente de diagnóstico em uma posição qualquer, durante o período de queda da indutância da fase em questão, o que gerará torque de frenagem nesta situação.

4.5 Região 4 - Altas velocidades

Na região de mais altas velocidades, a utilização de técnicas aplicadas a fases não energizadas não são mais possíveis, devido à excessiva força contra-eletromotriz. Em contrapartida, as técnicas de integração de fluxo são aplicadas com sucesso. Deve-se, no entanto, levar em consideração a redução da disponibilidade de tempo para os cálculos da estimação, para maiores velocidades da máquina. Isto força a reduzirmos o número de amostragens e pede por processadores mais rápidos. Além do mais, significantes superposições de fases vão aumentar os efeitos da indutância mútua que deteriorará a exatidão dos métodos clássicos de obtenção da força eletromotriz através da integração do fluxo.

Um método simples e direto para a eliminação do sensor de posição é o controle de malha aberta ou controle do ângulo de condução com sincronização. O método se baseia em controlar o tamanho deste ângulo com o objetivo de ter melhor performance [19]. Um aumento no ângulo possibilita ao controle, uma eficiente estabilidade diante de um distúrbio de torque, porém, ele degrada a eficiência devido ao torque negativo que é gerado. Por outro lado, se usarmos um ângulo pequeno, teremos uma melhor eficiência, entretanto a estabilidade fica comprometida. Não existe um único ângulo que provém um compromisso aceitável entre o torque marginal e a eficiência. Este método é bastante simples e barato, porém possui a desvantagem da instabilidade decorrente da malha aberta de controle.

A partir deste ponto de operação, torna-se evidente a observância de que as quantidades mecânicas (velocidade e posição) variam muito mais lentamente que as variáveis elétricas. Isto será de suma importância para ultra-altas velocidades.

4.6 Região 5 - Ultra-altas velocidades

Uma condição necessária para a operação sem sensores é termos as constantes de tempo mecânica, elétrica e de controle separadas numericamente uma das outras por uma margem razoável:

$$\tau_{\text{mec}} \gg \tau_{\text{elet}} \gg \tau_{\text{controle}} \quad (30)$$

A condição $\tau_{\text{mec}} \gg \tau_{\text{elet}}$ é observada em praticamente todas as aplicações. Entretanto, quanto maior a velocidade do motor, a velocidade do controlador se torna crítica.

Atualmente, o desenvolvimento dos *DSPs* tem permitido uma maior flexibilização quanto a condição $\tau_{\text{elet}} \gg \tau_{\text{controle}}$. A velocidade de processamento dos *DSPs* tem aumentado continuamente e já existem controladores que processam 200 milhões de instruções por segundo (MIPS).

Poucos trabalhos na literatura indicam mudanças significantes na forma de se operar sem sensores nestes níveis de velocidade.

O artigo [57] apresenta uma proposta de modelo não-linear do motor de relutância variável baseado em observadores. As tensões terminais são consideradas como entradas, as correntes são consideradas como as saídas e fluxo, velocidade e posição são os estados. São apresentados resultados para 3500 rpm. Como desvantagem, pode-se dizer que para este esquema de operação, há a necessidade de se utilizar equipamentos com maior velocidade de processamento.

O uso de observadores de estados em motores é bastante raro, tendo somente exceções na estimação de fluxo do rotor em motores de indução e na posição do rotor em motores de ímã permanente. Porém, com o desenvolvimento de *DSPs* mais rápidos, o uso de observadores de estados deverá crescer significativamente.. Para estes casos a detecção da posição de alinhamento e desalinhamento pela variação de fluxo ou de FEM é recomendada.

Como limitações da performance de algoritmos de alta velocidade temos as correntes parasitas a altas frequências de excitação e a complexidade computacional.

Existem outras técnicas além destas apresentadas anteriormente. Porém, cada uma delas é modelada para uma situação específica de operação. O artigo [66] apresenta a aplicação de

redes neurais para a identificação da velocidade de motores de indução. O artigo [67] também faz uso desta técnica de estimação de velocidade.

Para a aplicação em motores de relutância variável, podemos citar o trabalho [68] onde se modela um estimador com redes neurais para um motor de relutância linear. Para esta aplicação, onde somente uma fase é acionada por vez e onde se utiliza uma alimentação em *PWM*, obtém-se bons resultados para a estimação. O artigo [69] apresenta a estimação da posição utilizando um modelo do motor baseado em lógica *fuzzy*.

Como trabalhos recentes, temos a utilização das curvas de magnetização sendo modeladas por sistemas lógicos *fuzzy* ou por redes neurais [70]. A importância destas novas técnicas é a capacidade do modelo em se ajustar mais naturalmente às curvas reais de magnetização.

A comparação entre diversos tipos de estimadores inteligentes e suas implementações em um sistema DSP é apresentada no artigo [71].

4.7 Considerações Finais

Neste capítulo apresentou-se um conjunto de estratégias de eliminação de sensor de posição em um motor de relutância variável. Esta separação das técnicas se baseou nos diversos níveis de velocidade apresentados pelas MRV e tem essencialmente como princípio fundamental de operação, a variação do fluxo em função da posição angular do rotor.

No próximo capítulo, apresentamos o método de compensação das oscilações de torque no motor de relutância variável, cujo objetivo é reduzir as mesmas.

Capítulo 5

Controle com Compensação Automática das Oscilações de Torque da MRV

5.1 Considerações Iniciais

NOs dois capítulos anteriores foi apresentada uma revisão das técnicas de eliminação do sensor de posição e de redução de oscilações de torque em uma MRV. Neste capítulo propõe-se uma nova técnica de redução de oscilações de torque, baseada na compensação da corrente de referência, usando-se um sistema com aprendizagem *Neuro-fuzzy*. Deve-se realçar que o objetivo desta nova técnica proposta não consiste em obter-se uma maior minimização das oscilações quando comparado com as outras metodologias. Consiste sim na eliminação da necessidade de se ter o sinal de torque, além de que o compensador pode aprender a adaptar-se a variações paramétricas da máquina.

Uma maneira bastante popular e amplamente usada para se controlar a velocidade de um acionamento de relutância chaveado é utilizar um controlador PI. Entretanto, quando a entrada do controlador PI é zero, a sua saída será um valor constante, porém não nulo. Quando esta saída, em nosso caso, a referência de corrente, for introduzida no bloco do motor/conversor, ela gerará uma oscilação de torque, como consequência da dinâmica natural do sistema. Para evitar este problema, um sinal de compensação deve ser adicionado à saída do controlador PI, como é mostrado na Figura 36. Este sinal deve ser dependente da posição do rotor em relação ao estator e, ainda, é desejável que ele seja também dependente da velocidade e do valor do torque de carga. Como entradas, utilizou-se os sinais de velocidade, corrente e posição por serem eles sinais que melhor representam o que desejamos na saída do compensador.

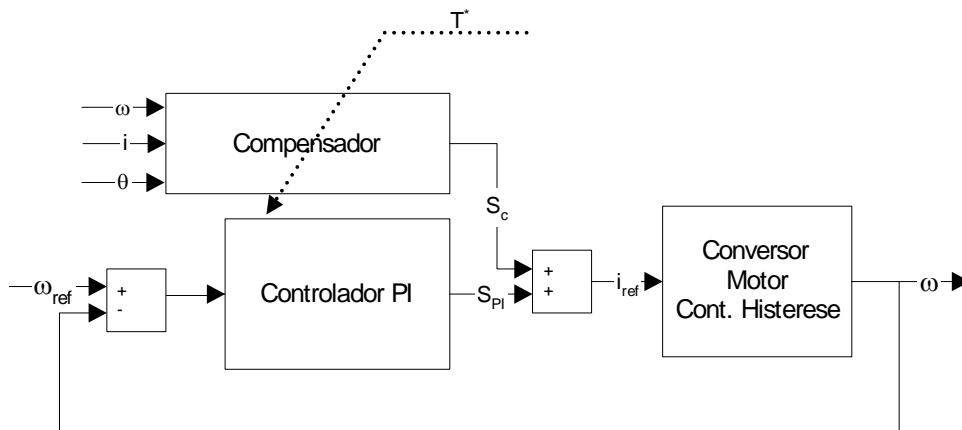


Figura 36 - Sistema com sinal de compensação

De fato, o sinal de compensação é uma função que possui alta complexidade matemática. Portanto, a geração deste sinal é bastante complicada. Alguns artigos [22], [31], [72], [73], [74] mostram diversas estratégias para se obter este sinal. Alguns autores ([5], [73]) utilizam a tabela da característica torque-posição-corrente e invertem sua relação. Se for necessário um torque específico, busca-se este valor na tabela e procura-se o valor correspondente de corrente. Em seguida, usa-se este valor no sistema para se obter o torque desejado.

A importância do controlador proposto está em possibilitar o seu treinamento através de sinais indiretamente vinculados aos sinais de entrada. Por exemplo, podemos usar a própria oscilação do torque para treinar a rede *Neuro-fuzzy* com o objetivo de se obter a corrente oscilante de compensação (Figura 37).

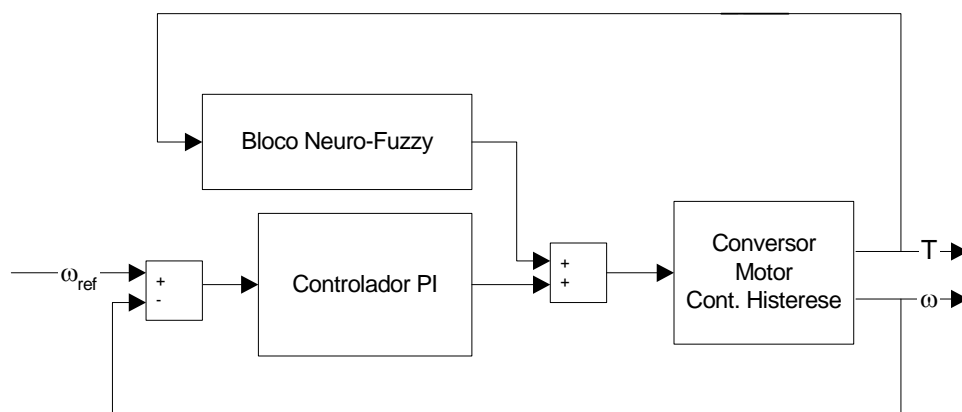


Figura 37 - Diagrama simplificado do controle PI tradicional com entrada única de torque no bloco do compensador *Neuro-fuzzy*.

No caso de termos um sistema já em operação e desejarmos incluir o compensador *Neuro-fuzzy*, basta adicionarmos a saída do mesmo ao sinal de corrente do controlador PI.

5.2 Controlador de Velocidade PI

A implementação do controlador PI foi feita aplicando-se no controlador, como entrada, o erro de velocidade e obtendo-se na saída a corrente de referência, sendo este sinal um dos utilizados pelo acionamento para escolher qual chave irá conduzir ou não [75]. O sistema de controle que rege o controlador PI é apresentado na equação (31). O diagrama reduzido do controle está mostrado na Figura 38.

$$i_{ref} = \left(k_p + \frac{k_i}{s} \right) e \omega \quad (31)$$




Figura 38 - Controlador PI Tradicional

Para ilustrar a operação do controlador PI apresentamos a Figura 39 onde é mostrada a corrente em uma das fases para o controle de velocidade em 500 rpm e θ_{off} igual a 27° . O controle de corrente é feito com CR-PWM.




Figura 39 - Curva de corrente, com controle PI Tradicional(1A/div)

5.3 Compensador *Neuro-fuzzy*

Neste trabalho, devido à capacidade de aprendizagem do compensador, o controle possui uma maior flexibilidade de operação. Este aprendizado torna o compensador mais independente das características do motor. Se o sistema sofrer alguma modificação paramétrica no valor da carga acoplada, na alimentação, ou na velocidade de operação, o compensador possuirá a habilidade de adaptar-se para operar neste novo ponto de operação, buscando a redução das oscilações de torque desejada.

A estratégia proposta para produzir este sinal de compensação é adicionar ao sistema de controle PI tradicional, mecanismos de aprendizagem [76], [77].

O controle proposto consiste em usar um sistema de aprendizagem *Neuro-fuzzy* cuja saída é adicionada ao sinal da saída do controlador PI tradicional [78], como é mostrado na Figura 40. Como sinais de entrada para o compensador utiliza-se o sinal de velocidade do motor, a posição do rotor e a corrente de referência, pois pode-se observar a partir de experimentos ou simulações que existe forte correlação entre estas variáveis e as oscilações de torque. Esta flexibilidade é muito interessante para situações onde não se têm disponíveis, através dos sensores, todos os sinais para o treinamento.

Não é objetivo do compensador *Neuro-fuzzy* substituir o controlador PI. A proposta é colocá-los operando em paralelo. O compensador não tem a intenção de fazer o controle de velocidade e sim melhorar a qualidade do torque, fazendo-o menos oscilante. Obviamente, que ao melhorarmos o sinal de torque, estaremos facilitando a resposta do controle do PI indiretamente. Percebeu-se através de testes que o compensador acaba fazendo um ajuste fino do controle de velocidade. As pequenas não-linearidades não controláveis pelo controlador PI são tratadas de forma bastante satisfatória pelo compensador.

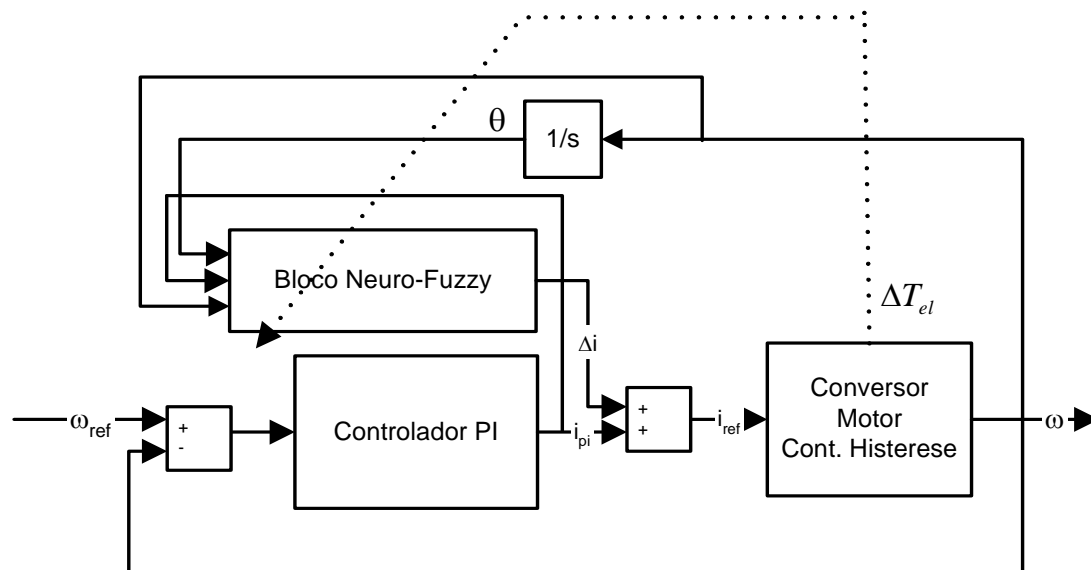


Figura 40 - Diagrama simplificado do controle PI tradicional com o bloco do compensador *Neuro-fuzzy*

No trabalho anteriormente desenvolvido por Henriques et al. [79], é apresentada uma compensação com treinamento *offline* de corrente utilizando o método proposto por Jang [80]. Uma desvantagem deste trabalho é de sempre termos a necessidade de refazer o treinamento quando houver alguma variação nos parâmetros da máquina.

Nesta tese é dado um passo adiante no desenvolvimento. Com uma mesma estratégia de compensação, porém em situações de atualização de sinais diferentes, apresentamos uma compensação *online* para a redução da oscilação de torque na MRV, em duas situações distintas: compensação com uso do sinal de torque e sem este sinal. Na primeira situação, trabalha-se com a parte oscilante do torque ΔT_{el} (torque total - torque médio), enquanto que na segunda situação, usa-se o sinal de erro de velocidade. Este trabalho apresenta duas contribuições diferentes para o compensador nestas duas situações distintas, porém com uma única estratégia de compensação. A desvantagem da primeira abordagem é a necessidade de se usar o sensor de torque ou o seu sinal estimado como forma de atualização do sistema.

A maioria dos trabalhos publicados sobre este assunto apresentam o uso de sensor ou de um observador/estimador de torque; sendo assim, a proposta principal deste trabalho é evitar o uso de qualquer uma destas estratégias [81].

A utilização de um sensor de torque só é viável economicamente se pudermos realizar um treinamento *offline* do sistema, em laboratório, com o objetivo de determinar os parâmetros

do compensador. O sensor de torque é bastante caro para mantê-lo constantemente ligado a um único sistema, operando em uma instalação industrial. Outra possibilidade é fazer um controle em tempo real, estimando o sinal de torque do motor, ou então utilizando o sinal de erro de velocidade para se obter indiretamente uma estimativa da magnitude das oscilações no torque, as quais se refletem no sinal da velocidade.

Na segunda situação, sem sensor de torque, há a vantagem de não precisarmos ter conectado ao motor um torquímetro ou dinamômetro, ou de utilizar qualquer estimativa de torque; porém, o sinal de atualização do sistema, obtido indiretamente do erro de velocidade, não possui tanta informação sobre a oscilação do torque quanto o próprio sinal de torque. Consequentemente, necessitamos de um maior tempo de treinamento e de uma taxa de aprendizagem bem pequena para manter o sistema estável, como se irá evidenciar nos resultados das próximas seções.

5.4 Treinamento e Operação

5.4.1 Introdução

A compensação *Neuro-fuzzy* é apresentada neste item como um método de aprendizagem de regras através de exemplos. No caso mostrado, utiliza-se um modelo matemático representativo de uma rede neural cujos neurônios representam funções de pertinência de um sistema lógico *fuzzy*.

Para o bom entendimento de todo o processo *Neuro-fuzzy*, apresentaremos na próxima seção a teoria geral da modelização do treinamento.

5.4.2 Modelização por aprendizagem supervisionada

As características principais deste algoritmo de aprendizagem supervisionada [82] são:

- Utiliza funções de pertinência gaussianas que permitem que a aprendizagem, usando-se todos os exemplos, seja feita em todo o universo de discurso.
- O uso de funções gaussianas elimina o problema do aparecimento de regras para as quais não se pode retirar nenhuma conclusão do conjunto de treino.

- A conclusão de cada regra é ajustada pelo método do gradiente com o objetivo de minimizar o valor do erro médio quadrático.

Esta técnica é um mecanismo de aprendizagem supervisionada para a extração do valor de conclusão de cada regra, ou também chamada técnica *Neuro-fuzzy* [83]. Esta técnica é assim chamada por basear-se num modelo híbrido, onde se permite a utilização de técnicas de otimização para a aprendizagem, por exemplo, gradiente descendente para a extração das regras. Desta forma, acoplou-se algoritmos geralmente usados em mecanismos de redes neurais com os conceitos lingüísticos introduzidos pelos conjuntos *fuzzy*.

Nesta topologia, as funções de ativação dos neurônios são as funções de pertinência do tipo gaussiana modeladas para operarem em todo o universo de discurso.

O mecanismo de aprendizagem pode ser representado pelo esquema apresentado na Figura 41. Na primeira camada, as entradas numéricas (no nosso caso corrente, posição e velocidade) são codificadas em valores lingüísticos pelo conjunto de funções de pertinência gaussiana de cada um de seus universos de discurso.




Figura 41 – Diagrama de camadas do mecanismo de aprendizagem

A segunda camada calcula o grau de ativação de cada uma das regras e finalmente na terceira camada, é feito o processo de inferência, onde cada grau de ativação pondera a saída de cada regra.

O sinal de erro entre o valor desejado de torque e o valor obtido para esta saída é então utilizado pelo método de gradiente descendente para ajustar os pesos sinápticos da saída.

O erro médio quadrático é apresentado como:

$$E = \frac{1}{2} [Y(x'(k)) - y'(k)]^2 \quad (32)$$

O método do gradiente modifica os valores de $\omega^{(l)}$ de maneira a minimizar esta função objetivo E. Na expressão (32), $y'(k)$ é o valor desejado de torque e $Y(x'(k))$ é o valor obtido com a saída do sistema calculado pelo modelo para o conjunto de entradas $x'(k)$.

A saída $Y(x'(k))$ é descrita como:

$$Y(x'(k)) = \frac{\sum_{l=1}^c \left(\prod_{j=1}^m \mu_{A_j^{(l)}}(x'_i(k)) \right) \omega^{(l)}(k)}{\sum_{l=1}^c \left(\prod_{j=1}^m \mu_{A_j^{(l)}}(x'_i(k)) \right)} \quad (33)$$

Esta equação juntamente com a equação (34), estabelecem o ajuste da conclusão de cada regra pelo método do gradiente.

$$\omega(k+1) = \omega(k) - \alpha \frac{\partial E}{\partial \omega} \quad (34)$$

α é a taxa de aprendizagem utilizada, e k indica o número da iteração que o algoritmo de aprendizagem já efetuou. O valor de ω é obtido da variação do erro médio quadrático segundo a variação de ω no passo anterior.

O numerador da equação (33) é designado por a e apresenta a seguinte forma:

$$a = \sum_{l=1}^c \left(\prod_{j=1}^m \mu_{A_j^{(l)}}(x'_i(k)) \right) \omega^{(l)}(k) \quad (35)$$

enquanto seu denominador pode ser escrito como b dependente do termo $d^{(l)}$:

$$b = \sum_{l=1}^c (d^{(l)}) \quad (36)$$

$$d^{(l)} = \prod_{j=1}^m \mu_{A_j^{(l)}}(x'_i(k)) \quad (37)$$

A obtenção de $\frac{\partial E}{\partial \omega}$, através da regra de derivação composta, é realizada pela multiplicação das 3 derivadas parciais:

$$\frac{\partial E}{\partial \omega} = \frac{\partial E}{\partial Y} \frac{\partial Y}{\partial a} \frac{\partial a}{\partial \omega} \quad (38)$$

Obtendo-se a expressão:

$$\frac{\partial E}{\partial \omega} = \frac{[Y(x'(k)) - y'(k)]d^{(l)}}{b} \quad (39)$$

As funções de pertinência gaussianas são assim representadas:

$$\mu_{A_i^j}(x_i') = a_i^j \exp \left[-\frac{1}{2} \left(\frac{x_i' - b_i^j}{c_i^j} \right)^2 \right] \quad (40)$$

sendo a_i^j o valor máximo da função gaussiana, b_i^j o centro da função gaussiana e c_i^j a abertura da função

6.4.3 Processo de Treino e Operação

A descrição de todo o processo de treinamento e operação *online* é apresentada a seguir. O bloco de compensação implementado no Simulink/Matlab [84] e apresentado na Figura 40 como bloco *Neuro-fuzzy* possui como entradas, os seguintes sinais:

- 1) Posição do rotor em graus
- 2) Corrente em Ampères
- 3) Velocidade do motor em rpm
- 4) O sinal de erro do treino que pode ser o valor oscilante do torque ou o erro de velocidade (isto depende essencialmente da estratégia a ser seguida - resultados para as duas estratégias serão apresentados).
- 5) Um sinal de *flag* que habilita, ou não, o treino do sistema de compensação (este *flag* poderá ser usado na técnica do sinal de erro de velocidade para suspender temporariamente

o treino quando houver variação significativa da referência de velocidade, ou seja, mesmo que o sistema de treinamento perceba um aumento do erro de velocidade, isto não significará que o motor apresentou uma maior oscilação de torque, somente, que ocorreu a variação da referência de velocidade). Este *flag* permite ainda interromper a qualquer momento o treino sem que seja necessário interromper a compensação.

Como saída do compensador tem-se um incremento de corrente de compensação em Ampères.

O sistema de compensação possui flexibilidade quanto ao número e tipo de função de pertinência para cada entrada, ou seja, se houver necessidade de colocarmos para uma entrada específica um número diferente de funções ou um tipo de função de pertinência diferente, isto é possível ser implementado.

No primeiro caso estudado, 3 funções de pertinência para cada uma das 3 entradas foram usadas. No segundo caso, 7 funções foram usadas. Para ambos os casos, as funções de pertinência são do tipo gaussianas. Como foi apresentado anteriormente, a escolha do perfil das funções foi feita para permitir que, para qualquer valor de entrada, exista sempre regras que possam extrair alguma conclusão do conjunto de treinamento.

Como o sistema deve operar em tempo real, a cada instante de amostragem, um conjunto de dados composto pelas 5 entradas já apresentadas é aplicado ao compensador.

Primeiramente, as variáveis e constantes utilizadas são inicializadas: as funções de pertinência, além dos parâmetros de treinamento como o número de funções de pertinência, a taxa de aprendizagem e o tempo de amostragem.

Após a inicialização, o sistema de acionamento é simulado até um tempo pré-determinado, aqui chamado de critério de parada. Durante todo o período de simulação, os parâmetros do controlador são atualizados com intervalos de amostragem de 1ms. O tempo de execução da rotina de interrupção é dependente da carga computacional introduzida pelo sistema *Neuro-fuzzy*, ou seja, principalmente do número de funções de pertinência atribuídas às entradas e ao número de entradas utilizadas. Depois de decorrido o tempo de simulação, busca-se os resultados para a análise.

A seqüência do treinamento e da operação é apresentada abaixo:

-
- a) Carregamento das variáveis: Nesta etapa, inicializa-se todas as variáveis necessárias para a operação do sistema, bem como se define as constantes para a comunicação da placa de aquisição de dados. Nesta fase, atribui-se os valores de taxa de aprendizagem, quantidade de funções de pertinência, seus universos de discurso e seus tamanhos. Além disto, designa-se aqui nesta etapa, os parâmetros do controlador PI e quais variáveis serão usadas para armazenar os dados treinados e os de saída.
- b) Cálculos do sistema de treinamento: Nesta fase, calcula-se com base nos dados carregados na etapa anterior, os centros e comprimentos de cada função de pertinência, além de se calcular os pesos das regras do sistema *Neuro-fuzzy*.
- c) Rotina de interrupção: Nesta etapa, o sistema entra em uma malha fechada de treinamento onde seqüencialmente:
- c.1 - Calcula-se a saída do regulador de velocidade PI
 - c.2 - Lê-se o valor da posição do rotor através do sensor de posição.
 - c.3 - Calcula-se a velocidade
 - c.4 - Lê-se o valor de corrente de referência calculado no controlador analógico de corrente
 - c.5 – De posse dos dados calculados e medidos anteriormente, escolhe-se qual fase da MRV deve ser acionada.
 - c.6 – Estima-se o torque usando-se a técnica apresentada no apêndice C.
 - c.7 – Nesta fase, inicia-se o treinamento *Neuro-fuzzy online*. O sistema tem como entradas (corrente, velocidade e posição) e como saída o sinal adicional de corrente. Esta fase de treino/operação pode ser descrita como:
 - c.7.1 – Inicialmente fuzzifica-se as entradas
 - c.7.2- Gera-se a matriz com os graus dos antecedentes para produzir a inferência
 - c.7.3 – Desfuzzifica-se aplicando a técnica de centro de gravidade.

c.7.4 – Ajusta-se as regras usando-se o sinal de erro e a taxa de aprendizagem.

c.8 – Finalmente, soma-se o sinal adicional com o sinal de saída do controlador PI, produzindo o sinal de referência total que será enviado para o controlador de corrente analógico.

d) Para concluir, grava-se os dados de saída obtidos para posterior análise.

O fluxograma da Figura 42 apresenta de forma gráfica todo o processo.

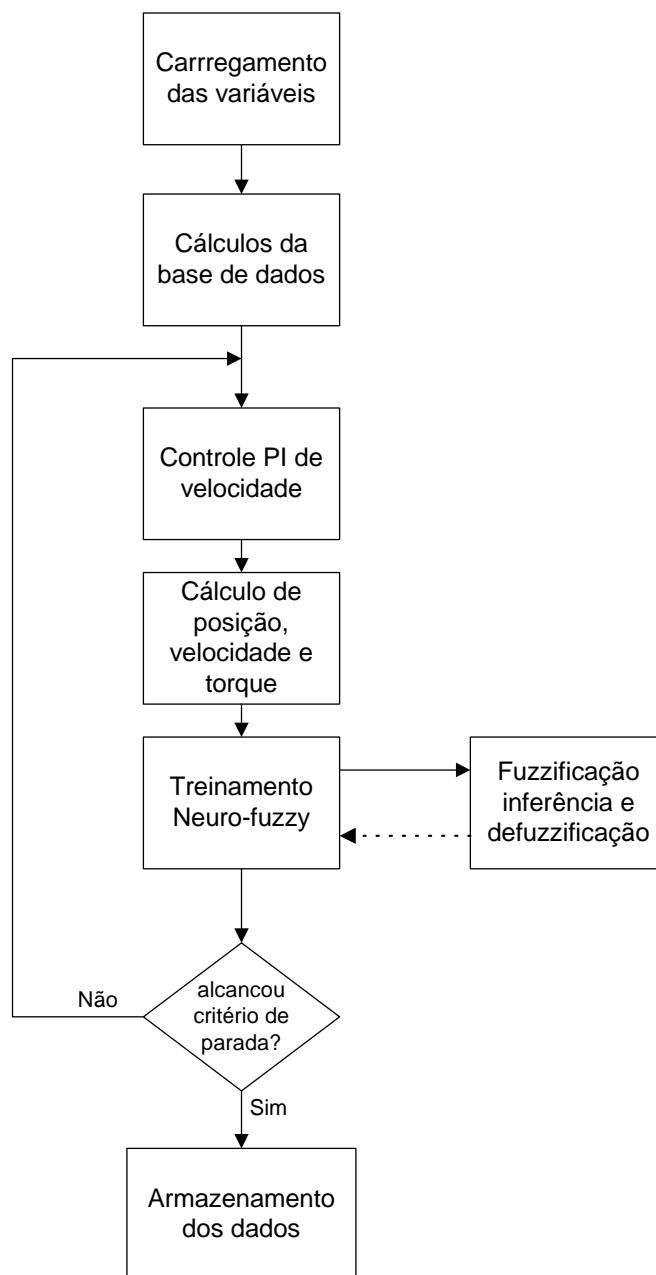


Figura 42 – Fluxograma do Programa de Treinamento

Formalizaremos abaixo todas as etapas do algoritmo de treinamento:

Fase 1: Inicialização das funções de pertinência (centros, valores máximos e aberturas das funções), os limites dos universo de discurso (limite negativo, limite positivo e centro do universo de discurso) bem como o número de funções de pertinência para cada variável de entrada. As variáveis a_i^j , b_i^j , e c_i^j são estabelecidas neste momento (equação (40)).

Fase 2: Estabelecimento dos valores de saída (conseqüentes) das regras, ω . No nosso caso, este valor é constante para todas as saídas. Sempre começamos um treinamento novo com estes pesos fixos em 0,1.

Fase 3: Esta fase é o início do treinamento *online*. O conjunto de entradas k (corrente, posição e velocidade) é adquirido e expresso como: $(i(k), \theta(k), \omega(k)) \rightarrow \Delta i(k)$. A obtenção deste conjunto de entradas é feita a cada iteração do processo, quando o programa de treinamento recebe os valores das variáveis vindas do sistema de aquisição de dados.

Numa primeira iteração, as entradas são fuzzificadas através da função de pertinência apresentada na equação (33). É nesta rotina que se define a função gaussiana.

Fase 4: Nesta fase, calcula-se o grau dos antecedentes de cada regra em uma matriz. Constrói-se uma matriz com estes dados.

$$\text{matriz} = \sum_{i=1}^3 \left(\prod_{j=1}^3 \mu_{A_j^{(i)}}(x'_i(k)) \right) \quad (41)$$

Fase 5: Defuzzifica-se o sistema através da técnica do centro de gravidade para se obter o valor final Δi .

$$\Delta i(k) = \frac{\int \left(\prod_{i=1}^3 \mu_{A_j^{(i)}}(x'_i(k)) \right) \omega^{(i)}(k) d\Delta i}{\int \left(\prod_{j=1}^3 \mu_{A_j^{(i)}}(x'_i(k)) \right) d\Delta i} \quad (42)$$

Porém, podemos discretizar os valores da defuzzificação, fazendo uma aproximação e substituindo as integrais por somatórios.

$$\Delta i(k) = \frac{\sum_{i=1}^3 \left(\prod_{j=1}^3 \mu_{A_j^{(i)}}(x'_i(k)) \right) \omega^{(i)}(k)}{\sum_{i=1}^3 \left(\prod_{j=1}^3 \mu_{A_j^{(i)}}(x'_i(k)) \right)} \quad (43)$$

Fase 6: Após obtermos este dado numérico de Δi , soma-se o mesmo ao sinal produzido pelo controlador PI. Esta corrente será a referência do sistema, o valor de torque obtido para esta corrente será comparado com o torque desejado.

Após esta comparação, obtemos o valor de erro que será utilizado para modificar as regras segundo o método do gradiente.

$$E_{\text{torque}} = \frac{1}{2} [T - T^*]^2 \quad (44)$$

Fase 7: Com este valor de erro aplicamos o ajuste *online* da regras da seguinte forma:

$$\omega^l(k+1) = \omega^l(k) - \alpha \cdot (T - T^*) \cdot \frac{\prod_{j=1}^3 \mu_{A_j^{(l)}}(x'_i(k))}{\sum_{l=1}^3 \left(\prod_{j=1}^3 \mu_{A_j^{(l)}}(x'_i(k)) \right)} \quad (45)$$

Fase 8: Caso não tenha sido alcançado o erro mínimo escolhido, ou o critério de parada do treino não tenha sido também alcançado, o algoritmo recomeça novamente na fase 3 com novos sinais coletados (k+1).

5.5 Resultados

Nesta seção apresentaremos resultados do sistema simulado, bem como algumas considerações sobre as duas estratégias e as restrições nelas encontradas.

5.5.1 Método com sinal de torque

Os resultados obtidos utilizando-se o sinal de torque como sinal de erro para a atualização do sistema de compensação são apresentados para duas velocidades: 200 rpm e 50 rpm, validando a importância deste método para baixas velocidades, onde as oscilações de torque são mais significativas. O valor de 50 rpm foi escolhido como sendo o limite

inferior de velocidade que o motor opera sem que a FCEM corrompa a operação da máquina. O objetivo de se apresentar o sinal de torque para estas duas velocidades é para mostrar a capacidade do compensador em fazer a minimização da oscilação de torque. Não existe carga conectada a nenhum dos dois sistemas. Os valores de torque de cada um dos sistemas são distintos e não há intenção de comparar os dois sistemas quanto ao torque. A condição nominal de operação desta máquina é para 1800 rpm e 5 A, portanto temos o nosso sistema operando fora da faixa nominal de operação (50 e 200 rpm e sem carga)

O sistema para 200 rpm foi simulado por 0,6 s com início da aprendizagem em 0,2 s. O resultado de corrente obtido para 200 rpm é apresentado na Figura 43.




Figura 43 – Corrente de fase – Taxa de Aprendizagem 0,3 – 200 rpm




Figura 44 – Torque Total – Taxa de Aprendizagem 0,3 – 200 rpm

O sistema básico ficou modelado com taxa de aprendizagem de 0,3 e 3 funções de pertinência para cada uma das três entradas (corrente, posição e velocidade).

Observa-se na Figura 44 que, imediatamente após a entrada da compensação a oscilação de torque diminui. O fato de obtermos maior oscilação de corrente (Figura 43) nos dá torque com menor oscilação. Um motivo a ser analisado para explicar este comportamento, é que a máquina em questão opera sob influência da saturação.

O erro médio quadrático inicia neste ponto uma queda bastante abrupta em seu valor como se verifica na Figura 45. Este sinal de erro médio quadrático é obtido do valor oscilante de torque. O erro de velocidade (Figura 46) nos mostra uma envoltória no erro de velocidade de aproximadamente 1 rpm antes da compensação; após um período de regime transitório cai para 0,1 rpm, demonstrando que o sistema está compensando a corrente.

Os resultados para 50 rpm são apresentados a seguir. Para este caso, foram simulados 1,5 s e o início do treinamento ocorre em 0,6 s.




Figura 45 – Erro Médio Quadrático – Taxa de Aprendizagem 0,3 – 200 rpm

Para a velocidade de 50 rpm encontramos a mesma situação de resultados obtidos para a velocidade de 200 rpm. A Figura 47 apresenta a corrente na fase a, como nos casos anteriores, em 0,5 segundos a compensação começa a operar. A oscilação de torque sofre uma redução bastante acentuada como pode ser visto na Figura 48. Temos um período de transitório na velocidade e em seguida o sistema tende para um regime permanente, onde teremos o erro de velocidade oscilando em torno do erro de velocidade nulo (Figura 49).




Figura 46 – Erro de Velocidade – Taxa de Aprendizagem 0,3 – 200 rpm




Figura 47 – Corrente de fase – Taxa de Aprendizagem 0,3 – 50 rpm




Figura 48 – Torque Total – Taxa de Aprendizagem 0,3 – 50 rpm




Figura 49 – Erro de Velocidade – Taxa de Aprendizagem 0,3 – 50 rpm

5.5.2 Método sem sensor de torque

Para esta metodologia onde não se usa o sensor de torque, nem se estima o seu valor para a obtenção do sinal de torque, utiliza-se apenas o sinal de erro de velocidade como apresentado anteriormente. A escolha se deve ao fato da variação de velocidade ser a aceleração da máquina, e consequentemente a aceleração é proporcional ao torque. Para esta condição, apresentamos os resultados obtidos para 50 rpm a seguir (Figura 50 e Figura 51).




Figura 50 – Corrente de fase – Taxa de Aprendizagem 0,001 – 50 rpm




Figura 51 – Torque Total – Taxa de Aprendizagem 0,001 – 50 rpm




Figura 52 – Erro médio quadrático da velocidade – Taxa de Aprendizagem 0,001 – 50 rpm

Observa-se na Figura 52 que a redução das oscilações de torque é apresentada pela curva do erro médio quadrático.

5.5.3 Considerações sobre a metodologia

Para a obtenção dos resultados apresentados, foram necessárias algumas análises anteriores. Inicialmente analisamos a influência da taxa de aprendizagem para o sistema. O valor numérico da taxa de aprendizagem está intimamente ligado à rapidez com que o sistema ajusta os pulsos de corrente, de modo a reduzir as oscilações de torque.

Os valores inicialmente usados foram: 0,001, 0,1 e 1. Para 0,001 o treinamento ficou excessivamente lento (Figura 53 e Figura 54) e para a taxa de valor unitário, o sistema se instabilizou. Portanto, utilizou-se o valor de 0,1 para a taxa de aprendizagem (Figura 55 e Figura 56). O significado deste valor está em permitir uma aprendizagem mais rápida ou mais lenta do sistema. Porém, uma aprendizagem muito rápida pode gerar a instabilidade encontrada no caso em que a taxa de aprendizagem é de 1.

Para estes estudos, o tempo de simulação foi de 0,8 s, com o início da aprendizagem em 0,25 s em uma velocidade de referência de 200 rpm.




Figura 53 – Corrente de fase – Taxa de Aprendizagem 0,001 – 200 rpm




Figura 54 – Torque Total – Taxa de Aprendizagem 0,001 – 200 rpm

Comparando os perfis de corrente (Figura 53 e Figura 55), podemos ver que o formato da curva de corrente (Figura 55) sofre uma mudança bastante nítida em sua curva em relação à Figura 53. Isto se deve ao maior valor da taxa de aprendizagem.




Figura 55 – Corrente de fase – Taxa de Aprendizagem 0,1 – 200 rpm




Figura 56 – Torque Total – Taxa de Aprendizagem 0,1 – 200 rpm

O próximo teste consistiu em variar o número de funções de pertinência mantendo a taxa de aprendizagem em 0,1. Foi feito o estudo para 3 funções de pertinência, 5, 7 e 11 funções, sendo que o número de funções é igual para cada uma das variáveis (Figura 57) . O estudo detalhado da quantidade de funções de pertinência está baseado na capacidade de representação do universo de discurso para cada uma das entradas.




Figura 57 – Erro médio quadrático para diversos números de funções de pertinência

Podemos observar que o melhor valor foi de 3 funções de pertinência para todas as entradas, mas torna-se necessário analisar combinações de números de funções para diferentes valores em cada entrada.

Combinações diversas variando de 3 a 11 funções para cada entrada foram testadas (Figura 58). A que apresentou melhor resultado através do erro médio quadrático do sinal de treino foi de 3 funções para cada entrada (Figura 59).

É importante salientar na Figura 58 que antes de 40 pontos temos uma certa oscilação do valor do erro médio quadrático devido ao erro de velocidade que se torna constante durante todo o período que antecede o início do treinamento.




Figura 58 – Erro médio quadrático para diversos números de funções de pertinência




Figura 59 – Zoom da Figura 58

Observando a Figura 60, podemos concluir que a taxa de aprendizagem de 0,3 apresenta uma melhoria em relação à de 0,1. Portanto, deste ponto do trabalho em diante, usaremos esta taxa.




Figura 60 – Estudo entre 0,1 e 0,3 para taxa de aprendizagem

Para o sistema sem sensor de torque (item 5.5.2), o sinal de erro de velocidade é usado para obter a informação da oscilação de torque. Como no primeiro caso, analisamos inicialmente a influência da taxa de aprendizagem para o sistema.

Os valores inicialmente usados foram: 0,0005, 0,01 e 0,1. Como no caso anterior, para 0,0005 o treinamento ficou excessivamente lento e para a taxa de valor 0,1, o sistema se instabilizou.

Consequentemente, adotou-se o valor de 0,01 e foi desenvolvida toda uma série de estudos para se obter a quantidade ideal de funções de pertinência.

Devemos ter em mente que grandes variações na velocidade de referência podem ser entendidas pelo compensador como variações de torque. Portanto, devemos tomar certas precauções em não acionarmos o treinamento durante mudanças bruscas na referência de velocidade.

5.6 Operação da MRV com Compensação *Neuro-fuzzy* de corrente sob condição de interrupção em uma das fases da máquina.

Este item tem como objetivo confirmar a capacidade do motor de relutância variável operar sem uma das fases, dentro das condições de operação do sistema de compensação *neuro-fuzzy*.

Apesar da MRV ter uma boa tolerância a faltas, em certas ocasiões, a falha em uma de suas fases pode comprometer a sua operação. Com a presença do compensador para a minimização das oscilações de torque operando, percebeu-se que quando da ocorrência da falta em uma das fases, o compensador contribui na melhoria do perfil de torque.

A operação deste caso foi feita da seguinte forma: foi inserido entre o enrolamento de uma fase e uma das chaves semicondutoras (IGBT) uma chave interruptora para que pudéssemos interromper a qualquer momento a operação da fase elétrica (Figura 61). A carga será uma lâmpada de 100W – 127V conectada ao motor através de um gerador.

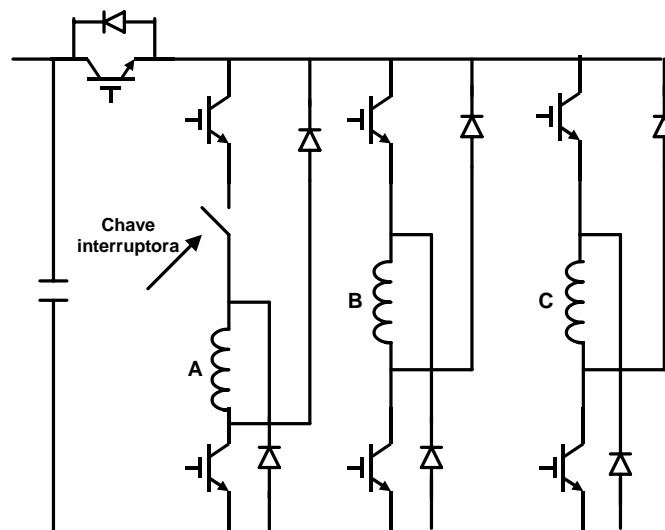


Figura 61- Circuito do conversor modificado com inclusão de chave interruptora

5.6.1 Resultados obtidos e casos estudados.

Primeiramente o motor foi operado sem uma das fases até aproximadamente 5 segundos. Após este instante, permitiu-se que a fase em falha voltasse a funcionar. Os três próximos gráficos apresentam este experimento (Figura 62, Figura 63 e Figura 64). O sistema opera com velocidade de 100 rpm, 9 funções de pertinência para cada entrada e taxa de aprendizagem de 0,0001. É importante salientar que os resultados abaixo começaram a ser armazenados após o motor estabilizar a operação sem a fase.




Figura 62 - Torque interpolado no momento de entrada da fase




Figura 63 - Corrente em uma fase no momento de entrada da fase




Figura 64- Corrente em uma fase no momento de entrada da fase

Podemos observar uma ligeira redução do nível CC da corrente de referência após os 4 segundos quando a terceira fase começa a operar. Isto é esperado pois neste resultado temos a contribuição de corrente das 3 fases. Anteriormente, o controle de velocidade

necessitava de mais correntes nas fases restantes do que posteriormente quando da operação do motor com as 3 fases em funcionamento pleno. O controle de velocidade para este estudo é o mesmo utilizado nos casos anteriores, um controlador PI de velocidade.

Para fazer um estudo mais comparativo do sistema com duas ou três fases e com e sem treinamento, os seguintes casos foram estudados:

- 1) Sem carga {
 - 2 fases { Com treino
 - { Sem treino
 - 3 fases { Com treino
 - { Sem treino

- 2) Com carga {
 - 2 fases { Com treino
 - { Sem treino
 - 3 fases { Com treino
 - { Sem treino

5.6.2 Resultados

Inicialmente operamos experimentalmente sem a carga (lâmpada) e com treino em funcionamento. Os itens a e b apresentam os resultados para as duas situações propostas: com 3 fases e com 2 fases. Os sinais de torque são obtidos segundo a estratégia apresentada no apêndice C.

a) Sem carga, com 3 fases e com treino.




Figura 65 – Velocidade na operação do motor com 3 fases, sem carga e com treinamento




Figura 66 - Torque na operação do motor com 3 fases, sem carga e com treinamento




Figura 67 - Correntes na operação do motor com 3 fases, sem carga e com treinamento

b) Sem carga, com 2 fases e com treino.




Figura 68 - Velocidade na operação do motor com 2 fases, sem carga e com treinamento




Figura 69 - Torque na operação do motor com 2 fases, sem carga e com treinamento




Figura 70 - Correntes na operação do motor com 2 fases, sem carga e com treinamento

Comparação dos dois casos anteriores

A curva de erro médio quadrático para as duas condições apresentadas anteriormente é mostrada na Figura 71.

É natural que o erro médio quadrático para a situação com duas fases seja maior que a situação com 3 fases.




Figura 71 – Erro médio quadrático na operação do motor com carga e sem treinamento

É natural termos a degradação do torque elétrico devido à falta da fase, mas mesmo assim, a oscilação encontrada na curva de velocidade (Figura 68) mostra uma variação na velocidade de 10% no pior caso, o que em muitas aplicações industriais representa uma condição de operação aceitável.

O próximo estudo é idêntico aos casos dos itens a e b com a diferença de não haver treino durante a operação. Os itens c e d apresentam este estudo.

c) Sem carga, com 3 fases e sem treino.

Os gráficos abaixo (Figura 72 a Figura 77) são comparados aos resultados anteriormente apresentados (Figura 65 a Figura 70).




Figura 72 - Velocidade na operação do motor com 3 fases, sem carga e sem treinamento




Figura 73 - Torque na operação do motor com 3 fases, sem carga e sem treinamento




Figura 74 - Correntes na operação do motor com 3 fases, sem carga e sem treinamento

d) Sem carga, com 2 fases e sem treino.




Figura 75 - Velocidade na operação do motor com 2 fases, sem carga e sem treinamento




Figura 76 - Torque na operação do motor com 2 fases, sem carga e sem treinamento




Figura 77 - Correntes na operação do motor com 2 fases, sem carga e sem treinamento

Comparação dos dois casos anteriores

O gráfico abaixo (Figura 78) apresenta as duas curvas referentes às situações sem treino, sem carga, com 3 fases e com 2 fases.




Figura 78 – Erro médio quadrático na operação do motor sem carga e sem treinamento
 A Figura 79 apresenta as 4 curvas de erro médio quadrático do torque (todas as curvas na situação sem carga).




Figura 79 – Erro médio quadrático na operação do motor sem carga
 Temos dois grupos de curvas : as curvas inferiores onde temos 3 fases operando, e as duas curvas superiores onde se tem 2 fases operando.

Vale lembrar que em ambos os casos, o erro médio quando há treinamento no sistema é sempre inferior a quando não há treinamento.

O próximo caso estudado é o da inclusão da carga resistiva ao sistema. Os itens e e f mostram os resultados obtidos com carga, sem treino para as duas situações de operação com 2 ou 3 fases elétricas.

e) Com carga, com 2 fases e sem treino.

Os casos abaixo foram gerados com a inclusão de uma carga resistiva (lâmpada de 100W-127V). Observa-se a constância na característica da velocidade comparada aos outros casos onde há somente 2 fases operando.




Figura 80 - Velocidade na operação do motor com 2 fases, com carga e sem treinamento

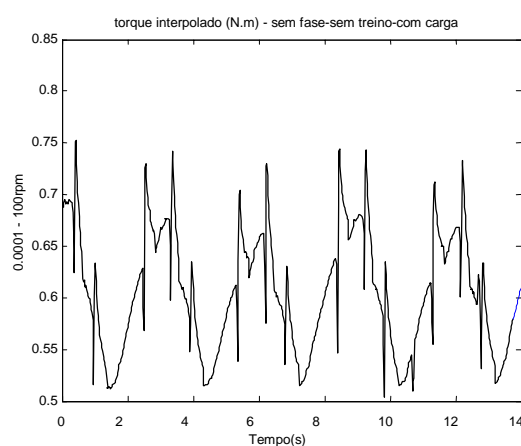


Figura 81 - Torque na operação do motor com 2 fases, com carga e sem treinamento

O nível da corrente de referência cresceu de 2,5A (sem carga) para quase 4A (com carga) para os casos com somente 2 fases e de 2,2A para 3,5A para os casos com 3 fases operando.




Figura 82 - Correntes na operação do motor com 2 fases, com carga e sem treinamento

f) Com carga, com 3 fases e sem treino.




Figura 83 - Velocidade na operação do motor com 3 fases, com carga e sem treinamento




Figura 84 - Torque na operação do motor com 3 fases, com carga e sem treinamento




Figura 85 - Correntes na operação do motor com 3 fases, com carga e sem treinamento

g) Com carga, com 3 fases e com treino.




Figura 86 - Velocidade na operação do motor com 3 fases, com carga e com treinamento




Figura 87 - Torque na operação do motor com 3 fases, com carga e com treinamento




Figura 88 - Correntes na operação do motor com 3 fases, com carga e com treinamento

h) Com carga, com 2 fases e com treino.




Figura 89 - Velocidade na operação do motor com 2 fases, com carga e com treinamento

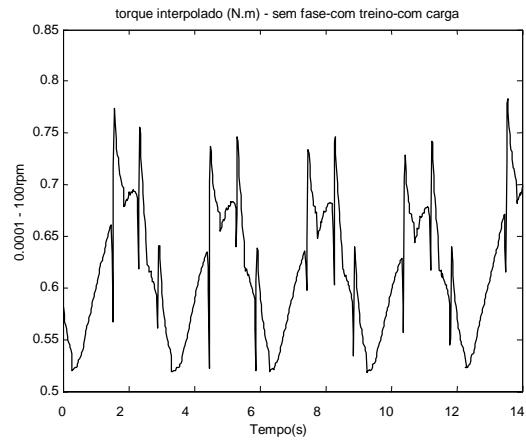


Figura 90 - Torque na operação do motor com 2 fases, com carga e com treinamento




Figura 91 - Correntes na operação do motor com 2 fases, com carga e com treinamento

Os resultados abaixo apresentados na Figura 92 e Figura 93 apresentam a comparação dos casos onde se tem a inclusão da carga.




Figura 92 – Erro médio quadrático na operação do motor com carga e com treinamento




Figura 93 – Erro médio quadrático na operação do motor com carga e sem treinamento

As figuras (Figura 94 e Figura 95) apresentam um resumo de todas as curvas de erro médio quadrático do torque. Percebe-se claramente que as curvas estão aos pares, cada par representa a curva com treino e sem treino.




Figura 94 – Erro médio quadrático na operação do motor para diversas condições




Figura 95 – Zoom dos sinais de erro médio quadrático na operação do motor em diversas condições

Os conjuntos de testes feitos (com treino/sem treino, com 2 fases/com 3 fases e com carga/sem carga) demonstraram a capacidade do acionamento do motor de relutância variável operar dentro da possibilidade de perda de uma de suas fases.

A capacidade do controlador de velocidade em continuar operando na referência (no caso 100 rpm) é apresentada através de resultados que demonstram visivelmente a capacidade do sistema em continuar operando durante esta falta de fase.

Quanto ao treino do compensador, conclui-se que ele continua a ajudar na minimização do torque, gerando um sinal de corrente adicional. Devido a sua própria natureza de compensação, o módulo *neuro-fuzzy* continua a buscar a redução da oscilação do torque mesmo que ele aumente consideravelmente quando da perda da fase.

5.7 Conclusões

Neste capítulo, foram apresentados o algoritmo de simulação do sistema *Neuro-fuzzy*, a estrutura do compensador, bem como o teste de operação do motor com interrupção de uma das fases.

Analisando os dois casos propostos (método de redução de oscilação de torque com sinal de torque e com sinal de velocidade), podemos concluir que tanto um quanto o outro apresenta resultados coerentes. O método sem utilização de sinal de torque apresentou um

aprendizado mais lento, devido ao baixo valor da taxa de aprendizagem (0,001) em comparação à taxa de aprendizagem usada no sistema com sinal de torque (0,3).

Salienta-se que este trabalho se baseia na observação indireta de sinais em tempo real para a compensação das oscilações de torque. A metodologia é de aprendizagem automática de um perfil de corrente, sem auxílio de observadores e estimadores de estados.

Capítulo 6

Desenvolvimento de Técnica de Eliminação de Sensor de Posição Angular do Rotor e Verificação Experimental do Modelo em Máquinas de Relutância Variável

6.1 Considerações Iniciais

Como foi apresentado no capítulo 4, diversas estratégias de eliminação de sensor de posição têm sido investigadas. Atualmente, cresce a utilização de técnicas de identificação usando-se redes neurais [66], [67], [68] e lógica *fuzzy* [69], devido à sua capacidade de estimar valores a partir de um conjunto de entradas, mapeando de maneira satisfatória um sinal de saída. A partir das idéias apresentadas nestes artigos e também no trabalho [85], desenvolveu-se uma nova estratégia de estimação de posição angular do rotor em máquinas de relutância variável. Esta estratégia é baseada em um sistema *Neuro-fuzzy* com aprendizagem, utilizando-se como sinais de entradas as tensões nas três fases e um sinal de corrente de referência, e obtendo como sinal de saída, o valor da velocidade da máquina que, após integrado, nos dá a posição angular do rotor.

6.2 Treinamento e Operação

O uso dos sinais medidos de tensão e corrente para estimar a posição do rotor é bastante comum. No entanto, esta metodologia utilizada sempre esbarra em restrições como, dificuldade na aquisição dos dados de tensão e corrente (custo e confiabilidade), e cálculo da relação entre tensão e corrente. Para o perfeito entendimento da estratégia utilizada no estimador de posição, devemos recordar a equação elétrica por fase da máquina de relutância variável:

$$v_j = R \cdot i_j + \frac{d\lambda}{dt} \quad (46)$$

Sabe-se que o fluxo magnético λ é função de θ e i . Aplicando-se a decomposição em derivadas parciais à relação $\lambda(\theta,i)$, resulta:

$$\frac{d\lambda}{dt} = \frac{\partial\lambda}{\partial\theta} \cdot \frac{d\theta}{dt} + \frac{\partial\lambda}{\partial i} \cdot \frac{di}{dt} \quad (47)$$

Se substituirmos o resultado de (47) em (46), tem-se:

$$v = R \cdot i + \frac{\partial\lambda}{\partial\theta} \cdot \frac{d\theta}{dt} + \frac{\partial\lambda}{\partial i} \cdot \frac{di}{dt} \quad (48)$$

A equação (48) pode ser re-escrita para a obtenção do valor da velocidade:

$$\frac{d\theta}{dt} = \frac{1}{\frac{\partial\lambda}{\partial\theta}} \cdot \left(v - R \cdot i - \frac{\partial\lambda}{\partial i} \cdot \frac{di}{dt} \right) \quad (49)$$

Como visto na equação (49), podemos obter uma relação entre a velocidade angular e os sinais de corrente e tensão impostos à máquina.

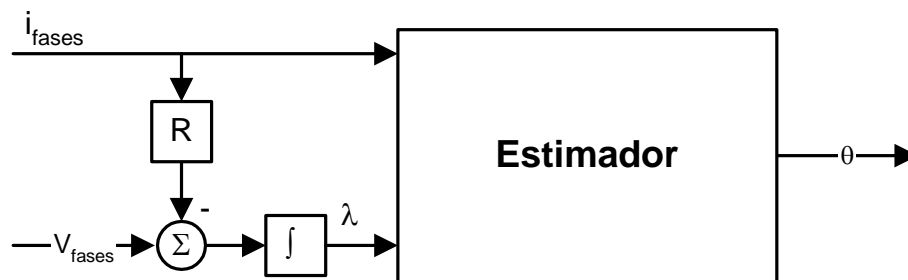


Figura 96 – Estimador convencional

Diversos trabalhos utilizam a relação (49), apresentada na forma de diagrama de blocos na Figura 96. Os valores de fluxo λ são obtidos através da integração dos sinais de corrente e tensão.

Porém, devido aos erros de leitura dos sinais de tensão, de corrente e às possíveis variações da resistência com o aumento de temperatura, o erro de estimação pode se tornar significativo. Outra situação que pode ocorrer é que em pontos extremos (alinhamento total e desalinhamento total), os erros de estimação são maiores. Particularmente, pequenos erros na corrente e no cálculo do fluxo geram significantes imprecisões no sinal de posição angular.

Na estratégia de estimação da posição do rotor proposta neste trabalho, estes erros são evitados ao incluirmos a não-linearidade presente no fluxo magnético $\lambda(\theta, i)$ no próprio estimador, e utilizando como entradas somente a variação da tensão aplicada a cada fase e a respectiva corrente de referência. O motivo da utilização da variação da tensão se baseia na necessidade de se considerar a parcela de não linearidade referente ao fluxo no estimador. Esta necessidade é devida à dependência temporal que existe entre a tensão e o fluxo e, conseqüentemente, à relação existente entre o sinal de posição e o fluxo. Para tal, opera-se um treinamento de uma rede *Neuro-fuzzy* cujas entradas são os 3 sinais de tensão $V(k)$ sendo k , um ponto amostrado no tempo, 3 sinais de tensão $V(k-1)$, e a corrente de referência $i_{ref}(k)$ (Figura 97). É importante alertar que esta rede não é recorrente (PERCEPTRON). O sinal atrasado de tensão é somente usado para o cálculo da variação da tensão no período de amostragem.




Figura 97 – Estimador *Neuro-fuzzy*

É importante lembrar que a tensão possui valores discretos de +150V, 0V e -150 V. Para que seja possível obter valores de tensão adequados ao treinamento torna-se necessária a utilização de um filtro passa-baixa de segunda ordem, por existir bi-unicidade nesta modelagem. Isto é, para valores únicos de tensão, teremos diversos valores de posição. Usando-se este filtro obtemos valores contínuos de tensão possibilitando um treinamento mais adequado. A Figura 98 apresenta o sinal de tensão antes e depois da filtragem.




Figura 98 – Tensão na fase 1, antes (a) e depois da filtragem (b).

Portanto, a Figura 97 passa a ser melhor representada pela inclusão de um filtro passa-baixa (Butterworth de segunda ordem), cuja função de transferência no domínio da frequência é dada por: (Figura 99).

$$H(s) = \frac{1}{\frac{s^2}{(100\pi)^2} + \frac{\sqrt{2}s}{50\pi} + 1} \quad (50)$$




Figura 99 – Estimador *Neuro-fuzzy* com filtro

Com uma quantidade representativa de dados para o treinamento, o sistema *Neuro-fuzzy* pode então mapear uma relação funcional entre V , I e ω . A Figura 100 mostra como o estimador *Neuro-fuzzy* é treinado de modo *offline* e depois utilizado como um estimador de velocidade e posição (Figura 101).

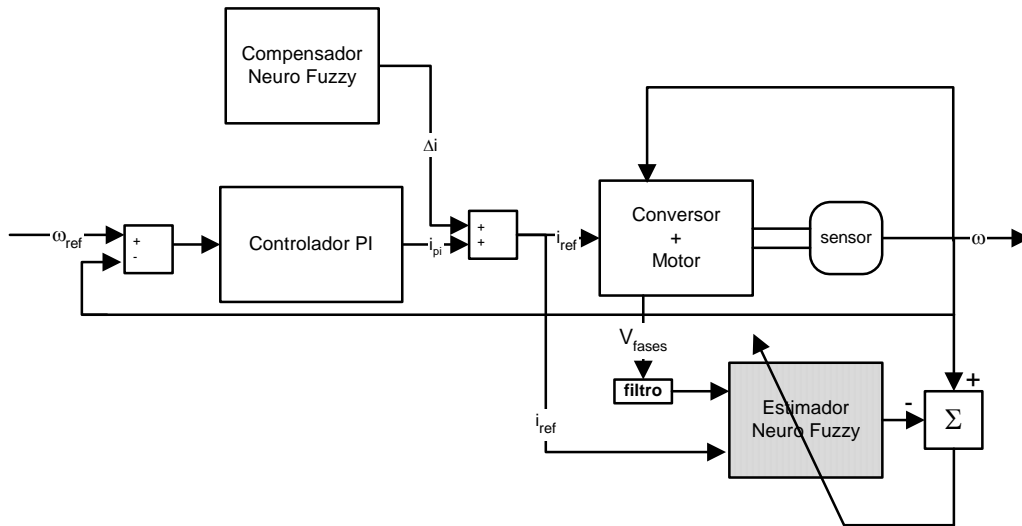


Figura 100 – Fase de treinamento do estimador *Neuro-fuzzy*

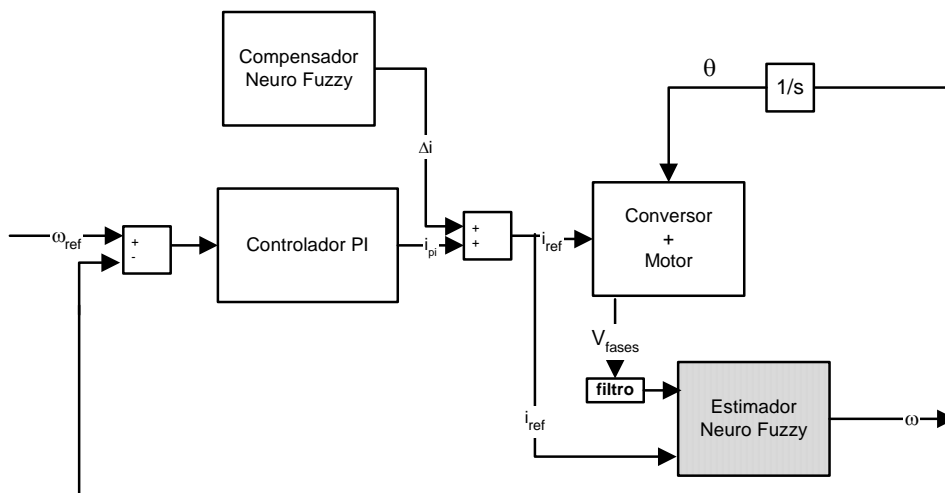


Figura 101 – Usando o estimador *Neuro-fuzzy* treinado como um estimador para a posição

O sinal de tensão filtrado seria o ideal para o treino. Porém, experimentalmente, temos restrições físicas na obtenção deste sinal (placa de aquisição de dados com frequência de amostragem insuficiente).

Para contornar este problema propusemos a utilização de um circuito de aquisição que foi projetado e apresentado em [86]. A Figura 102 mostra o circuito e a Figura 103 apresenta a fotografia da placa de circuito impresso que implementa este sistema de aquisição.

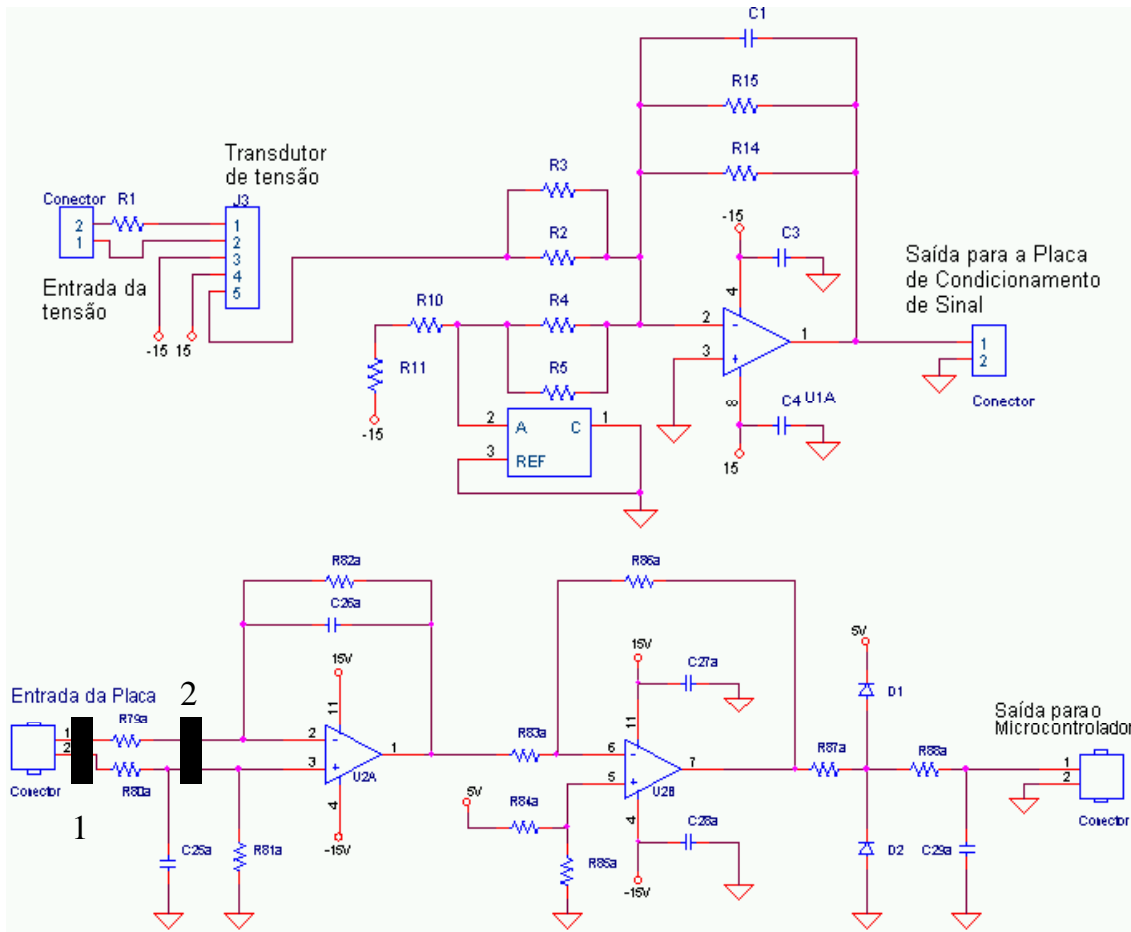


Figura 102 – Esquemático da placa de condicionamento de sinais.




Figura 103 – Foto da placa

Para a confirmação da operacionalidade do circuito de aquisição no nosso estudo, foram feitos alguns testes.

Operou-se o motor e obteve-se os sinais de tensão em três pontos distintos (Figura 104):

- Ponto 1: Na entrada do motor com uma ponteira diferencial de 100MHz (Figura 105)
- Ponto 2: Na saída da placa de aquisição com uma ponteira comum de osciloscópio (Tektronics 420 A – 200MHz – 100MS/s) (Figura 106)
- Ponto 3: Sinal obtido pela porta A/D da placa de aquisição de dados PCL 812 conectada ao microcomputador. (Figura 107)

Os pontos de conexão são apresentados na Figura 104.




Figura 104 - Pontos de aquisição da tensão




Figura 105- Sinal de tensão no ponto 1




Figura 106 - Sinal de tensão no ponto 2

O sinal 3 é obtido pela placa de aquisição PCL 812 (Figura 107):




Figura 107 – Sinal de tensão no ponto 3

6.3 Resultados de Simulação de Treino *Offline*

O primeiro passo para o treinamento do estimador *Neuro-fuzzy* de posição foi simular os sistema de treinamento gerando um conjunto de dados de treino, inicialmente com um valor de corrente de referência constante (no caso 1,5 A). Para este valor de corrente, obtém-se uma velocidade de aproximadamente 62 rpm em malha aberta. Portanto, o estimador foi treinado inicialmente para um único ponto de operação. Os resultados de simulação apresentados nas figuras (Figura 108 e Figura 109) foram obtidos preliminarmente aos estudos em malha fechada do sistema apresentados no próximo item.




Figura 108 – Posição estimada e real em graus do motor (simulação)




Figura 109 – Velocidade estimada e real do motor (simulação)

6.4 Resultados Experimentais de Treino *Offline*

Os dados de treinamento são obtidos com 1500 pontos (Figura 110 e Figura 111) e os dados de teste são 500 pontos distintos de um conjunto diferente de dados (Figura 112).

Para uma referência de velocidade de 100 rpm, sinais de tensão, corrente e velocidade foram adquiridos. Os sinais de tensão e corrente são apresentados na Figura 110 e Figura 111, respectivamente. Todos os resultados abaixo são experimentais.




Figura 110 - Tensão nas 3 fases - experimental




Figura 111 – Corrente de referência - experimental

Após o treinamento do estimador *Neuro-fuzzy* obtemos o resultado para a velocidade estimada apresentado na Figura 113. Como comparação, apresentamos a curva de velocidade real da máquina (Figura 112). Verifica-se a uma performance adequada do estimador neste teste. Os parâmetros de treino deste teste foram de 5000 épocas e taxa de aprendizagem de 0,5.




Figura 112 – Velocidade real - experimental




Figura 113 – Velocidade estimada - experimental

Após a obtenção dos resultados para o teste anterior, passou-se a buscar alterações nos parâmetros do treinamento com o objetivo de uma melhoria da qualidade do mesmo e de seus resultados.

Podemos dividir os testes em 3 partes:

- Aumento da velocidade de referência (1000 rpm)
- Treinamento para dois valores distintos de velocidade (100 rpm e 1000 rpm)
- Treinamento do sinal com um degrau de velocidade na referência.

A primeira parte tratou do aumento da velocidade de referência da máquina. O quadro abaixo (Tabela 3) apresenta o caso estudado. Velocidade de referência de 100 rpm, taxa de aprendizagem de 0,5 e dois pontos de parada (5000 e 20000 épocas). O erro médio quadrático continuou a cair (de 99 para 10) quando continuamos com o treino. Outra constatação é que quando utilizamos a referência de 100 rpm o erro médio quadrático é inferior ao obtido com a referência de 1000 rpm. O objetivo deste teste é mostrar a capacidade do algoritmo de treinamento *Neuro-fuzzy* de operar com velocidades maiores e

consequentemente com um conjunto de treino que possui menos informações sobre o perfil de tensão devido à baixa frequência de amostragem da placa de aquisição de dados.

Velocidade	Gama	Épocas	Erro médio
1000	0,5	5000	99
1000	0,5	20000	10

Tabela 3 – Estudo de caso para 1000 rpm

A segunda proposta de melhoria do treino foi manter após o treinamento para 100 rpm, o mesmo conjunto de pesos para o treinamento para a velocidade de 1000 rpm. Este estudo visa verificar se o sistema tem condição para uma ampla faixa de operação. A tabela abaixo apresenta os 3 casos obtidos.

caso	Velocidade	Gama	Épocas	Erro médio
A	100	0,5	5000	9
	1000	0,5	5000	23
B	100	0,005	2000	200
	1000	0,005	2000	5300
C	100	0,005	5000	60
	1000	0,005	5000	2200

Tabela 4 – Casos A, B e C

Não existem valores razoáveis para o erro. O ideal seria erro nulo, porém ele não foi alcançado. Os valores apresentados na Tabela 4 foram encontrados dentro das variações de parâmetros nela incluídos e servem para que sejam comparadas e para que sejam buscados os melhores resultados.

No caso A, aplicamos uma taxa de aprendizagem de 0.5 e obtivemos um treino consistente para a velocidade de 100 rpm (Figura 114). Porém, quando se treinou com 1000 rpm (Figura 115), o treinamento se degradou. Isto ocorreu devido à taxa de aprendizagem possuir um valor suficientemente grande para, ao treinar o sistema com 1000 rpm, fazer com que o sistema desaprenda o que havia sido treinado com velocidade de 100 rpm. A Figura 118 mostra este resultado. As figuras (Figura 116 e Figura 117) apresentam o sinal do erro entre o sinal de velocidade real e o estimado para as duas condições de velocidade.




Figura 114 – Velocidade real e estimada 100rpm - experimental




Figura 115 – Velocidade real e estimada 1000rpm - experimental




Figura 116 – Erro entre a velocidade real e estimada 100rpm - experimental




Figura 117 – Erro entre a velocidade real e estimada 1000rpm - experimental




Figura 118 – Velocidade depois dos dois treinos - experimental

Os casos B e C foram tentativas de conseguir, com o mesmo conjunto de treino do caso A, porém com uma taxa menor de treinamento (0,005), ter êxito nesta forma de treino. Como era de se esperar, o treino foi bastante mais lento do que no caso A e os mesmos resultados

insatisfatórios foram encontrados. Esta taxa de aprendizagem inviabiliza a operação em tempo real desta técnica devido ao treino demorar muito tempo para chegar a resultados aceitáveis.

Partiu-se para um terceiro teste ao se incluir um degrau de velocidade ao sistema. A Tabela 5 apresenta os casos estudados. Buscou-se variar a taxa de aprendizagem (gama), o número de épocas e a quantidade de funções de pertinência.

	velocidade	Gama	Épocas	Erro médio	n. de funções
a	1000 - 750	1	20000	40000	3 funções
b	1000 - 750	0,5	100000	32000	3 funções
c	1000 - 750	0,5	500	750000	5 funções
d	1000 - 750	0,5	5000	600000	5 funções
e	1000 - 750	5	500	Instabilizou	5 funções
f	1000 - 750	0,1	5000	1400000	5 funções
g	1000 - 750	0,5	500	4000000	7 funções
h	1000 - 750	1	500	520000	7 funções
i	200-100	0,5	20000	3000	3 funções
j	200-100	0,5	20000	40000	5 funções

Tabela 5 – Casos com degrau de velocidade

Neste estudo, obtivemos bons resultados para diversos casos. O caso onde foi usada uma taxa de aprendizagem de valor 5, instabilizou-se. Isto se deve naturalmente ao valor excessivo da taxa de aprendizagem aplicada ao sistema.

As figuras abaixo (Figura 119, Figura 120, Figura 121 e Figura 122) apresentam o caso j de 200-100 e taxa de aprendizagem (gama) de 0.5. Estes resultados são de simulação com 20000 épocas.




Figura 119 - Tensão nas 3 fases - experimental




Figura 120 – Corrente de referência – exp.




Figura 121 – velocidade real - experimental




Figura 122 - Erro médio quadrático - experimental

A Figura 123 apresenta o resultado para o caso j e percebe-se que a estimação não teve grande êxito neste caso estudado. Isto se deve à taxa de aprendizagem de 0,5 ser grande o bastante a ponto de não permitir um aprendizado suficiente com poucas épocas. Isto mostra que ao treinarmos com uma taxa de aprendizagem maior, o estimador tem dificuldade de aprender os dois níveis de velocidade. Neste caso percebeu-se que ao treinar para 200 e 100 rpm, o estimador apresentou resultados próximos a 150 rpm.




Figura 123 - Velocidade medida e estimada - experimental

O próximo item apresentará os resultados experimentais obtidos diretamente da bancada de teste com aprendizagem *online*.

6.5 Treinamento e Aprendizagem *online*

O algoritmo de obtenção do sinal estimado da posição do rotor, baseia-se na utilização de um sistema *Neuro-fuzzy* com aprendizagem *online* onde as entradas são as tensões de fase e a corrente de referência, e a saída o sinal de velocidade. Neste capítulo apresentaremos um conjunto de testes experimentais de modo a verificar-se as potencialidades e possíveis problemas em sua operação, com o sistema em malha fechada de velocidade.

Inicialmente montou-se um sistema *neuro-fuzzy* baseado em aprendizagem supervisionada análogo ao apresentado no capítulo 6.3. A aprendizagem é feita em tempo real com os sinais obtidos da placa de aquisição de dados. Quando o erro médio quadrático do treinamento atinge um valor mínimo pré-estabelecido, o treino deixa de ser feito e a estimação de velocidade e conseqüente estimação de posição começa a ser efetuada. A integração numérica da velocidade para a obtenção da posição do motor é feita usando-se a técnica de integração trapezoidal. Outras técnicas foram testadas (retângulo e Simpson), porém não tiveram o aproveitamento que a integração numérica trapezoidal obteve.

6.6 Resultados experimentais com treinamento *online*

Inicialmente, operou-se a máquina em malha aberta de controle de velocidade. A corrente de referência para cada fase foi fixada em 2 A e considerou-se uma taxa de aprendizagem de 0,1. Os resultados obtidos foram os seguintes:




Figura 124 – Erro médio quadrático total do sinal de treino - experimental




Figura 125 – Velocidade real e estimada - experimental

Os resultados apresentados na Figura 124 e Figura 125 mostram que o estimador com controle em malha aberta de velocidade tem performance esperada para o caso estudado.

O passo seguinte para a verificação da operacionalidade do sistema é fechar a malha de controle de velocidade. Os resultados das figuras abaixo (Figura 126 a Figura 129) foram obtidos nesta condição e com uma referência de 100 rpm. Operou-se experimentalmente o sistema com 4 valores de taxa de aprendizagem (0,001; 0,01; 0,1 e 0,5), sendo o controlador de velocidade um PI clássico sem minimização das oscilações.

A não utilização da técnica de minimização de oscilação de torque neste caso experimental deve-se a limitações de velocidade de processamento da placa de aquisição de dados e da necessidade de grande espaço de memória estendida no microcomputador.




Figura 126 – Velocidade real e estimada – taxa de aprendizagem 0,5 - experimental




Figura 127 – Velocidade real e estimada – taxa de aprendizagem 0,1 - experimental




Figura 128 – Velocidade real e estimada – taxa de aprendizagem 0,01 - experimental




Figura 129 – Velocidade real e estimada – taxa de aprendizagem 0,001 - experimental

Verifica-se que para valores muito pequenos de taxa de aprendizagem, o treino apresenta-se bastante lento. Dois valores de taxa de aprendizagem mostraram ser melhores (0,1 e 0,5).

Usou-se neste caso e nos casos subsequentes um número de 7 funções de pertinência para cada uma das quatro entradas do sistema *neuro-fuzzy*.

A Figura 130 apresenta a evolução do erro médio quadrático para os 4 casos. As curvas de erro médio quadrático mostram o quanto o estimador demora para se adaptar ao sistema. Enquanto o treino com taxa de aprendizagem de 0,5 demora menos de 5 segundos para chegar a um valor de erro, a taxa de 0,001 fez com que o estimador só tivesse tal performance após 300 segundos. Este gráfico mostra que o estimador treina para todos os quatro valores, porém com tempos diferentes de adaptação.




Figura 130 – Erro médio quadrático total - experimental

O próximo teste, ilustrado nas Figura 131 a Figura 134, foi desenvolvido para a confirmação da capacidade do algoritmo de aprendizagem do estimador de velocidade, ao incluir um degrau de 50% da velocidade inicial (150 rpm) na referência de velocidade. Buscou-se, conseqüentemente, a adaptação do estimador *Neuro-fuzzy* à nova situação. Para esta validação, foram também ensaiados experimentalmente 4 valores de taxa de aprendizagem (0,001; 0,01; 0,1 e 0,5).




Figura 131 – Velocidade real e estimada – taxa de aprendizagem 0.001 - experimental




Figura 132 – Velocidade real e estimada – taxa de aprendizagem 0.01 - experimental




Figura 133 – Velocidade real e estimada – taxa de aprendizagem 0,1 - experimental




Figura 134 – Velocidade real e estimada – taxa de aprendizagem 0,5 - experimental

Novamente, os resultados comprovaram a eficácia da estratégia de estimação elaborada. Os resultados com taxa de aprendizagem de 0,1 e 0,5 mostraram serem estes os valores mais indicados para serem usados como taxa de aprendizagem. A Figura 135 apresenta a evolução do erro médio quadrático obtido com os 4 valores de taxa de aprendizagem.

Os melhores resultados apresentados até este momento foram para a taxa de aprendizagem de 0,5 (Figura 126 e Figura 134).




Figura 135 – Erro médio quadrático total - experimental

O próximo conjunto de testes também apresenta o degrau de velocidade de referência como nos casos anteriores com 7 funções de pertinência para cada entrada, porém, diferentemente dos resultados anteriores (Figura 131 a Figura 134), quando do retorno à velocidade original (aos 25 s), o treinamento é interrompido e somente temos a operação sem sensor (Figura 101). Desta vez são apresentados os resultados para os três melhores valores de taxa de aprendizagem (Figura 136 a Figura 138). O objetivo deste teste é

mostrar a capacidade do sistema *Neuro-fuzzy* de treinar para dois níveis de velocidade e mesmo assim manter o aprendizado para os dois casos.




Figura 136 – Velocidade real e estimada – taxa de aprendizagem 0.1 - experimental




Figura 137 – Velocidade real e estimada – taxa de aprendizagem 0.01 - experimental




Figura 138 – Velocidade real e estimada – taxa de aprendizagem 0.5 - experimental




Figura 139 – Erro médio quadrático - experimental

A Figura 139 apresenta a evolução do erro médio quadrático obtido com os 3 valores de taxa de aprendizagem.

Conclui-se que mesmo com uma taxa de aprendizagem de 0,1, que o sistema apresenta uma incapacidade de voltar a ter a saída anteriormente treinada. Diante dos resultados obtidos, escolheu-se trabalhar, a partir deste ponto, com um valor de taxa de aprendizagem de 0,5 para a operação sem sensor.

Os resultados das Figura 140 e Figura 141 apresentam a corrente na fase 1 quando da operação sem sensor em malha fechada de velocidade e as tensões nas três fases respectivamente. Percebe-se que há um período de tempo em que a corrente é inferior ao valor do controle de histerese. Isto acontece devido a pequenos erros da estimação da velocidade que alimenta o motor com o rotor em uma posição desfavorável. O controlador

de velocidade PI não sofreu nenhuma modificação e os ângulos θ_{on} e θ_{off} também foram mantidos.

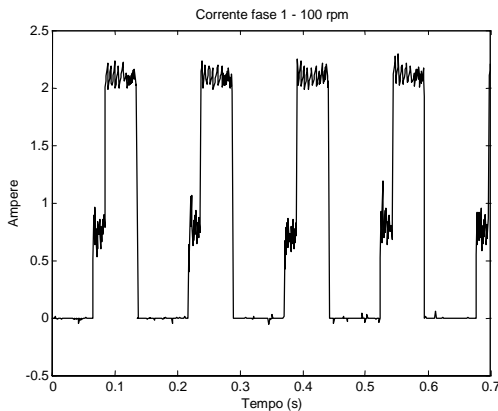


Figura 140 – Corrente em uma fase sem sensor de posição - experimental




Figura 141 – Tensão de fase - experimental

A corrente de referência do motor é apresentada na Figura 142. Observa-se que a partir do ponto onde o estimador começa a operar (aproximadamente aos 8 s), que a corrente de referência cresce levemente, isto ocorre para compensar as imperfeições da posição lida pelo controle. Este resultado é consequência da necessidade de se manter o controle de velocidade da máquina (controle PI clássico) (Figura 143).




Figura 142 – Corrente de referência – taxa de aprendizagem 0.5 - experimental




Figura 143 – Velocidade estimada - experimental

Os sinais de posição real e estimada estão apresentados na Figura 144. Durante o período de treino (até 8 s) os sinais estão próximos. Após este ponto, o estimador toma o lugar do sensor. A Figura 145 apresenta um zoom da região onde o treino do estimador ainda está em operação.




Figura 144 – Posição medida e estimada – taxa de aprendizagem 0.5 - experimental




Figura 145 – Erro entre valor de posição medida e estimada – taxa de aprendizagem 0.5 (zoom) - experimental

Após os testes preliminares, apresentamos o estudo de 5 casos onde as velocidades de referência são de 50 rpm, 100 rpm, 200 rpm, 300rpm e 400 rpm. A operação para cada um dos casos é de 14 s. Ao completar 8 s de operação, a máquina começa a funcionar totalmente sem sensor de posição. As figuras (Figura 146 a Figura 150) apresentam as curvas de velocidade para os 5 casos estudados. Pode-se observar que até os 8 s, os valores de velocidade medida e estimada são bastante próximos. Isto ocorre devido ao sistema já estar treinando anteriormente ao início da coleta destes dados.

Aos 8 segundos, percebe-se uma oscilação maior da velocidade medida enquanto a velocidade estimada mantém-se próxima à referência. Pode-se perceber que, apesar de o motor estar oscilando mais, o estimador *Neuro-fuzzy* possui uma característica estabilizadora e conservativa, mantendo a máquina operando com velocidade próxima à velocidade de referência nos 5 casos estudados.




Figura 146 – Velocidade medida e estimada – velocidade de referência 50 rpm - experimental




Figura 147 – Velocidade medida e estimada – velocidade de referência 100 rpm - experimental




Figura 148 – Velocidade medida e estimada – velocidade de referência 200 rpm - experimental




Figura 149 – Velocidade medida e estimada – velocidade de referência 300 rpm - experimental

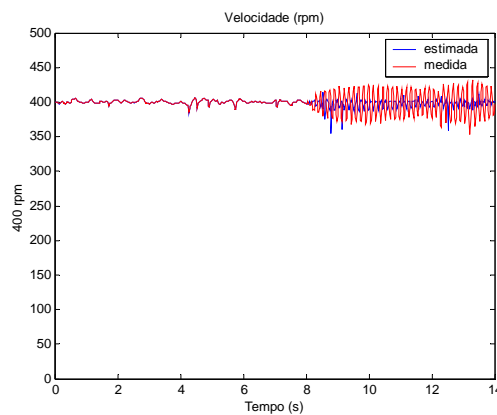


Figura 150 – Velocidade medida e estimada – velocidade de referência 400 rpm - experimental

Finalmente, após avaliarmos a melhor taxa de aprendizagem (0,5) e o número de funções de pertinência (7 funções para cada uma das entradas), ilustramos a operação da máquina sem sensor, apresentando a seguir a corrente em uma das fases do motor de relutância variável sem sensor nas condições de 50 rpm (Figura 151), 100 rpm (Figura 152), 200 rpm (Figura 153), 300 rpm (Figura 154) e 400 rpm (Figura 155). Observa-se que o erro de chaveamento devido à estimação apresenta um perfil de corrente diferente do encontrado na operação com sensor.

Esta imperfeição pode ser observada nas curvas de velocidade apresentadas anteriormente. Porém, mais facilmente nas curvas de posição estimada e medida (Figura 145)




Figura 151 – Corrente na fase 1 - velocidade de referência 50 rpm - experimental




Figura 152 – Corrente na fase 1 - velocidade de referência 100 rpm - experimental




Figura 153 - Corrente na fase 1 - velocidade de referência 200 rpm - experimental




Figura 154 – Corrente na fase 1 – velocidade de referência 300 rpm - experimental




Figura 155 – Corrente na fase 1 – velocidade de referência 400 rpm - experimental

6.7 Considerações Finais

Neste capítulo apresentou-se a técnica utilizada para a eliminação do sensor de posição de um motor de relutância variável. Foi mostrada a teoria do treinamento e da operação do estimador *neuro-fuzzy* bem como as restrições físicas encontradas para a obtenção dos dados

de entrada. Resultados iniciais de treino *offline* foram apresentados para garantir a capacidade do sistema.

Neste capítulo também são apresentados os resultados práticos em tempo real da eliminação do sensor de posição em um motor de relutância variável.

Inicialmente buscou-se a melhor taxa de aprendizagem entre os valores de 0,001; 0,01; 0,1 e 0,5; sendo esta última taxa aplicada para 5 níveis de velocidade. Para todos os 5 casos estudados de velocidade (50 rpm, 100 rpm, 200 rpm, 300 rpm e 400 rpm) obteve-se resultados significativos.

O motor quando estiver na condição sem treinamento prévio não tem habilidade de iniciar a operação sem sensor estando com velocidade zero (partida da máquina).

O objetivo desta nova proposta de estimação é aplicar uma nova técnica de busca pelo valor de posição/velocidade usando sistema com aprendizado e flexibilidade de operação.

Capítulo 7

Conclusões e Propostas de Trabalhos Futuros

7.1 Conclusões

Este trabalho teve dois grandes objetivos. O primeiro foi reduzir a oscilação de torque de um motor de relutância variável através de um compensador de corrente de referência baseado em técnicas inteligentes de controle, nomeadamente redes neurais e lógica *fuzzy*.

O segundo objetivo foi eliminar o sensor de posição deste mesmo motor de relutância variável. A técnica para a eliminação foi a mesma utilizada para a redução da oscilação de torque, porém com outros sinais de entrada e saída.

Para o desenvolvimento deste presente trabalho, inicialmente foi apresentada a máquina de relutância variável com suas características elétricas e mecânicas. Para a operação desta máquina podem ser empregadas diversas topologias de conversores. Cada uma com características distintas (potência, necessidades da carga) uma das outras e que devem ser levadas em consideração no momento da escolha da configuração ideal para a operação da máquina.

As estratégias de redução de oscilações de torque da MRV apresentam metodologias distintas de controle e modelagem para o sistema estudado. Buscou-se encontrar, através do estudo e análise de cada uma delas, as suas potencialidades de trabalho, permitindo discutir suas vantagens e desvantagens, bem como, uma maneira de se classificar estas técnicas. Também foram avaliadas as estratégias de eliminação de sensor de posição da MRV. Todas as técnicas têm como princípio fundamental de operação, a variação do fluxo em função da posição angular do rotor.

Para a redução das oscilações de torque foi implementado um sistema de compensação de corrente que adicionado ao controle PI de velocidade, gera um sinal de corrente que reduz as oscilações.

Todo o sistema proposto foi simulado através do programa comercial Matlab[®] e seus “toolboxes”: Simulink[®] e “Fuzzy Logic Toolbox” [84] e operado em bancada experimental com êxito. A opção por esta ferramenta computacional foi baseada na facilidade de manuseio do programa através de uma interface gráfica com o usuário e devido à ampla utilização deste pacote nas mais diversas instituições de pesquisa e ensino.

Um controle adaptativo *Neuro-fuzzy* para a minimização da oscilação de torque foi apresentado. Este tipo de compensador possui a capacidade de aprendizagem, permitindo uma maior flexibilidade de operação, tornando o compensador mais independente das características da máquina. A aprendizagem é alcançada através de um método de aprendizagem de regras baseado em exemplos. Este treino é feito através da divisão do domínio de estudo em um conjunto de funções de pertinência que são atribuídas a cada entrada do treinamento e onde cada divisão do domínio representa uma regra do compensador.

Após um número finito de épocas, o compensador é capaz de produzir um torque mais liso para uma faixa de velocidade zero a 1800 rpm. As fases são desligadas segundo um ângulo de desenergização de maneira a evitar a produção de torque negativo na máquina.

Todo o algoritmo de treino foi apresentado e comprovou-se sua eficiência. O sistema simulado não apresentou problemas de convergência numérica, possibilitando a simulação de dois modelos completos de simulação (controlador PI-Clássico e Controlador *Neuro-fuzzy*) sem necessidade de cuidados para evitar estes problemas.

A partir do modelo *Neuro-fuzzy* simulado do Matlab, o modelo projetado no simulador foi utilizado no controle implementado na bancada experimental. Foram propostos 2 casos diferentes: um usa o sinal de torque estimado como sinal de erro e um outro que utiliza o sinal de velocidade. Ambos apresentaram resultados compatíveis com o objetivo do trabalho.

Para a obtenção de resultados satisfatórios foram necessárias algumas análises anteriores. Inicialmente foi analisada a influência da taxa de aprendizagem para o sistema. Este valor da taxa está ligado diretamente à rapidez com que o sistema ajusta suas regras para a melhoria da saída. Apesar dos bons resultados obtidos com taxas de aprendizagem pequenas, o treinamento ficou excessivamente lento impossibilitando a operação em tempo

real. Por outro lado, valores muito altos (maiores que um) acarretaram em uma instabilidade do compensador devido à aprendizagem ser muito rápida.

Outra análise foi a dependência do resultado com a quantidade de funções de pertinência para cada regra. Foram estudados sistemas com 3, 5, 7, 11 funções de pertinência para cada entrada. Quanto maior a quantidade de funções, melhor será a capacidade de representação do universo de discurso para cada uma das entradas. Porém, uma quantidade muito alta de funções irá também tornar o processamento destas regras muito lento e ineficaz para a operação em tempo real.

A operação da MRV com compensação *neuro-fuzzy* de corrente sob condição de interrupção de uma das fases foi estudado. Além de confirmar a robustez a máquina em operar sem tensão em uma das fases, conseguiu-se, com a compensação, resultados mais positivos do que se utilizássemos somente o controlador de velocidade PI. Foram estudados, além da falta de fase, o estudo de casos sem carga e com carga (carga elétrica resistiva alimentada por um gerador conectado ao eixo da MRV). Os resultados apresentados mostraram que o compensador continua a ajudar na minimização do torque, gerando um sinal de corrente adicional. Devido a sua própria natureza de compensação, o módulo *neuro-fuzzy* continua a buscar a redução da oscilação do torque mesmo que ele aumente consideravelmente quando da perda da fase.

Para a eliminação do sensor de posição buscou-se implementar um sistema análogo ao desenvolvido para a redução de oscilação de torque.

Inicialmente foi proposto um sistema *Neuro-fuzzy* de estimação *offline*, os dados de treino foram obtidos através da bancada experimental, posteriormente treinados e depois disto, o estimador é incluído no sistema experimental substituindo a malha de leitura de posição/velocidade. Nestes casos, foram propostos três estudos: o estudo para velocidade de 100 rpm e 1000 rpm separadamente, o estudo do treino concomitante das duas velocidades e finalmente a criação de um degrau de velocidade.

Os resultados para 100 rpm e 1000 rpm separadamente foram satisfatórios, entretanto quando operados ao mesmo tempo o treino se degradou com taxas altas de aprendizagem. O caso proposto com degrau de velocidade apresentou resultados indesejáveis devido a demora no treinamento, mas percebeu-se que quando treinado em tempo real, a máquina funcionou com desempenho adequado.

A verificação do sistema com treino em tempo real constitui inicialmente em operar a máquina em malha aberta sem controle de velocidade, com resultados satisfatórios. O passo seguinte foi fechar a malha e incluir um degrau de 50% na velocidade. Todos os resultados de simulação e experimentais foram os esperados e demonstraram a capacidade do estimador *Neuro-fuzzy* de se obter, a partir de sinais filtrados de tensão e da corrente de referência, um sinal de velocidade que posteriormente foi integrado numericamente para a obtenção da posição.

Salienta-se que este trabalho se baseou na observação indireta de sinais em tempo real para a compensação das oscilações de torque e estimação de velocidade/posição. A metodologia é de aprendizagem automática de um perfil de corrente, sem auxílio de observadores e estimadores de estados.

As dificuldades encontradas no trabalho, especificamente no desenvolvimento do conversor X implementação das estratégias (minimização de oscilação de torque e estimação de velocidade/posição), foram essencialmente na compatibilização dos sinais de entrada e saída com o tempo necessário para o processamento da placa de aquisição de dados e do processador do microcomputador. Estas restrições foram ultrapassadas diminuindo a carga de processamento de todo o sistema sem que isto degradasse os resultados esperados.

7.2 Propostas de Trabalhos Futuros

A seguir, são apresentadas algumas sugestões para o prosseguimento deste trabalho:

- Transferência de toda a programação desenvolvida em linguagem C para linguagem orientada a objetos baseada em ambiente Windows.
- Melhoria do treino do sistema de estimação Neuro-fuzzy para a eliminação do sensor de posição, buscando aprofundar a validação experimental da metodologia.
- União das duas estratégias (eliminação de sensor e redução de oscilação de torque) em um mesmo software de controle.
- Desenvolvimento de uma malha de controle de posição para este acionamento.

Capítulo 8

Bibliografia

- [1] BOSE, B. K., *Power Electronics and Variable Frequency Drives - technology and Applications*, Capítulo 11 – IEEE Press, Nova Iorque, 1997.
- [2] REINER, J., INDERKA, R., MENNE, M., DE DONKER, R. W. “Optimizing Performance in Switched-Reluctance Drives”, *IEEE Industry Applications Magazine*, pp. 63-70, Jul/Ago 2000.
- [3] COSTA BRANCO, P. J., DENTE, J. A., “The Application of fuzzy logic in automatic modelling of electromechanical systems”, *Fuzzy sets and systems 95*, pp. 273-293, 1998
- [4] STANKOVIC, A. M., TADMOR, G., CORIC, Z. J., AGIRMAN I., “On torque ripple reduction in current-fed switched reluctance motors”, *IEEE Transactions on Industrial Electronics*, Vol. 46, n. 1, Fev 1999, pp. 177-183
- [5] LOVATT, H. C, STEPHENSON, J. M., “Computer-optimized Current Waveforms form switched Reluctance Motor” *IEE Proceedings*, v. 141, Pt B, n. 2, pp. 45-51, Mar. 1994
- [6] O’DONOVAN, J. G., ROCHE, P. J., KAVANAGH, R. C., “Neural Network Based Torque Ripple Minimization in a Switched Reluctance Motor” *IECON '94 Bologna Conference Proceedings*, pp. 1226-1231, Set 1994
- [7] MIR, S., ELBULUK, M. E., HUSAIN I., “Torque-Ripple Minimization in Switched Reluctance Motors Using Adaptive Fuzzy Control”, *IEEE Transaction on Industry Applications* v. 35, n. 2, pp. 461-468 Mar/Abr 1999
- [8] RUSSA, K., HUSAIN I., ELBULUK, M. E., “Torque-ripple Minimization in Switched Reluctance Machines Over a Wide Speed Range”, *IEEE Transaction on Industry Applications*, v. 34, n. 5, pp. 1105-1112 Set/Out 1998.
- [9] MENDEL, J. M., “Fuzzy logic systems for engineering: A tutorial”, *Proceedings of the IEEE*, v. 83, n. 3, pp. 345-377, Mar 1995.
- [10] WANG, L., *Adaptive fuzzy systems and control, Design and Stability Analysis*, Nova Jersey, PTR Prentice Hall, 1994
- [11] MILLER, T. J. E., *Brushless Permanent-Magnet and Reluctance Motors Drives*, Oxford, U.K., Magma Physics Publishing and Clarendon Press-Oxford, 1993.
- [12] HENRIQUES, L. O. A. P., 1999, *Compensação das Oscilações de Torque de um Acionamento de Relutância Chaveado utilizando técnicas de controle Neuro-fuzzy*, Tese de M.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.
- [13] NASCIMENTO, J. M. L., ROLIM, L. G. B., HEIDRICH, P., SUEMITSU, W. I., HANITSCH, R., “Design and Simulation Aspects of a Switched Reluctance Drive”, *COBEP'95*, pp. 79-83, 1995.

-
- [14] MILLER, T. J. E., *Switched Reluctance Motors and their Control*; Oxford, U.K., Magma Physics Publishing and Clarendon Press-Oxford, 1993.
- [15] LAWRENSON P. J., STEPHENSON, J. M., BLENKINSSOP, P. J., et al., "Variable-Speed Switched Reluctance Motor", *Proc. of IEE*, v. 127, Pt. B, n. 4, pp. 253-265, Jul. 1980.
- [16] GREENHOUGH, P., "Switched Reluctance Variable Speed Drives- A Focus on Applications", *Technology Mining - Papers and articles*, pp. 107-110, Abr. 1996
- [17] RADUN, A. V., "High-Power Density Switched Reluctance Motor Drive for Aerospace Applications", *IEEE Transaction on Industrial Electronics*, v. 28, n. 1, pp. 113-119, Jan/Fev 1992.
- [18] http://www.f-16.net/f-16_news_article594.html
- [19] BASS, J. T., ESHANI, M., MILLER, T. J. E., "Robust torque control of switched-reluctance motors without a shaft-position sensor", *IEEE Transaction on Industrial Electronics*, v. 33, n. 3, pp. 212-216, Ago. 1986
- [20] BUJA, G. S., MENIS, R. M., VALLA, M. I., "Variable Structure Control of an SRM Drive", *IEEE Transaction on Industrial Electronics*, v. 40, n. 1, pp. 56-63, Fev. 1993.
- [21] VAGATI, A., PASTORELLI, M., FRANSCHESCHINI, G., et al., "Design of low-torque-Ripple Synchronous Reluctance Motors" *IEEE Transaction on Industry Applications*, v. 34, n. 4, pp. 758- 765, Jul./Ago. 1998.
- [22] WALLACE, R. S., TAYLOR, D. G., "A Balanced Commutator for Switched Reluctance Motors to Reduce Torque Ripple" *IEEE Transaction on Power Electronics*, v. 7, n. 4, pp. 617-626, Out. 1992.
- [23] RAY, W. F., LAWRENSON, P. J., DAVIS, R., et al., "High-performance Switched Reluctance Brushless Drives", *IEEE Transaction on Industry Applications*, v. 22, n. 4, pp. 722-730, Jul./Ago. 1986.
- [24] HUSAIN, I., "Minimization of torque ripple in SRM drives", *IEEE Transaction on Industrial Electronics*, V. 49 n. 1, pp. 28-39, fev. 2002
- [25] ROLIM, L. G. B., 1997, *Investigation of a drive system: soft-switching converter and switched reluctance motor*, tese de Doutorado, Universidade Técnica de Berlim, Alemanha.
- [26] POLLOCK, C., WILLIAMS, B. W., "Power Converter circuits for Switched Reluctance Motors with minimum number of Switches", *IEE Proceedings*, Vol. 137, part B, No. 6, pp. 373-384, Nov/1990
- [27] KAVANAGH, R. C., MURPHY, J. M. D., EGAN M., "Torque Ripple Minimization in Switched Reluctance Drives using Self-Learning Techniques", *Proc. of IECON'91*, pp. 289-294, Vol. 1, Japão, 1991.
- [28] BYRNE, J. V., MCMULLIN, M. F., O'DWYER, J. B., "A High performance variable reluctance drive: a new brushless servo", *Proc. MotorCon*, pp.147-160, Out 1985

-
- [29] RADUN, A. V., “ Design Considerations for the Switched Reluctance Motor”, *IEEE Transaction on Industry Applications*, vol. 31 no5 Set/Out 1995 pp: 1079-1087
- [30] CARDOSO, J. R., DE PAULA, P. P., “Design of a Switched Reluctance Motor”, *COBEP'95*, pp. 67-72
- [31] HUSAIN, I., EHSANI, M., “Torque Ripple Minimization in Switched Reluctance Motor Drives by PWM Current Control” *IEEE Transaction on Power Electronics* v. 11, n. 1, pp. 83-88, Jan 1996.
- [32] SCHRAMM, D. S., WILLIAMS, B. W., GREEN, T. C., “Torque Ripple Reduction of Switched Reluctance Motors by PWM phase Current optimal Profiling”, *PESC 92*, pp. 857-860, 1992.
- [33] MOREIRA, J. C., “Torque Ripple Minimization in Switched Reluctance Motors Via bi-cubic Spline Interpolation”, *PESC 92* pp 851-856, 1992
- [34] PARREIRA, B., RAFAEL, S., PIRES, A. J., COSTA BRANCO, P. J. “Obtaining the Magnetic Characteristics of an 8/6-Switched Reluctance Machine: FEM Analysis and Experimental Tests” *ISIE 2003*, Rio de Janeiro, Brasil.
- [35] SOTELO, G. G., 2003, *Estudo de uma Máquina de Relutância Variável para aplicações em armazenamento cinético de energia*, Tese de M.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.
- [36] KJAER, P. C., GRIBBLE, J. J., MILLER, T. J. E., “High-grade control of Switched Reluctance Machines”, *Conf. Rec. IEEE IAS Ann. Meeting*, pp. 84-91, 1996
- [37] AMOR, B. L., DESSAINT L. A., AKHRIF, O., OLIVIER, G., “Adaptive Feedback linearization for position control of a Switched Reluctance motor: Analysis and Simulation,” *Int. Journal. Adapt. Control Signal Process*, vol. 7.no. 2, pp. 117-136, Mar/Apr. 1993
- [38] ROCHFORD, C., KAVANAGH, R. C., EGAN M. G., MURPHY, J. M. D., “Development of smooth torque in Switched Reluctance Motors using self-learning Techniques” *EPE 93* pp. 14-19, 1993
- [39] MIR, S., HUSAIN, I., ELBULUK, M. E., “Switched Reluctance Motor Modelling with On-line Parameter Identification” *IEEE Transaction on Industry Applications* Vol. 34 n. 4 pp 776-783, Jul/Ago 1998
- [40] INANÇ, I., DERDIYOK, A., OZBULUR, V. ABUT, N., ARSLAN, F., “Torque ripple Reduction of a Switched Reluctance Motor including Mutual Inductances” *ISIE 97* Vol 2 pp 489-492.
- [41] RUSSA, K., HUSAIN, I., ELBULUK, M., “Self-tuning controller for switched reluctance motors,” *IEEE Transactions on Power Electronics*, vol. 15, no. 3, pp. 545-552, 2000
- [42] ELMAS, Ç., SAGIROGLU, S., ÇOLAK, I., BAL, G., “Modelling of a nonlinear Switched Reluctance Drive based on artificial Neural Networks” *Power Electronics and Variable Speed Drives Conference Proceedings* pp. 7 – 12, 1994

-
- [43] REAY, D. S., GREEN, T. C. E., WILLIAMS, B. W., “Applications of Associative Memory Neural Networks to the Control of a Switched Reluctance Motor” *Industrial Electronics, Control, and Instrumentation, 1993. Proceedings of the IECON '93, International Conference on*, 1993 pp. 200 -206 vol.1
- [44] O'DONOVAN, J. G., ROCHE, P. J., KAVANAGH, R. C., et al., “Neural network based torque ripple minimization in a switched reluctance motor Industrial Electronics” *Control and Instrumentation, 1994. IECON '94, 20th International Conference on*, pp. 1226 -1231 vol.2, 1994
- [45] ELMAS, Ç., BAY, O. F., “Modelling and Operation of a nonlinear Switched Reluctance Motor Drive Based on Fuzzy Logic”, *EPE 95*, vol. 3, pp 592-597, 1995.
- [46] BOLOGNANI, S., ZIGLIOTTO, M.,” Fuzzy logic control of a switched reluctance motor drive” *IEEE Transactions on Industry Applications*, Vol 32, n.5, Set/Out, pp. 1063-1068, 1996.
- [47] RODRIGUES, M. G., SUEMITSU, W. I., COSTA BRANCO, P.J., “Fuzzy Logic Torque Ripple Reduction by Turn-off Angle Compensation for Switched Reluctance Motors” *IEEE Transactions on Industrial Electronics.* , Vol. 48, n. 3, pp. 711-715, Jun. 2001
- [48] BARRASS, P. G., MECROW, B. C., “Flux and torque control of switched reluctance machines” *IEE Proceedings in Electric Power Applications*, Volume: 145 n. 6, pp. 519 –527 Nov. 1998
- [49] ESHANI, M., FAHIMI, B., “Elimination of Position Sensors in Switched Reluctance Motor Drives: State of the Art and Future Trends” *Transaction on Industrial Electronics* v. 49, n. 1, pp. 40-47, 2002
- [50] ESHANI, M., HUSAIN, I., MAHAJAN, S., RAMANI, K. R., “New modulation encoding technique for indirect rotor position sensing in switched reluctance motors,” *IEEE Trans. Ind. Applications*, vol. 30, pp. 584-588, Jan./Fev. 1994
- [51] HUSAIN, I., ESHANI, M., KULKARNI, A. B., “Elimination of Discrete Position Sensor and Current Sensor in Switched Reluctance Motor Drive” *IEEE Transaction on Industry Applications* v. 28, n. 1, pp. 128-135, 1992
- [52] LAURENT, P., GABSI, M., MULTON, B., “Sensorless Rotor Position Analysis using Resonant Method for Switched Reluctance Motor” *IEEE IAS Annual Meeting* pp. 687-694, 1993
- [53] SURESH, G., FAHIMI, B., ESHANI, M., “Improvement of the accuracy and speed range in sensorless control of switched reluctance motors,” *IEEE APEC'98*, pp. 770-777, 1998
- [54] LYONS, J. P., MACMINN, S. R., PRESTON, M. A., “Flux/Current Methods for SRM Rotor Position Estimation” *IEEE IAS Annual Meeting* pp. 482-487, 1991
- [55] GALLAGOS-LOPEZ, G., KJAER, P. C., MILLER, T. J. E., “High-grade Position Estimation for SRM Drives using Flux Linkage/Current Correction Model” *IEEE Transaction on Industry Applications* v. 35, n. 4 pp. 859-869, 1999
- [56] HARRIS, W. D., LANG, J. H., “A Simple Motion estimator for Variable-Reluctance Motors” *Transaction on Industry Applications* v. 26, n. 2, pp. 237-243, 1990

-
- [57] LUMSDAIME, A., LANG, J. H., "State Observers for Variable-Reluctance Motors" *IEEE Transaction on Industrial Electronics*, v. 37, n. 2, pp. 133-142, 1990
- [58] BROSSE, A., HENNEBERGER, G., SCHNIEDERNEYER, M., et. al, "Sensorless control of a SRM at low speeds and Standstill based on signal power measurement" *IEEE IECON'98*, pp. 1538-1543, 1998
- [59] SURESH, G.; FAHIMI, B.; RAHMAN, K.M.; EHSANI, M., "Inductance based position encoding for sensorless SRM drives"; *Power Electronics Specialists Conference, 1999. PESC 99*. Vol. 2 pp. 832 - 837
- [60] HUSAIN, I., ESHANI, M., "Rotor Position Sensing in Switched Reluctance Motor Drives by Measuring Mutually Induced Voltages," *IEEE Transaction on Industry Applications* v. 30, pp. 665-672, 1994
- [61] MA. B., FENG, W., LIU, T., CHEN, C., "Design and Implementation of a Sensorless Switched Reluctance Drive System" *IEEE Transaction on Aerospace and Electronic Systems* v. 34, n. 4, pp. 1193-1206, 1998
- [62] ACARNLEY, P. P., HILL, R. J., HOOPER, C. W., "Detection of Rotor Position in stepping and Switched Motors by monitoring of Current Waveforms" *IEEE Transaction on Industrial Electronics*, v. 32, n. 3, pp. 215-222, Ago. 1985
- [63] PANDA, S. K., AMARATUNGA, G., "Comparison of Two Techniques for closed-loop Drive of VR Step Motors Without Direct Rotor Position Sensing" *IEEE Transaction on Industrial Electronics*, v. 38, n. 2, pp. 95-101, 1991
- [64] ESHANI, M., HUSAIN, I., RAMANI, K. R., "An Analysis of the error in Indirect Rotor Position Sensing of SR motors" *IECON 91* pp: 295-300
- [65] AL-BAHADLY, I. H., "Magnetically based Sensorless Switched Reluctance drive for General Purpose Applications", *Journal of Applied Physics* vol. 87 No 9 May/2000 pp. 5956-5968
- [66] HANG, S., HUANG, C., LIN Y., "Sensorless Speed Identification of Vector-Controlled Induction drives via Neural Network based estimation" *Electric Power Systems Research* v. 48 pp. 1-10, 1998
- [67] BEN-BRAHIM, L., TADAKUDA, S., AKDAG, A., "Speed Control of Induction Motor Without Rotational Transducers" *IEEE Transaction on Industry Applications* v. 35, n. 4, pp. 844-849, 1999
- [68] CINCOTTI, S., FANNI, A., MARCHESI, M., SERRI, A., "An Artificial Neural Network Position Estimator for a Variable Reluctance Linear Actuator" *Power Electronics Specialists Conference, 1996. PESC '96 Record, 27th Annual IEEE* 1Vol. 1 1996, pp. 695-700
- [69] ERTUGRUL, N., CHEOK, A. D. "Indirect Angle Estimation in Switched Reluctance Motor Drives using fuzzy logic Based motor model" *IEEE Transaction on Power Electronics* vol. 15 No 6 Nov/2000 pp 1029-1044

-
- [70] KOSAKA, T., OCHIAI, K., MATSUI, N., “Sensorless Control of SRM using Magnetizing Curves” *Electrical Engineering in Japan*, Vol. 135, No. 2, 2001, pp. 60-68
- [71] STRONACH, A. F., VAS, P., “Design, DSP Implementation, and Performance of artificial-intelligence-based speed estimators for Electromechanical Drives” *IEE Proceedings – Control Theory Applications* v. 145, N. 2 pp. 197-203 –Março 1998
- [72] SHARAMM, D. S., GREEN, T. C. E., WILLIAMS, B. W., “Optimum Commutation-Current Profile on Torque Linearization of Switched Reluctance Motors” *ICEM '92 Manchester Conference Proceedings*, pp. 484-488, Manchester, Set. 1992
- [73] STEIERT, U., SPATH, H., “Torque Control of the Doubly-Salient Reluctance Motor”, *ETEP*, v.3, n. 4, Jul/Ago 1993
- [74] STIEBLER, M., GE, J., “A Low Voltage Switched Reluctance Motor with Experimentally Optimized Control” *ICEM '92 Manchester Conference Proceedings*, pp. 532-536, Manchester, Set. 1992
- [75] RODRIGUES, M. G., 1997, *Controle de um motor de relutância variável usando lógica fuzzy*, Tese de M.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.
- [76] BOTHE, H.-H. , *Neuro-fuzzy Methoden*,. Springer-Verlag, Berlin-Heidelberg, 1997
- [77] LAZZERINI, B., REYNERI, L. M., CHIABERGE, M., “A *Neuro-fuzzy* approach to hybrid Intelligent Control” *IEEE Transaction on Industry Applications*, v. 35, n. 2, Mar/Abr 1999, pp. 413-424.
- [78] LI, W., “Design of Hybrid Fuzzy Logic Proportional Plus Conventional Integral-Derivative Controller”, *IEEE Transaction on Fuzzy Systems*, v. 6, n. 4, pp. 449-463, Nov. 1998.
- [79] HENRIQUES, L. O. P., ROLIM, L. G., SUEMITSU, W. I., COSTA BRANCO, P. J., DENTE, J. A., “Torque ripple minimization in switched reluctance drive by *Neuro-fuzzy* compensation”, *IEEE Transactions on Magnetics*, Vol. 36, no. 5, Sep 2000, pp 3592-3594
- [80] JANG, J. J. R., “ANFIS – Adaptive-Network-based Fuzzy Inference System,” *IEEE Transaction on Systems, man and Cybernetics*, vol. 23 no 3 May/June 1993, pp. 665-685
- [81] ISLAM, M. S., HUSAIN, I., “Torque-ripple minimization with Indirect Position and Speed Sensing for SR Motors” *IEEE Transaction on Industrial Electronics*, Vol. 47 n. 5 Out 2000 pp 1126-1133
- [82] COSTA BRANCO, P. J., 1998, *Aprendizagem por exemplos utilizando lógica fuzzy na modelização e controlo de um accionamento electro-hidráulico*, Tese de D.Sc., IST/UTL, Lisboa, Portugal.
- [83] JANG, J-S. R., SUN, C-T., “*Neuro-fuzzy* Modelling and Control”, *Proceedings of the IEEE*, vol 83, pp. 378-405. 1994.
- [84] Mathworks, Inc., *Fuzzy Logic Toolbox User's Guide*, v. 2, Jan. 1998

-
- [85] MESE, E., TORREY, D. A., “Optimal Phase Selection for a Rotor position Estimation in a Sensorless Switched Reluctance motor Drive” ICEM 2000, Espoo, Finland, Aug 20
- [86] PIMENTEL, D. G. M., 2003, *Análise e Implementação de um Compensador Síncrono Estático*, Projeto Final de Curso, UFRJ, Rio de Janeiro, RJ, Brasil
- [87] VUKOSAVIC, S., STEFANOVIC, V. R., “SRM inverter Topologies: A Comparative evaluation” *IEEE Transaction on Industry Applications* v. 27, n. 6, pp. 1034-1047 Nov/Dez 1991
- [88] KJAER, P. C., GALLAGOS-LÓPEZ, G., “Single Sensor Current Regulation in Switched Reluctance Motor Drives” *IEEE Transaction on Industry Applications*, v.34, n. 3, pp. 444-45, Mai/Jun 1998.
- [89] KUO, B. C., CASSAT, A., “On Current Detection in Variable-reluctance Step Motors” *Proc. of Sixty Annual Symp. on Incremental Motion Control Systems and Devices*, Urbana-Champaign, pp. 205-220, Mai 1977.
- [90] BAKHUIZEN, A. J. C., “ On Self-synchronization of Stepping Motors” *Proc. of the Int. Conf. on Stepping Motors and Systems*, pp. 77-83 Leeds, Set 1979.
- [91] ZADEH, L. A., “fuzzy sets”, *Inform and control*, 8,338-353, 1965
- [92] SOUSA, G. C. D., BOSE, B. K., “A Fuzzy Set Theory based Control of a Phase-controlled Converter DC Machine Drive” *IEEE Transaction on Industry Applications*, v. 30, n. 1, pp. 34-44, Jan/Fev 1994
- [93] SUGENO, M., *Industrial Applications of Fuzzy Control*, Elsevier Science Pub. Co, 1985
- [94] ROSENBLATT, F., *Principles of Neurodynamics*. Washington, DC. : Spartan Books, 1962.
- [95] WIDROW, B., IEHR, M. A., “30 years of adaptive neural networks: Perceptron, Adaline, and Backpropagation”, *Proceedings of the IEEE* v. 78, pp. 1415-1442, 1990.
- [96] POGGIO, T., GIROSI, F., “Network for approximation and learning”, *Proceeding of the IEEE* v.78, pp.1481-1497, 1990.
- [97] HAYKIN, S., *Neural Networks, a Comprehensive Foundation*, Nova Iorque, Macmillan - IEEE Press, 1994.
- [98] BRAGA, A. P., LUDERMIR, T. B., CARVALHO, A. P. F., “Fundamentos de redes neurais artificiais”, *11ª Escola de computação*, Rio de Janeiro Jul. 1998

Apêndice A

Sistema Experimental

A.1 Considerações Gerais

Este apêndice apresenta uma descrição detalhada do sistema de acionamento e do motor, bem como uma explanação das características físicas e mecânicas do motor.

A.2 Descrição detalhada do sistema de acionamento.

O sistema de acionamento consiste em:

- Um computador “Athlon XP” 1.6 GHz que serve como base para o algoritmo de controle desenvolvido em linguagem C em ponto flutuante.
- Um conversor de eletrônica de potência clássico modificado [87] para alimentar o motor.
- Um motor de relutância variável.

Possui ainda, um gerador de corrente contínua que alimenta uma carga resistiva de 500W, além das interfaces de aquisição de dados. A Figura 156 ilustra o sistema implementado.

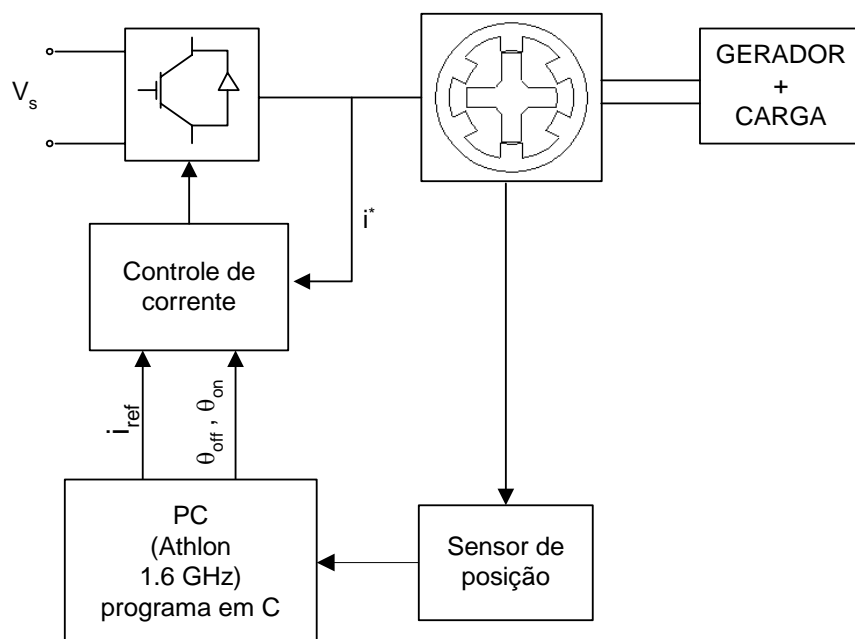


Figura 156 - Diagrama de blocos do sistema implantado no Laboratório de Eletrônica de Potência

A.2.1 Conversor

O conversor representado no diagrama por uma chave semicondutora é constituído basicamente por 6 chaves semicondutoras IGBT's (*Insulated Gate Bipolar Transistor*) e por 6 diodos *freeswheeling* em anti-paralelo com o propósito de proteger os IGBT's na ocorrência de tensão reversa. Sua entrada é uma tensão contínua V_s proveniente de uma ponte retificadora trifásica a diodos. E sua saída irá alimentar as três fases do motor de relutância variável. O esquema do conversor utilizado está mostrado na Figura 157. Esta configuração para o conversor foi escolhida, por possuir a habilidade de operar as fases de maneira independente entre si, além de ser extensivamente utilizada em diversos experimentos [87].. Este conversor possui a desvantagem de necessitar um número $2N$ de chaves, sendo N o número de fases do motor, e de possuir uma tensão de desmagnetização relativamente baixa a altas velocidades. Caso houver a perda de uma fase de alimentação, as duas outras continuarão a alimentar o motor de relutância variável, sendo este capaz de funcionar com somente duas das suas três fases. Porém com redução de velocidade.




Figura 157 - Conversor

Existe ainda um IGBT que se encontra em série com o conversor propriamente dito que tem a função de protegê-lo de sobrecorrentes e também para fazer o controle de histerese da corrente. Há também na entrada do conversor, um capacitor e um indutor com a função de filtragem da tensão retificada pela ponte retificadora trifásica da diodos.

Esta chave é acionada por um controle de histerese analógico, que compara uma corrente de referência com as leituras dos sensores de efeito *hall* de corrente conectados nas três fases do motor. Para este controle é necessário que se faça a leitura das correntes em cada

uma das 3 fases. Existem trabalhos onde um único sensor é utilizado para se fazer a estimação das correntes nas 3 fases. Entretanto, existe também um outro sensor no link CC com o intuito de proteger o circuito [88]. Esta proteção é feita conjuntamente, neste nosso trabalho, através das correntes nas três fases.

As outras 6 chaves servem somente para selecionar qual fase será alimentada. Isto é feito através do controle *fuzzy* gerado pelo computador que estabelece os ângulos de energização e desenergização das chaves.

A.2.2 Proteção de sobrecorrente e controle de corrente de histerese

A proteção de sobrecorrente e o controle de corrente de histerese são feitos analogicamente através de uma placa de circuito impresso próxima ao conversor conforme observamos na Figura 158.

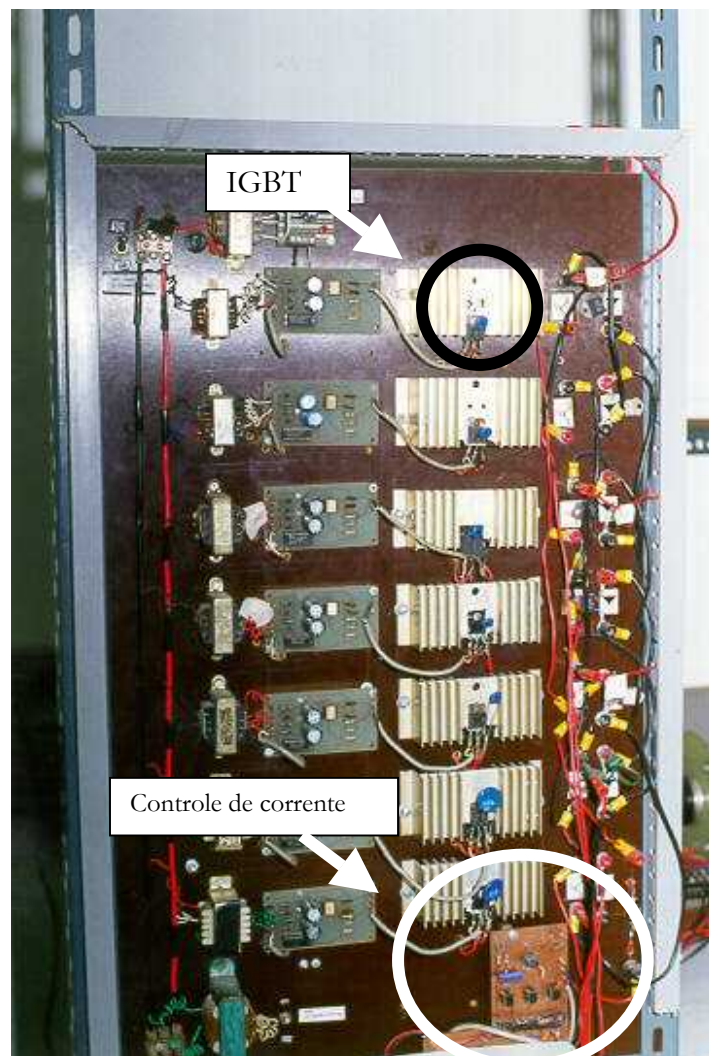


Figura 158 - Foto do acionamento de Relutância Variável

A proteção de sobrecorrente é obtida através da comparação entre uma corrente de referência (fixada pelo operador) e as correntes das fases do motor de relutância variável. Se a corrente ultrapassar o valor definido, a saída irá interromper os pulsos vindos do computador para os IGBT's do conversor.

O controle de histerese analógico funciona da seguinte maneira: As correntes nas fases são comparadas com uma corrente imposta pelo controle *fuzzy* vindo do computador. Desta comparação, uma corrente é gerada após a passagem das correntes de cada fase por um amplificador operacional. Após, é utilizado um oscilador para gerar uma corrente pulsante de histerese que será então enviada para um comparador cujas entradas são a corrente pulsante e a corrente de cada fase e daí enviada para os IGBT's que se encontram em série com os enrolamentos de fase.

A.2.3 Sensor de posição

Para o perfeito funcionamento do motor de relutância variável, o controle necessita da informação da posição do rotor em relação aos enrolamentos concentrados do estator. Isto é necessário para que se liguem e desliguem as chaves semicondutoras IGBT's nos momentos onde a indutância em cada enrolamento é crescente ou decrescente, respectivamente.

Portanto, é necessária a utilização deste sensor para suprir a informação da posição do rotor para o controle. Apesar disto, existem pesquisas com o objetivo de se retirar este sensor, por ele ser oneroso financeiramente para o seu uso em um equipamento comercial, além de não ser tão robusto quanto o resto do sistema [19].

Existem 2 grandes razões para se eliminar sensores: Reduzir custos e aumentar a confiabilidade, adaptando o acionamento para funcionar em ambientes nocivos [14].

Pode-se dividir em duas maneiras os métodos como o sistema funciona sem o sensor: Através de um controle de malha aberta [89] ou através de um controle com sensores de corrente [90].

O sensor que utilizamos nos entrega na sua saída uma palavra digital de 10 bits em código GRAY. Com isto temos uma resolução angular de 0,3515625 graus.

Esta palavra é enviada diretamente para uma entrada digital da placa de aquisição de dados.

A.2.4 Placa de aquisição de dados

Como foi observado anteriormente, é necessária a realimentação da posição do rotor, através do sensor de posição, e das correntes de fase através dos transformadores de corrente. Para que estas tarefas sejam executadas, utilizamos uma placa de aquisição de dados para executar estas realimentações. Além disto, a placa terá a tarefa de também coordenar os disparos das chaves que acionarão o motor de relutância variável. Deste modo, o controle do acionamento é feito através de um programa que, de acordo com os valores de posição do rotor, das correntes de fase e obviamente da estratégia de controle, determina quais e quando as chaves do conversor deverão ser acionadas para que o motor apresente o comportamento desejado.

A placa utilizada é a PCL-812PG, que opera com conversão A/D em ponto fixo.

A placa de aquisição de dados possui os seguintes recursos:

- 16 entradas de dados digitais
- 16 saídas de dados digitais
- 16 canais de conversão A/D multiplexados de 12 bits com taxa máxima de conversão de 30KHz
- 2 canais de conversão D/A multiplexados de 12 bits
- 1 contador programável com taxas de 0.5MHz a 35 minutos/pulso

Sua entrada digital constitui nos dados vindos do sensor de posição num formato de 10 bits, e a sua saída é a palavra que habilita as chaves semicondutoras e que irá ser utilizada no controle de histerese.

Sua entrada analógica é composta pelas correntes de cada fase do motor de relutância variável e sua saída analógica é a corrente imposta pelo controle $fuzzy$ para ser comparada no controle de histerese.

Apêndice B

Lógica *Fuzzy* e Redes Neurais

B.1 Considerações Gerais

Este apêndice tem como objetivos fazer uma revisão resumida de lógica *fuzzy* e redes neurais.

Na seção B.2, apresentaremos uma abordagem básica mínima para a compreensão da teoria *fuzzy*.

Na seção B.3, apresentaremos uma revisão sucinta sobre redes neurais artificiais.

B.2 Lógica *Fuzzy*

B.2.1 Considerações Iniciais

A primeira descrição matemática da lógica *fuzzy* foi feita por L. A. Zadeh [91].

A lógica *fuzzy* é uma metodologia muito eficiente quando se necessita trabalhar com informações inexatas, imprecisas, incompletas através de uma sistemática rigorosa. Os seres humanos são capazes de trabalhar de maneira efetiva com este tipo de lógica.

É uma lógica bastante utilizada quando existe a necessidade de se trabalhar com sistemas onde há uma difícil representação matemática do problema.

“Através da lógica *fuzzy* é possível manipular dados numéricos e conhecimentos lingüísticos simultaneamente. Com ela, gera-se um mapeamento não linear de um conjunto de dados de entrada em uma saída escalar, isto é, mapeia-se números em números. A teoria dos conjuntos e da lógica *fuzzy* estabelecem a maneira como é feito este mapeamento”[9].

A modelagem *fuzzy* descreve o comportamento do sistema usando linguagem natural baseada na lógica *fuzzy* utilizando conjuntos *fuzzy* considerando os conceitos humanos. Um modelo *fuzzy* é caracterizado pelo conjunto de regras que expressam a relação entre as variáveis do sistema. Cada regra representaria a descrição local da dinâmica do sistema e é

composta por uma parte antecedente (condição da regra) e uma parte conseqüente (conclusão da regra).

B.2.2 Sistema Lógico *Fuzzy*

O esquema básico de um sistema lógico *fuzzy* (SLF) pode ser representado pela

Figura 159.

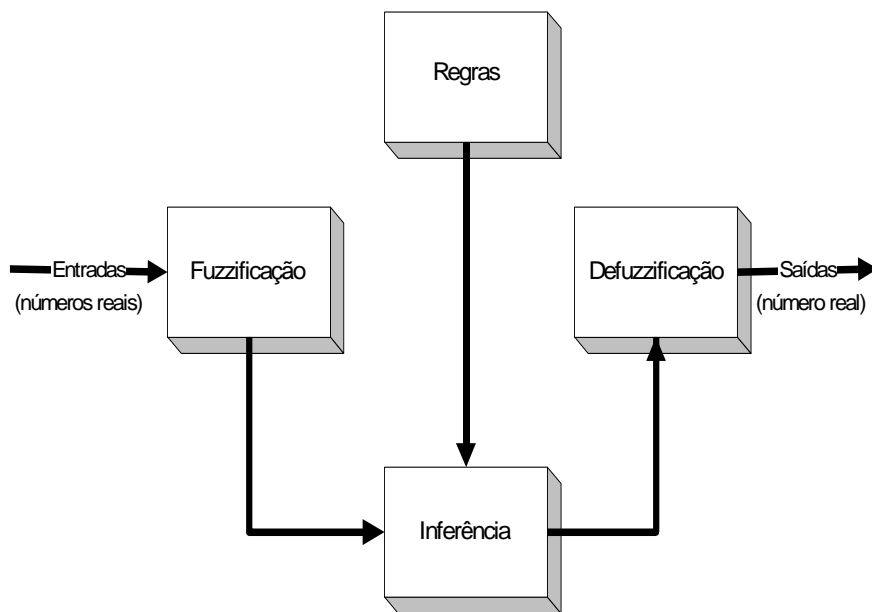


Figura 159 - Sistema de lógica *fuzzy*

Para podermos manipular de maneira coerente este esquema devemos definir alguns termos utilizados pelo controle *fuzzy* [9],[92].

B.2.3 Números *fuzzy* e *crisp*

Um número *crisp* \underline{x} pode ser representado, por exemplo, pela função de pertinência $\mu_A(\underline{x})$ sendo A um conjunto “*crisp*” como:

$$A = \{ \underline{x}; \mu_A(\underline{x}) \mid \mu_A(x) = \begin{cases} 0 & \text{se } x \in A \\ 1 & \text{se } x \notin A \end{cases} \}. \quad (51)$$

Um número *fuzzy* \underline{x} pode ser representado pela função de pertinência $\mu_A(\underline{x})$, sendo A , um conjunto *fuzzy*, como:

$$A = \{x; \mu_A(x) \mid \mu_A(x) \in [0,1]\}. \quad (52)$$




Figura 160 - Conjunto *crisp* e *fuzzy*.

B.2.4 Conjunto *fuzzy*

Se um elemento denominado genericamente por x do universo de discurso X pertence a um conjunto *fuzzy* A , então este conjunto *fuzzy* pode ser definido através da seguinte relação:

$$A = \{x; \mu_A(x) \mid \mu_A(x) \in [0,1]\} \quad (53)$$

ou

$$A = \{x; \mu_A(x) \mid \mu_A(x) \in X\} \quad (54)$$

onde $\mu_A(x)$ é a chamada função de pertinência.

A definição de conjunto *fuzzy* pode ser a extensão da definição do conjunto clássico (*crisp*). Se os valores da função de pertinência $\mu_A(x)$ ficam restritos a 0 e 1, então A fica restrito ao conjunto clássico.

Existem outros modos de se representar um conjunto *fuzzy*, dos quais um está representado pela equação (55):

$$A = \begin{cases} \sum_{x_i \in X} \frac{\mu_A(x_i)}{x_i} & \text{se } X \text{ é discreto} \\ \int_x \frac{\mu_A(x)}{x} & \text{se } X \text{ é contínuo} \end{cases} \quad (55)$$

Um exemplo de conjunto $fuzzy$ contínuo, representado graficamente, é mostrado na Figura 161. Tal figura mostra o conjunto zero e sua função de pertinência triangular. Como veremos adiante, muitas são as formas de função de pertinência.




Figura 161 - Conjunto $fuzzy$ zero

B.2.5 Função de Pertinência

Existem várias formas para se representar uma função de pertinência, das quais podemos apresentar as seguintes:

- Função de pertinência seno (Figura 162):

$$\mu_{A_i^j}(x_i') = \frac{1}{1 + \left(\frac{x_i' - c_i'}{a_i'} \right)^2 2b_i'} \quad (56)$$

- Função de pertinência trapezoidal (Figura 163)

$$\mu_{A_i^j}(x_i') = \max\left(0, \min\left[\frac{(x_i' - a_i')}{(b_i' - a_i')}, 1, \frac{(d_i' - x_i')}{(d_i' - c_i')}\right]\right) \quad (57)$$

- Função de pertinência triangular (Figura 164)

$$\mu_{A_i^j}(x_i') = \max\left(0, \min\left[\frac{(x_i' - a_i')}{(b_i' - a_i')}, \frac{(c_i' - x_i')}{(c_i' - b_i')}\right]\right) \quad (58)$$

- Função de pertinência gaussiana (Figura 165)

$$\mu_{A_i^j}(x_i') = a_i^j \exp\left[-\frac{1}{2} \left(\frac{x_i' - b_i^j}{c_i^j} \right)^2\right] \quad (59)$$

- Função de pertinência sigmoidal

$$\mu_{A_i}(x_i') = \frac{1}{1 + \exp(-a_i'(x_i' - c_i'))} \quad (60)$$




Figura 162 - Função de pertinência seno




Figura 163 - Função de pertinência trapezoidal




Figura 164 - Função de pertinência triangular




Figura 165 - Função de pertinência gaussiana

Atualmente têm sido usados procedimentos de otimização para criar funções de pertinência mais elaboradas.

B.2.6 Operações com conjuntos $fuzzy$

Sejam dois subconjuntos $fuzzy$ A e B definidos em U, cujas funções de pertinência são $\mu_A(u)$ e $\mu_B(u)$ respectivamente, sendo $u \in U$. Através destes conjuntos definem-se as seguintes operações:

União: O conjunto $fuzzy$ resultante da união dos conjuntos A e B, denotado por $A \cup B$, é representado pela Figura 169 e tem como função de pertinência:

$$\mu_{A \cup B}(u) = \max\{\mu_A(u); \mu_B(u)\} \quad (61)$$

Interseção: O conjunto *fuzzy* resultante da interseção dos conjuntos A e B, denotado por $A \cap B$, é representado pela Figura 168 e tem a função de pertinência dada por:

$$\mu_{A \cap B}(u) = \min\{\mu_A(u); \mu_B(u)\} \quad (62)$$

Complemento: O complemento de um conjunto *fuzzy* A é também um conjunto *fuzzy* denotado por $\sim A$, é representado pela Figura 167, com função de pertinência dada por:

$$\mu_{\sim A}(u) = 1 - \mu_A(u) \quad (63)$$

Dados 2 conjuntos A e B temos:




Figura 166 - Conjuntos A e B




Figura 167 - Conjunto $\sim A$.




Figura 168 - Conjunto $A \cap B$




Figura 169 - Conjunto por $A \cup B$

B.2.7 Variáveis lingüísticas *fuzzy*

O conceito de variáveis lingüísticas é de extrema importância na lógica *fuzzy*. Elas caracterizam a possibilidade de se trabalhar com conceitos incertos através de uma metodologia onde variáveis têm seus valores associados a palavras ou sentenças dentro de uma linguagem natural ou não, em vez de estarem associadas a valores numéricos.

Como exemplo podemos utilizar a variável lingüística *Temperatura*, seus valores numéricos são representados por u pertencentes a U . Esta variável lingüística *Temperatura* finalmente pode ser definida por um conjunto $Z(\textit{Temperatura})$, cujos componentes cobrem o universo de discurso U . Um possível conjunto pode ser:

$$Z(\textit{Temperatura}) = \{\text{frio}, \text{ótimo}, \text{quente}\}, \text{ com } u \in U = [-1, 1].$$

Podemos representar graficamente esta variável *Temperatura* através da Figura 170:

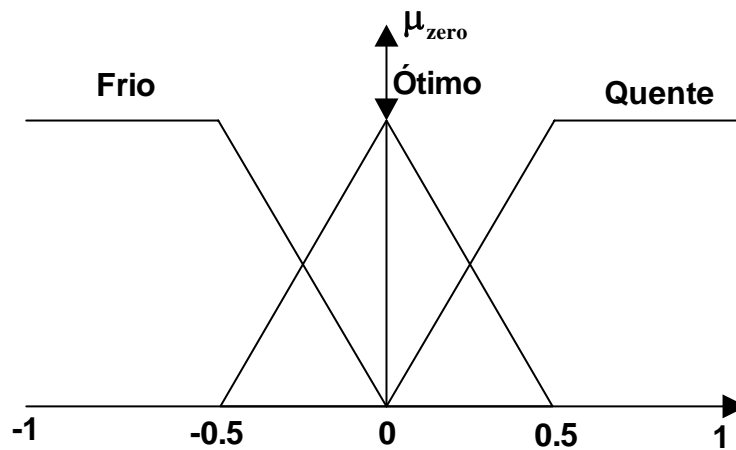


Figura 170 - Representação gráfica da variável *Temperatura*

B.2.8 Lógica *Fuzzy*

Uma das principais componentes de um sistema *Fuzzy* são as regras, estas regras são representadas através de implicações lógicas “SE-ENTÃO” assumindo a forma [91]:

Se x é A então y é B

onde A e B são valores lingüísticos definidos por conjuntos *fuzzy* sobre universos de discursos X e Y respectivamente. Nomeia-se “ x é A ” de antecedente e “ y é B ” de conseqüente. Podemos exemplificar esta lógica através das seguintes expressões lingüísticas:

- Se *Temperatura* é frio então ligue aquecedor
- Se força é grande então diminua a pressão

B.2.9 Inferência $fuzzy$

A inferência $fuzzy$ é utilizada para se obter conclusões sobre um conjunto de leis “SE-ENTÃO”. Existem 2 importantes formas para regras de inferência:

A) Modus ponens

Premissa 1 (fato):	x é A
Premissa 2 (lei):	Se x é A então y é B
Conseqüência (conclusão):	y é B

Tabela 6 - Modus ponens

B) Modus tollens

Premissa 1 (fato):	y não é B
Premissa 2 (lei):	Se x é A então y é B
Conseqüência (conclusão):	x não é A

Tabela 7 - Modus tollens

Além disto, existem 2 tipos de sistema de inferência: Mamdani e Sugeno.

O sistema Mamdani é o mais comumente utilizado na metodologia $fuzzy$. Sua fuzzificação é feita baseada nas técnicas de defuzzificação.

O sistema Sugeno é similar em muitos aspectos ao sistema Mamdani, porém a diferença preponderante é que as funções de pertinência da saída são lineares ou constantes [93].

Enquanto o sistema de inferência Mamdani é do tipo:

Se x é A e y é B então z é C, onde A, B e C são variáveis linguísticas

O sistema de inferência de 1ª ordem Sugeno é:

Se x é A e y é B então $z = px + qy + r$, onde A e B são variáveis linguísticas e p, q e r são as variáveis conseqüentes numéricas.

Devido à dependência linear de cada regra ao sistema de variáveis de entrada (x e y), o sistema de inferência Sugeno é ideal para sistemas dinâmicos não lineares que possuem diferentes condições de operação.

Concluindo, podemos dizer que :O sistema de inferência Sugeno, por ser mais compacto e sua representação computacionalmente mais eficiente que o sistema Mamdani, é bem mais utilizado em técnicas adaptativas para criação de modelos $fuzzy$. Estas técnicas adaptativas podem ser usadas para criar funções de pertinência capazes de modelar, através dos dados, um melhor sistema $fuzzy$.

B.2.10 Defuzzificador

Na maioria das aplicações de SLF, é necessário ter-se uma saída escalar. Com esta finalidade, surge o defuzzificador que transforma a saída $fuzzy$ da máquina de inferência em um escalar. Dos muitos defuzzificadores que foram propostos na literatura, apresentaremos alguns tipos a seguir.

Defuzzificador máximo

Este defuzzificador examina o conjunto $fuzzy$ B e escolhe como saída o valor de y para o qual $\mu_B(y)$ é máximo. Isto pode levar a resultados enganosos porque somente o ponto máximo da FP da saída da máquina de inferência é considerado, independente da largura de sua base. Note que este método de defuzzificação só funciona quando $\mu_B(y)$ tem apenas um ponto máximo.

Defuzzificador média dos máximos

Este defuzzificador examina o conjunto $fuzzy$ B e acha os valores de y para os quais $\mu_B(y)$ é máximo. Então, a média desses valores é computada como saída. Neste método de defuzzificação, não existe problema algum de $\mu_B(y)$ ter dois máximos. Entretanto, se $\mu_B(y)$ tiver um único máximo, este método fica reduzido ao defuzzificador máximo e os resultados enganosos comentados podem ocorrer novamente.

Defuzzificador centróide

Este defuzzificador determina o centro de gravidade, \bar{y} , de B e usa este valor como saída do SLF. A centróide é obtida pela seguinte equação:

$$\bar{y} = \frac{[\int_S y \mu_B(y) dy]}{[\int_S \mu_B(y) dy]} \quad \text{para universo contínuo} \quad (64)$$

onde S é o suporte de $\mu_B(y)$. Frequentemente, S é discretizado de tal forma que \bar{y} pode ser aproximado pela seguinte equação que usa somatório ao invés de integral:

$$\bar{y} = \frac{[\sum_{i=1}^I y_i \mu_B(y_i)]}{[\sum_{i=1}^I \mu_B(y_i)]} \quad \text{para universo discreto} \quad (65)$$

O defuzzificador centróide é o melhor, pois leva em consideração toda a forma do conjunto B . Entretanto, tem a desvantagem de consumir muito tempo de processamento computacional.

Defuzzificador média das centróides

Considere \bar{Y}^1 o centro de gravidade do conjunto fuzzy B^1 (que é o consequente da lei $R^{(1)}$).

Este defuzzificador primeiro avalia $\mu_B(y)$ em \bar{Y}^1 e então calcula a saída do SLF como

$$y = \frac{[\sum_{l=1}^M \bar{y}^l \mu_{B^l}(\bar{y}^l)]}{[\sum_{l=1}^M \mu_{B^l}(\bar{y}^l)]} \quad (66)$$

É muito fácil usar (x) porque os centros de gravidade das funções de pertinência comumente usadas são conhecidos de antemão. Independente do método de inferência usado, a centróide de B^1 para uma função de pertinência triangular simétrica é sempre o vértice do triângulo e no caso de uma função gaussiana, é o seu centro.

B.3 Redes Neurais

O estudo das redes neurais data dos anos 1940, porém somente no final dos anos 1970 é que ressurgiu o interesse em se pesquisar este tipo de programação não algoritmada que tenta emular as operações processadas pelo cérebro. Este tipo de sistema tem a característica de possuir um processamento paralelo e distribuído, sendo este, composto por unidades de processamento simples que computam determinadas funções matemáticas (normalmente não-lineares). Tais unidades (neurônios) são dispostas em uma ou mais camadas e interligadas por um grande número de conexões, geralmente unidirecionais. O processamento em cada neurônio depende exclusivamente das entradas desta unidade e dos valores acumulados em uma pequena memória local do mesmo. Na maioria dos modelos, estas conexões estão associadas a pesos, os quais armazenam o conhecimento representado pelo modelo e servem para ponderar a entrada recebida por cada neurônio da

rede. O funcionamento destas redes é inspirado em uma estrutura física concebida pela natureza: o cérebro humano.

A utilização deste modelo para solucionar determinados problemas é bastante interessante, pois sua arquitetura interna permite um desempenho superior aos encontrados usando-se modelos convencionais. Para a solução de um determinado problema é necessária uma fase de aprendizagem, onde a rede neural recebe um conjunto de exemplos que devem traduzir grande parte das informações necessárias para que se obtenham respostas coerentes para o problema. Após esta fase, se utiliza a rede neural para se obter as saídas necessárias para nosso problema.




Figura 171 - Modelo de Rede Neural

Podemos dizer que existem três procedimentos de aprendizagem utilizados:

- Treinamento supervisionado, onde se tem a entrada e a saída, como exemplo podemos citar: Perceptron [94], ADALINE[95], GMDH, LQV, RBF (“*Radial Basis Function*”)[96]
- Treinamento por reforço, onde se tem a entrada e a certeza que a saída é certo ou errado
- Treinamento não-supervisionado, onde se tem somente a entrada., como exemplo podemos citar: Rede ART e Mapa de Kohonen [97].

A capacidade de aprender e posteriormente generalizar a informação aprendida são, sem dúvida, os maiores atrativos da solução de problemas através de redes neurais. A desenvoltura das redes neurais em trabalhar com dados não conhecidos a partir de dados anteriormente apresentados nos dá a liberdade de perceber que as redes neurais vão além de simplesmente mapear relações entrada-saída. Não obstante, as redes neurais são capazes de atuar como mapeadores universais de funções multivariáveis, com um custo computacional que cresce linearmente com o número de variáveis. Outras características importantes são a capacidade de auto-organização e de processamento temporal que aliadas àquelas anteriormente citadas, fazem das redes neurais artificiais uma ferramenta computacional extremamente poderosa e atrativa para a solução de problemas complexos [98].

A rede neural biológica é composta por neurônios que se comunicam entre si através de conexões chamadas sinapses. O nível de ativação do j -ésimo neurônio é representado pela sua variável de saída y_j . Esta saída é transmitida ao j -ésimo neurônio através da sinapse w_{ij} . O neurônio i soma as excitações recebidas de todos os N neurônios que atuam sobre ele, criando uma variável interna.

$$u_k = \sum_{j=1}^p w_{kj} x_j \quad (67)$$

e gera sua saída dada por

$$y_k = \varphi(u_k - \theta_k) \quad (68)$$

sendo φ , a função de ativação do neurônio

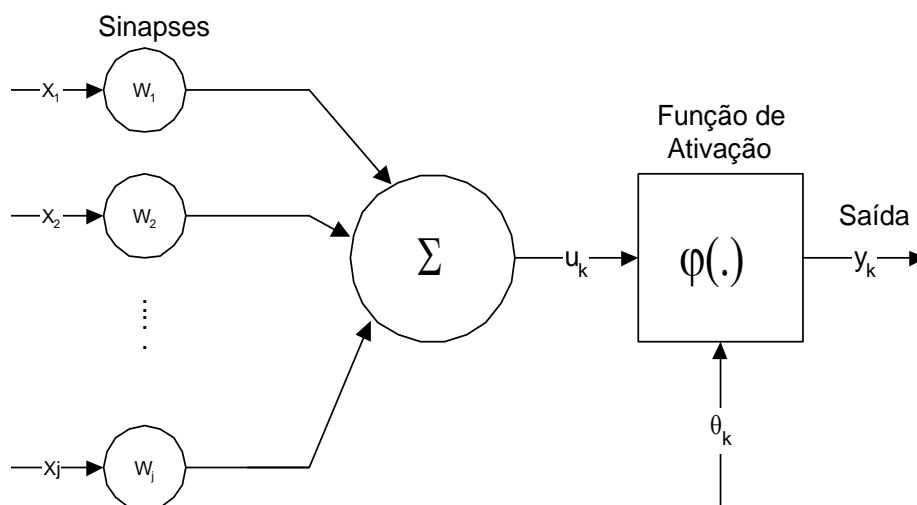


Figura 172 - Modelo de um Neurônio

O modelo neuronal pode ser dividido em três elementos básicos:

um conjunto de sinapses ou linhas de conexão, cada uma é caracterizada por possuir um peso. Especificamente, o sinal u_j da entrada da sinapse j que está conectada ao neurônio k é multiplicado pelo peso w_{kj} .

Um somador que soma todas as entradas, cada uma delas já com seu respectivo peso associado. Esta operação constitui uma combinação linear.

Uma função de ativação que pode ou não limitar a saída do neurônio. Normalmente, a função de ativação é uma sigmóide (Figura 173), uma função degrau ou uma função linear (Figura 174).




Figura 173 - Função de ativação sigmoidal




Figura 174 - Função de ativação linear

Um processo de aprendizagem das redes neurais é o algoritmo chamado “*backpropagation*”. Tem como característica básica a inexistência de sinapses entre neurônios de mesma camada, ou seja, um neurônio se liga aos neurônios da camada anterior e posterior através de suas entradas e saídas respectivamente. Assim, como esta estrutura não permite realimentações, o sistema é sempre estável.

Esta estratégia de aprendizagem acontece da seguinte maneira: Dado um determinado vetor de entrada x obtém-se uma saída y . Em cada apresentação de dados determina-se o valor do erro quadrático $E=(y_{ref}-y)^2$ e procede-se à alteração dos pesos sinápticos w_{ij} pelo método gradiente dado pela equação (69):

$$\nabla W_{ij} \propto -\gamma \frac{\partial E}{\partial w_{ij}} \quad (69)$$

Este processo se repete até que o erro para o conjunto de aprendizagem seja inferior a um certo valor pré-fixado. E este processo ocorre mais rápido ou não dependendo do valor da taxa de aprendizado (γ).

Apêndice C

Demonstração da confiabilidade do algoritmo de busca do valor de torque.

C.1 Introdução

Neste apêndice será apresentado um algoritmo importante para a funcionalidade da técnica da minimização de oscilação de torque e da eliminação do sensor de posição. O algoritmo visa encontrar o valor de torque do motor quando da inexistência de um sensor de torque disponível.

C.2 Algoritmo de busca do valor de torque

Devido à indisponibilidade de um equipamento capaz de fazer a leitura do valor de torque dinamicamente, bem como da impossibilidade física de conectar este sensor, optou-se em obter o valor do sinal de torque para a MRV utilizando-se uma tabela pré-calculada anteriormente através de elementos finitos.

Para confirmar a operacionalidade desta técnica baseada em uma interpolação dupla, têm-se como entradas da interpolação o sinal de posição do rotor e o valor da corrente de referência (θ e i_{ref}).

Inicialmente faz-se uma busca dos dois valores limítrofes entre os valores de entrada. Depois, buscamos na tabela de torque, os valores de torque correspondentes a cada um dos valores limítrofes (θ_{n-1} , θ_n , i_{n-1} , i_n) (Figura 175).

$$A=T(\theta_n, i_{n-1})$$

$$B=T(\theta_{n-1}, i_{n-1})$$

$$C=T(\theta_n, i_n)$$

$$D=T(\theta_{n-1}, i_n)$$

Inicialmente, faz-se uma interpolação para a curva gerada pelo plano paralelo a $\theta \times T$ e que passa por i_{n-1} .

$$E = B + \frac{(i - i_{n-1})(A - B)}{i_n - i_{n-1}}, \text{ sendo } E = T(\theta, i_{n-1}) \quad (70)$$

Do mesmo modo, faz-se a interpolação da curva gerada pelo plano paralelo a $\theta \times T$ e que passa por i_n .

$$F = D + \frac{(i - i_n)(C - D)}{i_{n-1} - i_n}, \text{ sendo } F = T(\theta, i_n) \quad (71)$$

Obtidos os dois valores de E e F podemos, neste momento, calcular o valor de $T(\theta, i)$.
Baseado nos resultados das equações (70) e (71), mais uma interpolação é feita

$$T(\theta, i) = E + \frac{(\theta - \theta_{n-1})(F - E)}{(\theta_n - \theta_{n-1})} \quad (72)$$




Figura 175 – Gráfico esquemático da interpolação dupla.

Com este algoritmo foram obtidos alguns resultados experimentais e comparados com os resultados simulados.

C.2.1 Resultados de simulação

Abaixo é apresentada a simulação para os casos de 2,5 A. (Figura 176 e Figura 177) e 3 A. (Figura 178 e Figura 179). Em uma primeira aproximação, utilizou-se uma carga constante de 0,2 N.m e uma de 0,3 N.m




Figura 176 – Curvas simuladas de correntes, torque, posição e velocidade sem carga e corrente de referência de 2,5A.




Figura 177 - Curvas simuladas de correntes, torque, posição e velocidade com carga de 0,2 N.m e corrente de referência de 2,5A.




Figura 178 – Curvas simuladas de correntes, torque, posição e velocidade com carga de 0,2 N.m e corrente de referência de 3A.




Figura 179 – Curvas simuladas de correntes, torque, posição e velocidade com carga de 0,3 N.m e corrente de referência de 3A.

C.2.2 Resultados Experimentais

Foram obtidos resultados experimentais com duas cargas: uma de 100 W e outra de 500W, sendo que em cada uma delas foram aplicadas correntes de 2,5 A ou 3 A.

Também foi obtido resultado sem carga.

As figuras (Figura 180, Figura 181, Figura 182) foram obtidas para o caso de 3A e as figuras (Figura 184 e Figura 185) para o caso de 2,5A. Obteve-se para o caso de 2,5A e carga de 500W, um resultado desfavorável (o motor não entrou em operação) por gerar um torque de carga superior ao torque elétrico gerado com os 2,5A.




Figura 180 – Curvas experimentais de correntes, torque, posição e velocidade com carga de 500 W e corrente de referência de 3A.

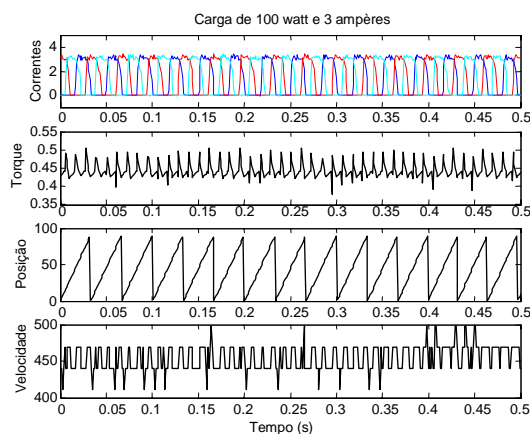


Figura 181 – Curvas experimentais de correntes, torque, posição e velocidade com carga de 100 W e corrente de referência de 3A.




Figura 182 – Curvas experimentais de correntes, torque, posição e velocidade sem carga e corrente de referência de 3A.




Figura 183 – Detalhe da Figura 182




Figura 184 – Curvas experimentais de correntes, torque, posição e velocidade com carga de 100 W e corrente de referência de 2.5A.




Figura 185 – Curvas experimentais de correntes, torque, posição e velocidade sem carga e corrente de referência de 2.5A.

C.2.3 Avaliação dos resultados

Foram analisadas algumas situações (experimentais e simuladas) onde a velocidade dos sistemas era semelhante. Foram notadas semelhanças em:

Simulado	Experimental
Com carga 0,3 e 3 A (veloc. ~127 rpm)	Carga de 100W e 2,5 A (veloc. ~140 rpm)
Com carga 0,3 e 3 A (veloc. ~75 rpm)	Carga de 500W e 3 A (veloc. ~90 rpm)

Tabela 8 – Casos simulados e experimentais

Uma aspecto interessante é que o sinal de torque possui, no momento de mudança (chaveamento) entre fases, uma curva de torque com característica diferente.

Isto ocorre porque o chaveamento entre fases é quase instantâneo nas simulações, o que é uma aproximação. Na realidade a corrente não se extingue instantaneamente quando ocorre o chaveamento, o que é comprovado experimentalmente.

Estes resultados encontrados confirmam a capacidade do algoritmo de busca do torque.

C.3 Considerações Finais

Neste item foi apresentada uma estratégia essencial para a operação do sistema proposto. Foram obtidos por meio de simulações e testes experimentais, resultados que comprovaram a confiabilidade do algoritmo de busca do torque.

Apêndice D

Publicações Científicas do Autor

L. O. P Henriques, P.J.C. Branco, L.G.B. Rolim, W.I. Suemitsu, e J.A. Dente, “Neuro fuzzy compensation of torque ripple in a switched reluctance drive” 6 TH International Conference on Modelling and Simulation of Electric Machines, Converters and Systems (ELECTRIMACS'99), Instituto Superior Técnico, Lisboa, Portugal. (1999)

L. O. P Henriques, P.J.C. Branco, L.G.B. Rolim, W.I. Suemitsu, e J.A. Dente, “Torque ripple minimization of switched reluctance drive using a *Neuro-fuzzy* control technique” V Congresso Brasileiro de Eletrônica de Potência (COBEP'99), Foz do Iguaçu, Brasil. (1999)

L. O. P Henriques, P.J.C. Branco, L.G.B. Rolim, W.I. Suemitsu, e J.A. Dente; “Torque ripple minimization in a switched reluctance drive by *Neuro-fuzzy* compensation” IEEE Transactions on Magnetics. Vol. 36, No. 5/Part 1, pp. 3592-3594, Setembro (2000)

L. O. P Henriques, P.J.C. Branco, L.G.B. Rolim, W.I. Suemitsu, e J.A. Dente “*Neuro-fuzzy* Compensation Strategy to minimize Torque Ripple in Switched Reluctance Motor Drives” 1st IFAC-Conference on MECHATRONIC SYSTEMS (Setembro/2000)

L. O. P Henriques, P.J.C. Branco, L.G.B. Rolim, W.I. Suemitsu “Automatic learning of pulse current shape for torque Ripple minimization in switched reluctance machines”, European Control Conference (ECC2001), pp. 232-237, Porto – Portugal (2001).

L. O. P Henriques, P.J.C. Branco, L.G.B. Rolim, W.I. Suemitsu “Two Automatic On-line New Schemes to Compensate the Torque Ripple of Switched Reluctance Machines: With and Without Torque Signal Measurement” 6th Online World Conference on Soft Computing in Industrial Applications (WSC6), On the Internet, September 10 - 24, 2001

L. O. P Henriques, P.J.C. Branco, L.G.B. Rolim, W.I. Suemitsu “Proposition of an Offline Learning Current Modulation for Torque-Ripple Reduction in Switched Reluctance Motors: Design and Experimental Evaluation”, IEEE Transactions on Industrial Electronics. Vol. 49, No. 3, pp. 665-676, Junho. (2002)

L. O. P Henriques, P.J.C. Branco, L.G.B. Rolim, W.I. Suemitsu “Review of the ripple reduction strategies in SRM”, Congresso Brasileiro de Automática (CBA2002), Natal, Brasil (2002)

L. O. P Henriques, P.J.C. Branco, L.G.B. Rolim, W.I. Suemitsu “Two Automatic On-line New Schemes to Compensate the Torque Ripple of Switched Reluctance Machines: With and Without Torque Signal Measurement” Roy, R., Koppen M., Ovaska S., Furuhashi, T., Hoffmann, F. (eds) *Soft Computing and Industry – Recent Applications*, Springer-Verlag London.

J.L. da Silva Neto, L G. Rolim, W. Suemitsu, L. O. Porto Henriques, P.J. Costa Branco, M. Godoy Simoes “Application of Learning Methodologies in Control of Power Electronics Drives” 2003 IEEE International Symposium on Industrial Electronics (ISIE 2003) Rio de Janeiro, Brasil, (2003)

L. O. P Henriques, L.G.B. Rolim, W.I. Suemitsu, P.J.C. Branco, “Development of a Neuro Fuzzy Technique for position sensor elimination in a SRM” VII Congresso Brasileiro de Eletrônica de Potência (COBEP 2003) – Fortaleza, Brasil (2003)

L. O. P Henriques, L.G.B. Rolim, W.I. Suemitsu, P.J.C. Branco “Uma Revisão das Estratégias de Redução de Oscilações de Conjugado no motor de relutância Chaveado” *Revista da Sociedade Brasileira de Eletrônica de Potência - SOBRAEP*. Brasil: , v.8, n.1, p.16 - 24, 2003.

L. O. P Henriques, P.J.C. Branco, L.G.B. Rolim, W.I. Suemitsu. “Development and Implementation of a Neuro Fuzzy Technique for position sensor elimination in a SRM” 2004 IEEE International Symposium on Industrial Electronics (ISIE 2004) Ajaccio, França, (2004).

Luís Oscar A. P. Henriques, Luís Guilherme B. Rolim, Paulo J. Costa Branco, Walter I. Suemitsu “Position sensor elimination using a Neuro-fuzzy Technique in a SRM: Project and Implementation” XV Congresso Brasileiro de Automática (CBA 2004) Gramado, Brasil (2004)