

Universidade Federal de Minas Gerais

Escola de Engenharia

Centro de Pesquisa e Desenvolvimento em Engenharia Elétrica

Estimação de Estados do Motor de Indução Utilizando Rede Neuro-Fuzzy com Aprendizado em Tempo Real

por

Régis Pinheiro Landim

Texto de Tese de Doutorado submetido à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Minas Gerais, como requisito parcial para a obtenção do título de Doutor em Engenharia Elétrica.

Orientador: Benjamim Rodrigues de Menezes

Co-Orientador : Walmir Matos Caminhas

20 de dezembro de 2000

Dedico este trabalho a todos que me apoiaram nesta jornada.

A Deus,

A Cleidimar Pinheiro e Rubens Landim, meus pais,

A Silvânia Antunes, minha esposa, e a Aymoré Filho, Francisco Neves, Reginaldo Roris, meus grandes amigos.

Agradecimentos

A Deus pela oportunidade de aprendizado e crescimento, e pela ajuda nos momentos difíceis.

Aos meus pais, Rubens e Cleidimar, pelo apoio e a minha esposa, Silvânia, pelo companheirismo.

Aos Professores Benjamim Rodrigues de Menezes e Walmir Matos Caminhas, pela orientação, incentivo, aprendizado e sobretudo pela amizade, desenvolvidos no decorrer deste trabalho.

Ao Professor Porfírio Cabaleiro Cortizo e aos colegas Francisco Neves e Gustavo Parma, pela amizade e pela grande contribuição na parte experimental deste trabalho.

Aos Professores Fernando Gomide, Selênio R. Silva, Braz C. Filho, Luís Eduardo Borges e Pyramo P. da Costa Jr pelas valiosas contribuições técnicas neste trabalho, e aos Professores Luís A. Aguirre, Antônio de P. Braga, José Carlos R. Oliveira, Paulo F. Seixas, José L. Silvino e Evandro Araújo pelos valiosos ensinamentos nas disciplinas.

Aos amigos da pós-graduação, em especial a “turma do almoço”, pelo agradável convívio.

A Coordenação do PPGE, pelo empenho na melhoria do Curso e das condições oferecidas a nós, alunos, e aos funcionários da secretaria Rojane Castro e Heitor, pela amizade e pelo apoio às minhas atividades como aluno do Programa.

A todos os professores, alunos e funcionários do CPDEE/UFMG e do DEESP/UFPE que direta ou indiretamente contribuíram para a realização deste trabalho.

À CAPES e à FAPEMIG, pelo suporte financeiro.

*“Na vida só dá fruto o que custa trabalho de corpo e de espírito. Lutar, lutar sempre,
eis a vida. Com alma forte e nobre intenção pode-se conseguir moralmente tudo que se
deseja.”*

Scheffel (poeta alemão)

Resumo

Este trabalho trata do problema de observação de estados para o controle de sistemas dinâmicos rápidos, não-lineares, com distúrbios, em tempo real. Nele, é apresentada uma nova proposta de observação de estados de sistemas dinâmicos em tempo real utilizando o algoritmo Neo-Fuzzy-Neuron com treinamento *on-line*, com convergência em apenas um passo. Para este tipo de treinamento, utiliza-se uma *equação de mapeamento* entre os estados observados e os estados a serem comparados com os medidos.

Foi demonstrado um teorema que permite a adequada escolha de uma equação de mapeamento, dentre aquelas candidatas. Foram desenvolvidas expressões válidas para equações de mapeamento com determinadas características. Estas expressões podem ser aplicadas no problema de observação de qualquer sistema dinâmico em tempo real que possibilite a obtenção deste tipo de equações de mapeamento. Em seguida, foi restringido o universo de equações de mapeamento para uma determinada classe, sendo demonstrada uma expressão para atualização dos pesos com taxa de aprendizado ótima, que levará o observador à convergência em apenas um passo de cálculo.

Baseados nesta proposta, foram desenvolvidos quatro observadores de estados para a máquina de indução (um observador de fluxos de rotor e três observadores de velocidade rotórica) com equações de mapeamento pertencentes à referida classe. Estes observadores foram aplicados no acionamento de uma máquina de indução, que é um sistema dinâmico não-linear, multivariável, acoplado, sujeito a distúrbios, cujo controle deve ser feito em tempo real e cujo tempo de resposta deve ser rápido o suficiente para um satisfatório desempenho dinâmico do acionamento. Estes observadores foram validados através de análises e testes de simulação e experimentais no controle vetorial de um motor de indução com rotor em gaiola.

Abstract

This work treats the problem of state observation for the control of fast, non-linear dynamic systems, with disturbances, in real time. A new algorithm for state observation of dynamic systems based on a Neo-Fuzzy-Neuron with *on-line* training and convergence in just one step is proposed. It was necessary the use of a *mapping equation* between the observed states and the states which are supposed to be compared with the measured ones.

A theorem which allows the appropriate choice of a mapping equation was introduced. Expressions were developed for mapping equations with specific characteristics. These expressions can be extended to the observation problem of any dynamic system in real time which makes possible the obtainment of this kind of mapping equation. After that, the universe of mapping equations was restricted to a certain class. It was demonstrated an expression for the updating of the weights with optimum learning rate, which guarantees the observer convergence in just one step.

Based on this proposal, four induction machine state observers were developed (one rotor fluxes observer and three rotor speed observers) with mapping equations belonging to the referred class. These observers were applied in an induction motor drive system. Induction machines are non-linear, multivariable and coupled dynamic systems, subjected to disturbances, whose control should be made in real time and whose time response should be fast enough for a satisfactory dynamic performance of the electric drive. These observers were validated through analyzes and simulations and experimental tests in the vector control of a squirrel-cage induction motor.

Sumário

Dedicatória	i
Agradecimentos	ii
Epígrafe	iii
Resumo	iv
Abstract	v
Sumário	vi
Lista de Símbolos	1
Lista de Figuras	5
Lista de Tabelas	11
Capítulo 1 - Introdução Geral	13
1.1 - Introdução	13
1.2 - Estado da Arte em Observadores de Fluxo para Acionamentos Elétricos do Motor de Indução	15
1.3 - Estado da Arte em Observadores de Velocidade para Acionamentos Elétricos do Motor de Indução	21

1.4 - Contribuições da Tese	28
1.5 - Conclusões e Organização do Texto	29
Capítulo 2 - Introdução às Redes Neo-fuzzy-Neuron	31
2.1 - Introdução	31
2.2 - Algoritmo Neo-Fuzzy-Neuron (NFN)	33
2.2.1 - Estrutura do Neo-Fuzzy-Neuron [108]	33
2.2.2 - Algoritmo de Aprendizado [108]	36
2.2.2.1 - Atualização dos Pesos com Taxa de Aprendizado Ótima [14]	37
2.2.3 - Neo-Fuzzy-Neuron Generalizado [14]	40
2.3 - Conclusões	41
Capítulo 3 - Observadores de Estados Neo-Fuzzy-Neuron	43
3.1 - Introdução	43
3.2 - Observador de Estados NFN [53]	44
3.2.1 - Equação de Atualização dos Pesos com Taxa de Aprendizado Ótima para uma Determinada Classe de Equações de Mapeamento	48
3.3 - Observador de Fluxo Rotórico Utilizando o Algoritmo Neo-Fuzzy-Neuron [50] ..	53
3.3.1 - Definição da topologia da rede	53
3.3.2 - Desenvolvimento do Observador	55

3.3.2.1 - Equação de Atualização dos Pesos com Taxa de Aprendizado Ótima	59
3.4 - Observador de Velocidade Rotórica Utilizando o Algoritmo Neo-Fuzzy-Neuron: Primeira e Segunda Propostas	60
3.4.1 - Definição da topologia da rede	61
3.4.2 - Desenvolvimento do Observador	63
3.4.2.1 - Equação de Atualização dos Pesos com Taxa de Aprendizado Ótima	66
3.5 - Observador de Velocidade Rotórica Utilizando o Algoritmo Neo-Fuzzy-Neuron: Terceira Proposta [52]	68
3.5.1 - Definição da topologia da rede	69
3.5.2 - Desenvolvimento do Observador	69
3.5.2.1 - Equação de Atualização dos Pesos com Taxa de Aprendizado Ótima	74
3.6 - Conclusões	75
Capítulo 4 - Validação das Propostas e Análise dos Resultados	77
4.1 - Introdução	77
4.2 - Sistema Experimental para Acionamentos Elétricos	80
4.2.1 - Programa de Controle	80
4.2.2 - Sub-Sistema Experimental	82

4.3 - Testes e Critérios de Avaliação dos Observadores de Fluxo e de Velocidade da Máquina de Indução	83
4.3.1 - Teste de Partida e Reversão de Velocidade (PRV)	85
4.3.2 - Teste de Robustez a Distúrbios	85
4.3.3 - Teste de Operação à Velocidade e Frequência Nulas	86
4.3.4 - Teste de Aplicação de Onda Quadrada Simétrica de Conjugado de Referência [32]	86
4.3.5 - Funções de Erro de Observação e Erro de Controle	87
4.3.6 - Custo Computacional	88
4.4 - Resultados de Simulação e Discussão de Resultados do Observador de Fluxos NFN	89
4.4.1 - Teste de Partida e Reversão de Velocidade	89
4.4.1.1 - Acionamento em Baixas Velocidades	89
4.4.1.2 - Acionamento em Médias Velocidades	89
4.4.1.3 - Acionamento em Altas Velocidades	95
4.4.2 - Teste de Robustez a Distúrbios	97
4.4.2.1 - Teste de Robustez às Variações Paramétricas	97
4.4.2.2 - Teste de Robustez à Aplicação e Retirada de Carga (ARC)	100
4.4.3 - Teste de Operação à Velocidade e Frequência Nulas	102

4.4.4 - Análise da Influência da Taxa de Aprendizado	104
4.4.5 - Custo Computacional do Observador de Fluxo NFN	109
4.4.6 - Comparação com o Observador de Gopinath de Ordem Reduzida	109
4.5 - Resultados Experimentais e Discussão de Resultados do Observador de Fluxo NFN	112
4.5.1 - Teste de Partida e Reversão de Velocidade	112
4.5.1.1 - Acionamento em Baixas Velocidades	112
4.5.1.2 - Acionamento em Médias Velocidades	112
4.5.2 - Teste de Robustez de Distúrbios	114
4.5.2.1 - Teste de Robustez à Aplicação e Retirada de Carga (ARC)	114
4.5.3 - Teste de Aplicação de Onda Quadrada Simétrica de Conjugado	117
4.6 - Resultados e Discussão de Resultados do Observador de Velocidade NFN: Primeira e Segunda Propostas	119
4.6.1 - Resultados de Simulação	119
4.6.2 - Resultados Experimentais	125
4.7 - Resultados de Simulação e Discussão de Resultados do Observador de Velocidade NFN: Terceira Proposta	128
4.7.1 - Teste de Partida e Reversão de Velocidade	130
4.7.1.1 - Teste de Operação em Baixas Velocidades	130

4.7.1.2 - Teste de Operação em Médias Velocidades	132
4.7.2 - Teste de Robustez de Distúrbios	132
4.7.2.1 - Teste de Robustez às Variações Paramétricas	133
4.7.2.2 - Teste de Robustez à Aplicação e Retirada de Carga (ARC)	134
4.7.3 - Teste de Operação a Velocidade e Frequência Nulas	136
4.7.4 - Análise da Rigidez Dinâmica ([18] e [58])	139
4.8 - Resultados Experimentais e Discussão de Resultados do Observador de Velocidade NFN: Terceira Proposta	142
4.8.1 - Teste de Partida e Reversão de Velocidade	142
4.8.1.1 - Acionamento em Baixas Velocidades	142
4.8.1.2 - Acionamento em Médias Velocidades	142
4.8.2 - Teste de Robustez de Distúrbios	144
4.8.2.1 - Teste de Robustez à Aplicação e Retirada de Carga (ARC)	144
4.9 - Conclusões	147
Capítulo 5 - Conclusões Gerais e Propostas de Continuidade	151
5.1 - Conclusões Gerais	151
5.2 - Propostas de Continuidade	153
Bibliografia	155

Apêndice A - Dados e Parâmetros do Sistema	163
Apêndice B - Modelo da Máquina de Indução	165

Lista de Símbolos

Abreviaturas

<i>A/D</i>	Analógico/Digital
<i>ARC</i>	Aplicação e Retirada de Carga
<i>CA</i>	Corrente Alternada
<i>CC</i>	Corrente Contínua
<i>DUFOR</i>	Direct Universal Field Oriented Control-Rotor Flux
<i>DUFOS</i>	Direct Universal Field Oriented Control-Stator Flux
<i>FCEM</i>	Força Contra Eletro Motriz
<i>IC</i>	Inteligência Computacional
<i>IGBT</i>	Insulated Gate Bipolar Transistor
<i>LAE</i>	Laboratório de Acionamentos Elétricos
<i>MCA</i>	Máquina ou Motor de Corrente Contínua
<i>MCC</i>	Máquina ou Motor de Corrente Alternada
<i>MI</i>	Máquina ou Motor de Indução
<i>MIMO</i>	Multiple Input-Multiple Output
<i>MLP</i>	Multi Layer Perceptron
<i>MRAS</i>	Model Reference Adaptive System
<i>NFN</i>	Neo-Fuzzy-Neuron
<i>PC</i>	Personal Computer
<i>PRV</i>	Partida e Reversão de Velocidade
<i>PWM</i>	Pulse Width Modulation
<i>RNA</i>	Redes Neurais Artificiais
<i>SCR</i>	Silicon Controlled Rectifier
<i>SI</i>	Sistema Internacional de Unidades
<i>SISO</i>	Single Input-Single Output
<i>SM</i>	Sliding Mode
<i>VSI</i>	Voltage Source Inverter
<i>VSS</i>	Variable Structure System

Constantes e Variáveis

B	Coeficiente de atrito viscoso ($N.m.s$)
e	Erro absoluto
$f(.)$	Função de nebulização-desnebulização do NFN
$F(.)$	Função de nebulização-desnebulização da rede NFN
$g(.)$	Função de mapeamento entre y^d e z^d
$h(.)$	Função de mapeamento entre $\hat{y}$ e $\hat{z}$
i	Corrente instantânea (A)
$\vec{i}$	Vetor corrente instantânea (A)
I	Corrente (A) ou número de entradas da rede NFN
J	Momento de Inércia ($N.m.s^2$)
L	Indutor, indutância (H) ou número de saídas da rede NFN
M_i	Número de funções de pertinência da entrada i da rede NFN
p	Operador derivada
P	Número de pólos
R	Resistor, resistência (Ω)
t	Tempo (s)
T	Período de amostragem (s)
T_e	Conjugado eletromagnético (N.m)
T_c	Conjugado de carga (N.m)
T_r	Conjugado resistente (N.m)
v	Tensão instantânea (V)
$\vec{v}$	Vetor tensão instantânea (V)
V	Tensão (V)
W	Pesos da rede NFN
x	Entrada do sistema a ser observado ou do observador NFN
y	Estado a ser observado
$\hat{y}$	Estado observado e saída da rede NFN
z^d	Estado desejado, para treinamento da rede NFN
$\hat{z}$	Estado observado a ser comparado com z^d , para treinamento da rede NFN
α	Taxa de aprendizado da rede NFN sem equação de mapeamento
ε	Erro quadrático
θ_e	Ângulo entre o eixo direto e o eixo da fase a do estator (rad)
θ_r	Posição do rotor (rad)
λ	Enlace de fluxo (Wb)
$\vec{\lambda}$	Vetor enlace de fluxo (Wb)
μ	Grau de pertinência
η	Taxa de aprendizado da rede NFN com equação de mapeamento
ρ_r	Posição do vetor fluxo de rotor (rad)
σ	Coeficiente de dispersão da máquina
τ	Constante de tempo (s)
ω_e	Velocidade angular do sistema de coordenadas (rad/s)
ω_r	Velocidade angular do rotor (rad/s)
ω_{sr}	Velocidade angular de escorregamento (rad/s)

Matrizes e Vetores Matriciais

A, B, C	Matrizes de equação de estado contínua
U	Vetor de entradas
W	Matriz de pesos da rede NFN
x	Vetor de entradas (da rede NFN ou do sistema) ou vetor de estados
$\hat{y}, \hat{z}$	Vetor de estados observados
y	Vetor de estados a serem observados
z^d	Vetor de estados desejados, para treinamento da rede NFN

Símbolos Matemáticos

Δ	Diferença, desvio
j	Operador imaginário
Re, Im	Parte real, parte imaginária
$\left\{ \begin{array}{l} \frac{dx(t)}{dt} \\ \dot{x}(t) \end{array} \right.$	Operador derivada temporal da variável $x(t)$
∂	Operador derivada parcial

Sobrescritos

$*$	Valor de referência ou conjugado de um vetor
$\wedge$	Valor estimado ou observado
d	Valor desejado para treinamento da rede NFN
e	Relativo ao sistema de eixos dq num referencial genérico
j	Relativo ao passo da malha do observador NFN
n	Relativo ao passo da malha de controle
r	Relativo ao sistema de eixos dq num referencial fixo no rotor
s	Relativo ao sistema de eixos dq num referencial fixo no estator
$\rightarrow$	Vetor

Subscritos

r, s, t	Relativo às fases do sistema abc de alimentação do conversor
a, b, c	Relativo às fases do sistema abc de saída do conversor
α, β	Relativo aos eixos do sistema de referência fixo no estator
d, q	Relativo aos eixos do sistema de referência arbitrário
G	Referente ao observador de fluxo de Gopinath
i	Entrada genérica da rede NFN
j	Instante genérico de amostragem da malha do observador
k_i	Primeira função de pertinência ativa da entrada i da rede NFN
$k_i + 1$	Segunda função de pertinência ativa da entrada i da rede NFN
l	Saída genérica da rede NFN
l_r	Relativo à dispersão do rotor
l_s	Relativo à dispersão do estator
m	Relativo ao fluxo mútuo
m_i	Função de pertinência da entrada i da rede NFN
N	Relativo ao observador de fluxo NFN
n	Instante genérico de amostragem do programa de controle
r	Relativo ao rotor
s	Relativo estator
ω_r	Relativo à velocidade do rotor
λ_r	Relativo ao fluxo de rotor

Lista de Figuras

1.1	Diagrama de Blocos de um Observador	16
2.1	Estrutura do NFN.....	33
2.2	Funções de pertinência	34
2.3	Processamento de um NFN.....	35
2.4	Diagrama de blocos do treinamento do NFN	37
2.5	a) Diagrama de blocos do Neo-Fuzzy-Neuron generalizado b) Bloco $F_i(x_i)$	40
3.1	a) Diagrama de blocos de um observador de estados com rede NFN b) Bloco $F_i(x_i)$	45
3.2	Processo de ajuste dos pesos do observador de estados NFN	45
3.3	Exemplo de função contínua estritamente monotônica crescente	46
3.4	Correlação-cruzada de I_{sd} com λ_{rd}	55
3.5	Correlação-cruzada de I_{sq} com λ_{rq}	56
3.6	Diagrama de blocos do observador de fluxo rotórico NFN	58
3.7	Correlação-cruzada de T_e com ω_r	62
3.8	Correlação-cruzada de $I_{s\alpha}$ com ω_r	63
3.9	Diagrama de blocos do observador de velocidade NFN: primeira e segunda propostas	65
3.10	Função singular $\frac{1}{\lambda_{r\alpha}}$	68

3.11	Diagrama de blocos do observador de velocidade NFN: terceira proposta	73
4.1	Esquema de controle DUFOR <i>sensorless</i>	78
4.2	Diagrama de blocos do sistema experimental para acionamentos elétricos utilizado	81
4.3	Conversor CA/CC/CA - <i>Chopper</i>	84
4.4	Resultados de simulação: teste de PRV em baixas velocidades ($\hat{\lambda}_r$ NFN)	90
4.5	Resultados de simulação: teste de PRV em baixas velocidades ($\hat{\lambda}_r$ NFN)	90
4.6	Resultados de simulação: teste de PRV em baixas velocidades ($\hat{\lambda}_r$ NFN)	91
4.7	Resultados de simulação: teste de PRV em médias velocidades ($\hat{\lambda}_r$ NFN)	92
4.8	Resultados de simulação: teste de PRV em médias velocidades ($\hat{\lambda}_r$ NFN)	93
4.9	Resultados de simulação: teste de PRV em médias velocidades ($\hat{\lambda}_r$ NFN)	94
4.10	Resultados de simulação: teste de PRV em médias velocidades ($\hat{\lambda}_r$ NFN)	94
4.11	Resultados de simulação: teste de PRV em médias velocidades ($\hat{\lambda}_r$ NFN)	95
4.12	Resultados de simulação: teste de PRV em altas velocidades ($\hat{\lambda}_r$ NFN)	96
4.13	Resultados de simulação: teste de PRV em altas velocidades ($\hat{\lambda}_r$ NFN)	96
4.14	Resultados de simulação: teste de robustez a variações paramétricas ($\hat{\lambda}_r$ NFN)	98
4.15	Resultados de simulação: teste de robustez a variações paramétricas em baixas velocidades ($\hat{\lambda}_r$ NFN)	98
4.16	Resultados de simulação: teste de robustez a variações paramétricas em baixas velocidades ($\hat{\lambda}_r$ NFN)	99
4.17	Resultados de simulação: teste de robustez a variações de R_r em médias velocidades ($\hat{\lambda}_r$ NFN)	100

4.18	Resultados de simulação: teste de robustez a variações de R_r em altas velocidades ($\hat{\lambda}_r$ NFN)	101
4.19	Resultados de simulação: teste de robustez a ARC em baixas velocidades ($\hat{\lambda}_r$ NFN)	102
4.20	Resultados de simulação: teste de robustez a ARC em médias velocidades ($\hat{\lambda}_r$ NFN)	103
4.21	Resultados de simulação: teste de robustez a ARC em altas velocidades ($\hat{\lambda}_r$ NFN)	103
4.22	Resultados de simulação: teste de operação à velocidade nula ($\hat{\lambda}_r$ NFN)	104
4.23	Resultados de simulação: teste de operação à velocidade nula ($\hat{\lambda}_r$ NFN)	105
4.24	Resultados de simulação: teste de operação à velocidade nula ($\hat{\lambda}_r$ NFN)	105
4.25	Resultados de simulação: teste de PRV com $\eta=2,56$ ($\hat{\lambda}_r$ NFN)	107
4.26	Resultados de simulação: teste de PRV com $\eta=2,56$ ($\hat{\lambda}_r$ NFN)	107
4.27	Resultados de simulação: teste de PRV com $\eta=2,56$ ($\hat{\lambda}_r$ NFN)	108
4.28	Resultados de simulação: teste de PRV em baixas velocidades ($\hat{\lambda}_r$ NFN)	110
4.29	Resultados de simulação: teste de PRV em altas velocidades ($\hat{\lambda}_r$ NFN)	111
4.30	Resultados de experimentais: teste de PRV em baixas velocidades ($\hat{\lambda}_r$ NFN) ..	113
4.31	Resultados de experimentais: teste de PRV em baixas velocidades ($\hat{\lambda}_r$ NFN) ..	113
4.32	Resultados de experimentais: teste de PRV em médias velocidades ($\hat{\lambda}_r$ NFN) .	114
4.33	Resultados de experimentais: teste de PRV em médias velocidades ($\hat{\lambda}_r$ NFN) .	115
4.34	Resultados de experimentais: teste de PRV em médias velocidades ($\hat{\lambda}_r$ NFN) .	116
4.35	Resultados experimentais: teste de robustez a ARC em baixas velocidades ($\hat{\lambda}_r$	

NFN)	116
4.36 Resultados experimentais: teste de robustez a ARC em médias velocidades ($\hat{\lambda}_r$ NFN)	117
4.37 Resultados de experimentais: teste de aplicação de onda quadrada simétrica de T_e^* ($\hat{\lambda}_r$ NFN)	118
4.38 Resultados de experimentais: teste de aplicação de onda quadrada simétrica de T_e^* ($\hat{\lambda}_r$ NFN)	118
4.39 Resultados de experimentais: teste de aplicação de onda quadrada simétrica de T_e^* ($\hat{\lambda}_r$ NFN)	119
4.40 Resultados de simulação: teste de PRV em médias velocidades, utilizando o fluxo do modelo na observação de velocidade ($\hat{\omega}_r$ NFN-1,2)	120
4.41 Resultados de simulação: teste de PRV em médias velocidades, utilizando o fluxo do modelo na observação de velocidade ($\hat{\omega}_r$ NFN-1,2)	121
4.42 Resultados de simulação: teste de PRV em médias velocidades, utilizando o fluxo do modelo na observação de velocidade ($\hat{\omega}_r$ NFN-1,2)	121
4.43 Resultados de simulação: teste de PRV em médias velocidades, utilizando o fluxo NFN na observação de velocidade ($\hat{\omega}_r$ NFN-1,2)	122
4.44 Resultados de simulação: teste de PRV em médias velocidades, utilizando o fluxo NFN na observação de velocidade ($\hat{\omega}_r$ NFN-1,2)	123
4.45 Resultados de simulação: teste de PRV em médias velocidades, utilizando o fluxo NFN na observação de velocidade ($\hat{\omega}_r$ NFN-1,2)	123
4.46 Resultados de simulação: teste de PRV em médias velocidades, utilizando o fluxo do modelo na observação de velocidade, com ajuste ($\hat{\omega}_r$ NFN-1,2)	124
4.47 Resultados experimentais: teste de PRV em baixas velocidades, com o observador de velocidade na malha de controle e com o observador de fluxo NFN utilizando a velocidade medida ($\hat{\omega}_r$ NFN-1,2)	126
4.48 Resultados experimentais: teste de PRV em baixas velocidades, com o observador de velocidade na malha de controle e com o observador de fluxo	

NFN utilizando a velocidade medida ($\hat{\omega}_r$ NFN-1,2)	127
4.49 Resultados experimentais: teste de PRV em baixas velocidades, com o observador de velocidade na malha de controle e com o observador de fluxo NFN utilizando a velocidade medida ($\hat{\omega}_r$ NFN-1,2)	127
4.50 Resultados experimentais: teste de PRV em médias velocidades, com o observador de velocidade na malha de controle e com o observador de fluxo NFN utilizando a velocidade medida ($\hat{\omega}_r$ NFN-1,2)	128
4.51 Resultados experimentais: teste de PRV em médias velocidades, com o observador de velocidade na malha de controle e com o observador de fluxo NFN utilizando a velocidade medida ($\hat{\omega}_r$ NFN-1,2)	129
4.52 Resultados de simulação: teste de PRV em baixas velocidades, utilizando o fluxo do modelo na observação de velocidade ($\hat{\omega}_r$ NFN-3)	130
4.53 Resultados de simulação: teste de PRV em baixas velocidades, utilizando o fluxo do modelo na observação de velocidade ($\hat{\omega}_r$ NFN-3)	131
4.54 Resultados de simulação: teste de PRV em médias velocidades, utilizando o fluxo do modelo na observação de velocidade ($\hat{\omega}_r$ NFN-3)	132
4.55 Resultados de simulação: teste de PRV em médias velocidades, utilizando o fluxo do modelo na observação de velocidade ($\hat{\omega}_r$ NFN-3)	133
4.56 Resultados de simulação: teste de robustez a ARC em baixas velocidades ($\hat{\omega}_r$ NFN-3)	135
4.57 Resultados de simulação: teste de robustez a ARC em baixas velocidades ($\hat{\omega}_r$ NFN-3)	136
4.58 Resultados de simulação: teste de robustez a ARC em médias velocidades ($\hat{\omega}_r$ NFN-3)	137
4.59 Resultados de simulação: teste de robustez a ARC em médias velocidades ($\hat{\omega}_r$ NFN-3)	137
4.60 Resultados de simulação: teste de operação à velocidade nula, utilizando o fluxo do modelo na observação de velocidade ($\hat{\omega}_r$ NFN-3)	138

4.61	Topologia de um controlador DUFOR.....	140
4.62	Rigidez Dinâmica de um controlador DUFOR	140
4.63	Rigidez Dinâmica ($\left \frac{T_c(s)}{\omega_r(s)} \right $) do controle DUFOR da máquina de indução com a velocidade do modelo (- -) e com a velocidade observada (-)	141
4.64	Resultados experimentais: teste de PRV em baixas velocidade ($\hat{\omega}_r$ NFN-3)	143
4.65	Resultados experimentais: teste de PRV em baixas velocidade ($\hat{\omega}_r$ NFN-3)	143
4.66	Resultados experimentais: teste de PRV em médias velocidade ($\hat{\omega}_r$ NFN-3) ...	144
4.67	Resultados experimentais: teste de PRV em médias velocidade ($\hat{\omega}_r$ NFN-3) ...	145
4.68	Resultados experimentais: teste de robustez a ARC em baixas velocidades ($\hat{\omega}_r$ NFN-3)	146
4.69	Resultados experimentais: teste de robustez a ARC em baixas velocidades ($\hat{\omega}_r$ NFN-3)	147
4.70	Resultados experimentais: teste de robustez a ARC em médias velocidades ($\hat{\omega}_r$ NFN-3)	148
4.71	Resultados experimentais: teste de robustez a ARC em médias velocidades ($\hat{\omega}_r$ NFN-3)	149

Lista de Tabelas

4.1	Custo Computacional de Observadores	109
4.2	Máximo erro de observação em fluxo NFN e de Gopinath (obtida de uma média de simulações)	111
4.3	Máximo erro de observação (%) dos observadores de velocidade (primeira e segunda propostas)	125
4.4	Erro de observação médio (%) do observador de velocidade (terceira proposta)	138

Capítulo 1

Introdução Geral

1.1 Introdução

As linhas de manufatura numa planta industrial geralmente envolvem um ou mais sistemas de acionamentos elétricos de conjugado controlado a velocidade variável, que são utilizados em braços de robôs, moinhos de papel, trefiladoras, linhas de processamento de plástico e fibras, entre outros processos. Até a década de 50, estas aplicações requeriam o uso de acionamentos de corrente contínua, já que os acionamentos de corrente alternada não eram capazes de variar a velocidade suavemente devido a sua operação à frequência fixa (ou próxima desta) de alimentação da rede, com o tipo de controle da época [58].

Em 1957, o laboratório de pesquisas da General Electric introduziu a utilização de topologias *Voltage Source Inverter* (VSI) com *Silicon Controlled Rectifier* (SCRs) no controle de MCA. O controle era escalar, com variação da frequência de alimentação do motor de indução (MI), mantendo-se a relação tensão/frequência constante, a fim de evitar a saturação do ferro e melhorar a saída de conjugado em várias velocidades [39]. Este e outros fatos provocaram o início da utilização de MCA onde eram utilizados apenas MCC.

As técnicas de controle vetorial ([7], [9], [16], [58], [71], [72], [93], [96], [101]) surgiram no final da década de 60, a fim de proporcionar acionamentos elétricos de conjugado controlado com o motor de indução. O surgimento destas técnicas, juntamente com o desenvolvimento de dispositivos semicondutores de potência (com capacidade cada vez maior de corrente e tensão) e da microeletrônica (microprocessadores, microcontroladores e processadores de sinais cada vez mais rápidos) levou a indústria a ir substituindo gradativamente os motores de corrente contínua por motores de indução.

Como as técnicas de controle vetorial precisam da informação quanto a posição e

o módulo do vetor fluxo (de rotor, de estator ou mútuo), surgiu a necessidade de obtenção destas grandezas. Isto pode ser feito através da medição direta, ou por métodos indiretos, como será visto na próxima seção.

Em sistemas industriais com controle de velocidade e conjugado e em muitas aplicações de transporte, o sistema de controle em malha fechada é baseado na medição da velocidade ou posição do motor, através de um *sensor* em seu eixo. Os sensores de posição e velocidade precisam ser instalados no eixo da máquina, aumentando os custos e diminuindo a confiabilidade do sistema de acionamento [83]. A fim de eliminar estes sensores, foram propostos vários algoritmos de estimação da posição ou velocidade, geralmente baseados nos parâmetros da máquina e nas medições das tensões e/ou correntes de alimentação do motor.

O termo *sensorless* (“sem sensores”, literalmente) surgiu para designar esta técnica de acionamentos elétricos desprovidos dos sensores de posição e de velocidade. Convém salientar que ainda são necessários os sensores de corrente e/ou de tensão para a obtenção de um acionamento elétrico de alto desempenho. Os acionamentos de sistemas de alto desempenho são aqueles com precisão de velocidade de até 0,5%, larga faixa de velocidade (20:1, pelo menos) e transitório de resposta rápido para a malha de controle de velocidade [58]. Atualmente, todos os *drives* VSI de aplicação geral para acionamentos elétricos da MI possuem a opção de *controle vetorial sensorless* [39].

Estima-se que sistemas adaptativos por modelo de referência (MRAS) e sistemas baseados em Inteligência Computacional (IC) terão um papel cada vez maior no futuro. Por exemplo, a “Intelligent Motion Control Group” (IMCG) da Universidade de Aberdeen está desenvolvendo diferentes tipos de controle, com estimadores de fluxo, conjugado e velocidade baseados em IC. A Yaskawa atualmente comercializa um inversor com controle vetorial que utiliza um observador de fluxo com controle neural [103]. Maiores detalhes sobre a IC podem ser vistos em [12], [23], [31], [37], [42], [80], [95] e [100].

No mercado atual da automação industrial, os *drives* isolados para acionamento dominam o mercado. Entretanto, tudo indica que futuramente eles serão substituídos por sistemas de *drives* que utilizam plataforma baseada em controle por computadores, com diversos *drives*, motores, sensores e equipamentos de processamento. Isto permitirá

a implementação de estratégias integradas de comunicação, possibilitando uma maior interação entre todas as partes integrantes do processo produtivo industrial [39].

Portanto, os acionamentos sem sensor de velocidade, utilizando técnicas de IC e controlados por computador estão de acordo com a tendência do desenvolvimento tecnológico mundial em acionamentos elétricos.

Neste capítulo, será feito um levantamento do *estado da arte* nas linhas de pesquisa de observadores de fluxos e de velocidade para a MI. Serão vistas as principais técnicas existentes para a obtenção dos fluxos e da velocidade da MI, bem como os seus principais problemas. Além disso, serão vistas as contribuições atingidas neste trabalho.

1.2 Estado da Arte em Observadores de Fluxo para Acionamentos Elétricos do Motor de Indução

Em 1966, Luemberger [59] descreveu o conceito de observadores de estado aplicado a sistemas multivariáveis.

Em 1971, Gopinath [22] desenvolveu uma metodologia de projeto de controladores e observadores de estado para sistemas multivariáveis e Luemberger [60] fundamentou a teoria de *observadores de estado* para sistemas lineares multivariáveis.

O advento do controle vetorial por orientação pelo campo ([7] e [55]) serviu como motivação para a pesquisa da obtenção do vetor fluxo. Inicialmente, diversas formas de aquisição do vetor fluxo foram propostas: sensores de efeito Hall, bobinas exploradoras, bobinas individuais do enrolamento de estator, e estimadores e observadores de fluxo [61]. Dentre as formas de obtenção do vetor fluxo, uma das mais utilizada é a estimação ou observação do fluxo, devido à sua facilidade e baixo custo de implementação.

A maneira mais simples de fazer uma estimação de estados da MI, utilizando os conceitos de observação, é através de um *estimador*, que nada mais é do que um modelo da máquina de indução, em malha aberta. Isto significa que, mesmo considerando

que as condições iniciais da máquina e as do estimador coincidam (o que seria pouco provável), o estimador não acompanha as mudanças aleatórias sofridas pela máquina (ruídos, variações paramétricas, etc.), dificultando a sua convergência. Além disso, a dinâmica do estimador é igual à do sistema, quando deseja-se que a dinâmica do estimador (ou observador) seja mais rápida do que a do sistema, a fim de possibilitar uma boa resposta no controle que utiliza a informação da variável estimada. Para resolver este problema, utiliza-se uma realimentação para correção da convergência do estimador. Neste caso, temos um observador propriamente dito. Na fig.1.1 temos o diagrama de blocos de um observador de estados *convencional*. A realimentação pode ser vista analiticamente na eq.1.1, pelo termo $K \cdot [C \cdot \hat{X}(t) - Y(t)]$.

$$\dot{\hat{X}}(t) = A \cdot \hat{X}(t) + B \cdot U(t) + K \cdot [C \cdot \hat{X}(t) - Y(t)] \quad (1.1)$$




Figura 1.1- Diagrama de Blocos de um Observador

Convém salientar que na área de controle clássica, não há distinção entre *estimador* e *observador* de estados; esta é feita apenas na área de controle de acionamentos elétricos e será adotada neste texto.

Uma das primeiras aplicações práticas de um observador de fluxo foi feita por Kubota e outros [44], em 1984, onde foi proposto um observador de fluxo, utilizado no acionamento de um motor de indução, via microprocessador.

Em 1987, Hori e outros [25] fizeram uma generalização e classificação de observadores de fluxo convencionais.

Verghese e Sanders [106], em 1988, aplicaram o conceito de observadores de estado para máquinas de indução, na observação do fluxo de rotor e criaram o termo *estimador*, fazendo clara distinção entre estimadores e observadores de estado para máquinas de indução.

O surgimento destas e de outras propostas de observadores de fluxo motivou Jansen e Lorenz [32], em 1992, a introduzirem uma nova metodologia para análise de variações paramétricas dos observadores de fluxo convencionais, utilizando *Funções de Resposta em Frequência (FRF)*.

Nestli e Nilsen [70], em 1994, apresentaram uma metodologia para avaliação e comparação de estimadores e observadores convencionais de fluxo de rotor. Para isto, introduziram vários conceitos interessantes, tais como *erro de estimação estacionário* e *número de qualidade*. As avaliações e comparações foram feitas a partir da análise de sensibilidade às variações paramétricas da MI.

Em 1997, Luiz e outros [62] apresentaram uma metodologia para o projeto de observadores de fluxo convencionais a partir da análise do desempenho das estruturas. Além disso eles propuseram um critério de escolha do ganho baseado na teoria de controle robusto. Foram apresentados resultados de simulação numérica e práticos obtidos em um protótipo.

Apesar das diversas propostas de observadores lineares para o MI baseadas na abordagem linear de suas equações, o mesmo é um sistema não-linear, não-estacionário e multivariável acoplado, e a obtenção de uma lei de realimentação adequada, satisfatória alocação dos pólos (que variam com a velocidade, com o sistema de referência adotado

[81] e com o passo de integração [64]) não é trivial, o que resulta em observadores sensíveis a variações paramétricas e ruídos, e/ou com problemas de operação em baixa velocidade. Assim, surgiram várias propostas de observadores de fluxo *não-convencionais*, que utilizam técnicas de Inteligência Computacional (IC), efeitos da geometria, da assimetria e da saturação, Modos Deslizantes, etc.

Em 1994, Theocharis e Petridis [99] fizeram o que parece ser uma das primeiras aplicações de RNAs em observadores de fluxo, apresentando resultados de simulação.

Resultados experimentais de um observador de fluxo de rotor utilizando RNAs foram apresentados por Simões e Bose [94], em 1995. Os fluxos de estator, que fazem parte das entradas da rede, são obtidos através de um estimador feito a partir da integração da equação de tensão do MI. O treinamento utilizado foi *off-line*, o que resultou em pequenas oscilações no fluxo observado, que geraram erro da ordem de 5%.

As vantagens de rapidez do treinamento *on-line*, com convergência em apenas um passo de cálculo, capacidade de generalização, robustez a ruídos e reduzido esforço computacional do algoritmo Neo-Fuzzy-Neuron [108], motivaram Landim e outros [49], em 1998, a desenvolverem um estimador de fluxo de rotor para a máquina de indução baseado neste algoritmo. Os resultados de simulação e experimentais mostraram a rápida convergência do observador (em um passo de cálculo), tanto em altas como em baixas frequências (0,8 Hz). Além disso, o observador mostrou-se robusto às variações paramétricas da MI e à aplicação de carga.

Em 1990, Moreira e Lipo [68], desenvolveram um método para a obtenção da informação sobre o fluxo mútuo a partir da componente de 3º harmônico de tensão de estator, após sua integração. Esta componente da tensão é obtida pela soma das tensões de fase, para a máquina de indução ligada em Y não aterrado. Este método apresenta uma dependência do nível de saturação e da relação entre as amplitudes das componentes de terceiro harmônico e fundamental de fluxo, além dos problemas de integração (*drift*, *offset*, condições iniciais e saturação dos integradores);

Marino e outros [65], em 1999, propuseram um observador de fluxo de rotor

utilizando uma rede neural artificial robusta, cujas entradas são as correntes terminais e os fluxos de estator. Os fluxos de estators são obtidos através da filtragem da FCEM do modelo de tensão da MI. Segundo os autores, a rede é capaz de observar o fluxo de rotor mesmo diante dos erros do estimador de fluxo de estator.

Outros estimadores ou observadores de fluxo propostos podem ser vistos em [5], [11], [13], [26], [33], [38], [45], [75], [76], [88], [90], [91] e [92].

Assim, as principais técnicas existentes para a obtenção dos fluxos da MI são:

- estimadores convencionais (modelo de corrente, modelo de tensão, método de cancelamento);
- observadores convencionais (de Kalman, Luemberger, de Gopinath, etc);
- medições da tensão (ou da corrente) do estator ou do *link DC* ;
- medições das tensões de terceira harmônica do estator;
- força contra-eletromotriz;
- sistemas adaptativos por modelo de referência (MRAS);
- Inteligência Computacional (IC): Redes Neurais Artificiais (RNA), Lógica Nebulosa, Algoritmos Genéticos, Redes Neuro-Nebulosas, etc.;
- efeitos geométricos, assimétricos e de saturação;
- sistemas de estrutura variável (VSS).

Dentre os problemas atuais na observação ou estimação de fluxo, podemos citar:

- sensibilidade às variações paramétricas e a ruídos de medição;
- observação deficiente em velocidades baixas e nulas;
- baixa velocidade de convergência diante de exigências dinâmicas da planta (reversões de velocidade, aplicação e retirada de carga, etc.);
- dificuldade na manipulação da dinâmica dos observadores convencionais (alocação de pólos adequada que garanta rapidez de convergência e baixa sensibilidade a ruídos e às variações paramétricas, independentemente da velocidade

e do referencial do sistema de eixos dq escolhido);

- problemas de condições iniciais, *drift*, *offset* e saturação dos integradores (no caso dos estimadores).
-

1.3 Estado da Arte em Observadores de Velocidade para Acionamentos Elétricos do Motor de Indução

A primeira tentativa de operar o motor de indução em malha fechada sem usar um sensor de velocidade, segundo Rajashekara e outros [83], foi feita por Abbondanti e Brennen [1], em 1975. A estratégia baseia-se na obtenção do escorregamento da máquina através de um circuito analógico, a partir das medições de tensão e corrente. O sinal analógico obtido é proporcional ao escorregamento da máquina, desde que se considere o modelo de regime permanente da MI. A velocidade do motor é obtida a partir do escorregamento e da frequência elétrica. Como o método é baseado no modelo em regime permanente da máquina, a faixa de velocidade é pequena (10:1), e há grande sensibilidade às variações paramétricas, principalmente à variação da resistência rotórica.

Uma extensão desta estratégia foi apresentada por Venkataraman e outros [105], em 1980. A partir da potência do elo CC do inversor, os autores obtiveram o conjugado eletromagnético, e a partir deste (utilizando a mesma relação torque-escorregamento que [1]), obteve-se o escorregamento. Como este método também é baseado no modelo em regime permanente da MI, possui os mesmos problemas que [1], além de precisar da medição das perdas no inversor e da máquina.

O que parece ser a primeira abordagem de acionamento *sensorless* de motores de indução baseados nas equações de estados da MI (aqui chamado simplesmente de modelo dq) foi feita por Joetten e Maeder [36], em 1983. Considerando o fluxo de rotor constante, as forças contra-eletromotrizes (FCEMs) rotóricas (com o sistema de eixos dq fixo no estator) são utilizadas para calcular o escorregamento. A velocidade é obtida a partir do escorregamento e da frequência elétrica. As correntes e tensões são medidas. As considerações de fluxo de rotor constante para calcular o escorregamento pelas FCEMs, e a diminuição destas em baixas velocidades, torna este método sensível a operação em baixas velocidades. Não foi enfatizada a faixa de velocidade atingida por este método.

Zinger e outros [111], em (1988), propuseram um método para obtenção de velocidade a partir dos harmônicos produzidos pelas ranhuras rotóricas no fluxo de

entreferro. Este foi obtido a partir da integração da FCEM medida em derivações específicas nos enrolamentos de estator. A precisão deste tipo de estimação é função do número de ranhuras rotóricas. Se o número de ranhuras for pequeno, a estimação da velocidade fica prejudicada em baixas velocidades [86].

Xu e Novotny [107], em 1991, propuseram um esquema de acionamentos *sensorless* para utilização no controle vetorial direto por orientação pelo fluxo de estator. O vetor fluxo de estator foi calculado através da equação de tensão de estator (eixos fixos no estator) da MI. A partir dos fluxos, eles obtiveram a frequência elétrica; a partir dos parâmetros da MI e da corrente de eixo d , eles calcularam a frequência de escorregamento, obtendo então, a velocidade. O fluxo estimado não requer a informação da velocidade, e este método apresenta desempenho superior ao acionamento com orientação pelo fluxo de rotor na região de enfraquecimento de campo (velocidade acima da nominal). Entretanto, a integração necessária para a obtenção do fluxo traz os já conhecidos problemas de integração, principalmente em baixas velocidades. Além disso, há grande sensibilidade às variações paramétricas e necessidade de um termo de desacoplamento para a malha de controle de conjugado.

Ohtani e outros [75], em 1992, propuseram um modelo para estimar a velocidade, baseado na força contra-eletromotriz (FCEM). O método foi implementado no controle vetorial indireto do MI. O fluxo de rotor é estimado a partir da FCEM. Os problemas de integração são contornados com a aplicação de um filtro passa-baixas na FCEM. O escorregamento é calculado a partir dos valores de referência das correntes de eixo d e q , e a frequência de alimentação é calculada a partir do fluxo de rotor observado e da corrente de eixo q . A velocidade é calculada a partir do escorregamento de referência e da frequência de alimentação. A velocidade mínima atingida foi de 18 rpm.

Um observador de velocidade baseado em sistemas adaptativos por modelo de referência (MRAS) foi proposto por Schauder [89], em 1992. O modelo de referência foi obtido pela equação de tensão de estator da MI (pois não depende da velocidade) para fornecer os fluxos de rotores de referência. O modelo adaptativo foi obtido a partir da equação de tensão de rotor, para obter o fluxo de rotor a ser comparado com o de referência. A velocidade entra como informação do modelo adaptativo, considerando que

todos os parâmetros da MI estão corretos. Assim, a única fonte de erro entre os dois modelos é devido à velocidade observada, que é corrigida através de um mecanismo de adaptação até que o erro se anule. A estabilidade global do sistema vai depender do mecanismo de ajuste adotado. O observador de velocidade foi utilizado no controle vetorial indireto de um MI. O problema deste método reside no próprio modelo de referência, que na verdade é um estimador de fluxo, e tem todos os problemas da integração, principalmente a baixas velocidades. Schauder [89] propôs a substituição dos integradores por filtros passa-baixa com baixa frequência de corte. Contudo, o observador perde a estabilidade durante transitórios e em velocidades muito baixas, limitando o tempo de funcionamento nestas condições. Além disso, há uma grande sensibilidade às variações paramétricas.

Ben-Brahim e Kurosawa [6], em 1993, propuseram um observador de velocidade usando redes neurais artificiais (RNAs). O princípio de funcionamento da rede utilizada é o mesmo que o de um MRAS: o modelo de referência é obtido a partir da equação de tensão de estator, a fim de gerar o fluxo de rotor como referência, a partir da integração da FCEM. A rede é o modelo adaptativo, projetada de modo a fornecer o fluxo de rotor. O seu projeto é feito a partir da equação de tensão de rotor, de modo que as entradas da rede são os vetores fluxo de rotor e corrente de estator do passo anterior, e os pesos da rede são funções lineares da velocidade, constante de tempo rotórica e indutância mútua. O erro de observação é usado pelo algoritmo *backpropagation* a fim de definir os pesos da rede que levam o erro a zero. São mostrados resultados de simulação com controle vetorial de um MI, usando o observador, onde é aplicada uma referência em degrau da velocidade (de 50 rad/s) e uma aplicação e retirada de carga (5 N.m). Há um *ripple* de 8% na velocidade estimada. O observador apresenta sensibilidade às variações paramétricas da MI. Além disso, o estimador de fluxo utilizado tem problemas potenciais de integração num acionamento real.

Um observador de velocidade com filtro de Kalman foi proposto por Kim e outros [41], em 1994. O filtro de Kalman é de ordem estendida e tem como saídas fluxos e velocidade. Os fluxos observados são utilizados no controle vetorial direto de um MI. O observador mostrou-se bastante sensível às variações da resistência rotórica.

Yong e Sul [109], em 1994, propuseram um método de estimação da velocidade

através da injeção de correntes de alta frequência nas correntes de estator de eixo d . Estas correntes produzem um *ripple* no conjugado eletromagnético. A informação da posição do rotor está no *ripple*, que é obtida através de filtragem. Os resultados experimentais mostram um desempenho razoável do acionamento *sensorless*, a baixas velocidades (18 rpm, onde apresentou o erro máximo de 27%), a baixas velocidades (30 rpm) com aplicação de meia carga (onde apresentou erro máximo de 30%) e a altas velocidades, com partida e reversão de velocidade a altas velocidades (500 rpm) com aplicação e retirada de carga plena. A faixa de velocidade obtida foi 100:1. Não foi feito nenhum acionamento à velocidade nula. Também não foi feito nenhum comentário a respeito do efeito do *ripple* no conjugado, com relação ao desempenho do acionamento. Além disso, este método demanda grande esforço computacional para a filtragem e obtenção da informação da posição rotórica.

Hurst e outros [28], em 1994, propuseram um método de estimação da velocidade, baseado na medição dos harmônicos de corrente produzidos pelas ranhuras do rotor. A informação do escorregamento está nestes harmônicos, que são obtidos a partir de filtragem. Este método precisa do *número de ranhuras do rotor*, da *ordem da excentricidade do rotor* e da *ordem da harmônica da força magneto-motriz (FMM) de entreferro*, que são obtidos previamente a partir das *harmônicas de excentricidade*. A partir da medição de corrente, um algoritmo de estimação espectral, utilizando FFT, detecta a frequência dos harmônicos produzidos pelas ranhuras. O velocidade de escorregamento é determinada a partir da relação entre os parâmetros construtivos da MI e a frequência dos harmônicos produzidos pelas ranhuras. O tempo necessário para o cálculo da velocidade é relativamente alto (de 20 a 30 ciclos da frequência do sinal de corrente), e a velocidade do motor deve estar em regime permanente, diferente de zero.

Jansen e Lorenz [35], em 1995, apresentaram os principais problemas na estimação de velocidade, e apontaram que as condições básicas para a obtenção da posição e velocidade de maneira precisa e insensível às variações paramétricas seriam: através da medição da modulação espacial introduzida pelas ranhuras e através da injeção de um sinal apropriado durante toda a faixa de operação (inclusive à velocidade zero). Eles também propuseram um método de obtenção da velocidade, que consiste na modificação das aberturas, profundidade ou o preenchimento das ranhuras ao longo da superfície do

rotor, associado à injeção de um sinal de alta frequência para determinar as saliências produzidas pela modulação da indutância própria do rotor $-L_{lr}$ (que traz a informação de posição). Demodulando-se as correntes resultantes deste processo e filtrando-se o sinal demodulado, obtém-se um sinal que, juntamente com o modelo mecânico da MI, fornece a posição e velocidade da máquina. A necessidade de modificações nas máquinas já existentes, as modulações indesejáveis nos sinais injetados causadas pelo tempo morto do inversor e erros de estimação causados pela modulação espacial adicional em L_{lr} (devido aos efeitos da saturação) são alguns dos problemas deste método.

Mehrotra e outros [66], em 1996, desenvolveram um estimador de velocidade com RNAs. A partir das equações da MI, eles obtiveram duas expressões para a velocidade, que dependem da derivada de corrente de estator, da corrente de estator, da FCEM e do fluxo de estator. Assim, eles projetaram duas redes: uma para o mapeamento da função do numerador de uma das expressões, e outra para mapear o denominador. Um *filtro de passagem por zero* é utilizado para obter a velocidade através da divisão entre as saídas das duas redes. O treinamento da rede é feito *off-line*. O fluxo de estator é obtido pela integração da FCEM da MI. A velocidade estimada apresenta *ripples*, que foram eliminados com a utilização de um filtro passa-baixa de primeira ordem. Como era de se esperar, o filtro injetou um certo atraso na velocidade estimada. Este estimador tem problemas de sensibilidade às variações paramétricas da MI. Além disso, o estimador de fluxo utilizado leva a problemas de integração num acionamento real.

Ribeiro e outros [85], em 1997, fizeram uma revisão e classificação das técnicas *sensorless* existentes. As classes propostas (com uma pequena modificação na nomenclatura e inclusão de dois itens na classe 1) são as seguintes:

1. Baseadas na modelagem da máquina de indução:
 - (a) pela estimação do escorregamento: usando as equações dq da máquina de indução em regime permanente ou em regime dinâmico;
 - (b) através do modelo de estado ou função de transferência;
 - (c) sistemas adaptativos por modelo de referência (MRAS);
 - (d) sistemas adaptativos convencionais;
 - (e) observadores convencionais (filtro de Kalman, Luemberger, etc);
 - (f) sistema de Estrutura Variável (VSS) e Modos Deslizantes (SM);

- (g) inteligência Computacional;
 - (h) outros.
2. Baseada nos harmônicos produzidos pelas saliências das máquinas de indução e pelos efeitos de saturação:
- (a) baseados na alimentação fundamental;
 - (b) baseados na injeção de sinais de alta frequência.

Em 2000, Landim e outros [52] propuseram um observador de velocidade rotórica utilizando o algoritmo Neo-Fuzzy-Neuron [108]. O observador proposto possui convergência em apenas um passo, alta precisão, baixo custo computacional, robustez às variações de R_r , R_s e à aplicações e retiradas de carga. Foram apresentados resultados de simulação e experimentais do observador em um acionamento DUFOR *sensorless* do MI.

Outros observadores de velocidade propostos podem ser vistos em [4], [10], [21], [24], [30], [33], [46], [54], [67], [79], [82], [83], [84], [98] e [104].

As técnicas baseadas na modelagem da máquina de indução (classe 1) utilizam a força contra-eletromotriz para extrair a informação da velocidade. Os problemas apresentados pelas técnicas desta classe de estimadores (ou observadores) de velocidade são os seguintes:

- sensibilidade às variações paramétricas e a ruídos de medição e/ou
- baixa convergência e estabilidade em velocidades baixa e nula e/ou
- necessidade da informação do fluxo de rotor. Neste caso, quando o observador de fluxo também precisa da informação da velocidade, pode haver uma instabilidade dos observadores (de fluxo e velocidade) como um todo. Quando se utiliza uma estimação de fluxo (para evitar a necessidade da informação de velocidade), há problemas de estabilidade devido aos problemas de integração (já mencionados anteriormente).

Deve-se frisar a importância de uma boa estimação dos parâmetros da MI, bem como uma boa medição das tensões e correntes que a alimentam, a fim de se recuperar convenientemente a informação de posição/velocidade. Uma técnica eficiente de medição

das tensões PWM da MI pode ser vista em [78].

As técnicas baseadas nos harmônicos produzidos pelas saliências das máquinas de indução (classe 2) apresentam os seguintes problemas :

- problemas em velocidades baixa ou nula;
- influência da saturação e atrasos devido a filtragens do sinal;
- necessidade de elevado esforço computacional ou de hardware extra;
- necessidade de modificações na máquina;
- necessidade do conhecimento dos parâmetros estruturais da MI.

Os observadores baseados em IC têm numerosas vantagens sobre os observadores convencionais [102] e [103]. Dentre elas, podemos citar:

- seu projeto pode não necessitar do modelo do motor;
- podem levar à melhora do desempenho quando adequadamente ajustados;
- podem ser projetados incluindo a informação lingüística disponível, obtida a partir de especialistas no sistema;
- podem ser projetados utilizando uma combinação de informação lingüística e baseada em respostas;
- podem levar a uma generalização extremamente boa, sendo conseqüentemente independente das características particulares dos sistemas de acionamentos elétricos;
- podem ser facilmente adaptados a novas situações, através da incorporação de novas informações;
- podem exibir boas propriedades de rejeição a ruídos.

Contudo, as técnicas de IC também possuem suas desvantagens. As RNAs, por exemplo, demandam grande tempo de projeto, devido à necessidade de ajustes dos seus parâmetros (número de camadas escondidas, número de nodos em cada camada, etc.). Isto levou à utilização de técnicas híbridas (ou seja, que utilizam duas ou mais

das tecnologias da IC), que utilizem as vantagens de cada uma, inclusive aproveitando o conhecimento do modelo da planta para diminuir o tempo de projeto.

Assim, a utilização da IC mostra-se uma alternativa interessante para a proposição de observadores de fluxo e de velocidade apropriados a sistemas não-lineares, com distúrbios, que resolvam os problemas existentes e que sejam de implementação fácil e relativamente barata.

1.4 Contribuições da Tese

Este trabalho está relacionado à linha de pesquisa de observadores de estados para sistemas dinâmicos. As principais contribuições associadas a esta linha de pesquisa são:

- Desenvolvimento de uma metodologia de projeto de observadores de estado de sistemas dinâmicos utilizando o algoritmo Neo-Fuzzy-Neuron com treinamento *on-line* e com convergência em apenas **um passo** [53]:
 - proposição e demonstração de um teorema que permite a adequada escolha de uma equação de mapeamento, dentre aquelas candidatas;
 - desenvolvimento de expressões válidas para certos tipos de equações de mapeamento e que podem ser aplicadas no problema de observação de qualquer sistema dinâmico em tempo real (que possibilite a obtenção destes tipos de equação de mapeamento);
 - desenvolvimento de uma expressão para atualização dos pesos com taxa de aprendizado ótima (com relação à minimização da função de erro), que leva o observador à convergência em apenas **um passo de cálculo** para uma determinada classe de equações de mapeamento.
- Desenvolvimento de um observador de fluxos para a MI [48], [49], [50] e [51]:
 - Aplicação da metodologia de projeto para observadores de estados NFN;
 - Desenvolvimento de expressões para obtenção da taxa de aprendizado ótima;
- Desenvolvimento de três observadores de velocidade para a MI [52]:
 - Aplicação da metodologia de projeto para observadores de estados NFN;
 - Desenvolvimento de expressões para obtenção da taxa de aprendizado ótima;

As publicações resultantes deste trabalho foram as seguintes:

- *On-line Neo-Fuzzy-Neuron State Observer*, no VI Simpósio Brasileiro de Redes Neurais, 2000 [53];
- *Speed Sensorless Field-Oriented Control of Induction Machines Using a Real Time Neo-Fuzzy-Neuron Algorithm*, no IEEE Industry Applications Conference, 2000 [52];
- *Estimação de Estados do Motor de Indução Utilizando Rede Neuro-Fuzzy com Aprendizado em Tempo Real*, na I Semana de Pós-Graduação da UFMG, 1999 [51];
- *Nonlinear System Identification Using a Neo Fuzzy Neuron Algorithm: Electrical Drive Application*, no International Journal of Neural Systems, 1999 [50];
- *A Neo-Fuzzy-Neuron with Real Time Training Applied to Flux Observer for an Induction Motor*, no V Simpósio Brasileiro de Redes Neurais, 1998 [49];
- *Observador de Fluxo para Máquinas de Indução Utilizando uma Rede Neo-Fuzzy-Neuron-Generalizada*, no Congresso Brasileiro de Automática, 1998 [48].

1.5 Conclusões e Organização do Texto

Neste capítulo, foi feita uma introdução geral sobre o trabalho. Levantou-se o *estado da arte* nas linhas de pesquisa de observadores de fluxos e de velocidade para a MI. Foram vistas as principais técnicas e problemas existentes na obtenção dos fluxos e da velocidade da MI. Para isto, foi feita uma extensa revisão bibliográfica a partir das fontes acessíveis (periódicos do IEEE, periódicos do IEE, anais de congressos nacionais e internacionais, livros, Internet, etc). Também foram vistas as contribuições originadas neste trabalho.

O capítulo 2 apresenta a estrutura da rede NFN. As informações contidas neste capítulo foram obtidas a partir de [14] e de [108], com uma pequena mudança de notação. Estas informações são importantes para um melhor entendimento dos capítulos posteriores, que utilizam como base esta estrutura de rede.

No capítulo 3, é apresentada uma nova proposta de observação de estados de sistemas dinâmicos em tempo real utilizando o algoritmo Neo-Fuzzy-Neuron com

treinamento *on-line*, com convergência em apenas **um passo**. São apresentadas as condições para a obtenção de uma expressão para atualização dos pesos com taxa de aprendizado ótima, que levará o observador à convergência em apenas **um passo de cálculo**. Baseados nesta proposta, são desenvolvidos quatro observadores de estados para a máquina de indução: um observador de fluxos de rotores e três observadores de velocidade rotórica.

O capítulo 4 apresenta a avaliação dos observadores propostos. São abordados os índices de desempenho utilizados para avaliar os acionamentos elétricos de alto desempenho, bem como testes e critérios de avaliação para os observadores propostos. Resultados de simulação e experimentais são apresentados e discutidos.

No capítulo 5 as principais contribuições deste trabalho são resumidas. Além disso, são apresentadas as propostas de continuidade.

As unidades utilizadas neste trabalho são do Sistema Internacional de Unidades (SI). Entretanto, no SI não há distinção entre o radiano elétrico e o radiano mecânico, distinção esta importante na área de acionamentos elétricos. A relação entre estas unidades é dada por:

$$rad\ elétrico = \frac{P}{2} . rad\ mecânico \quad (1.2)$$

A não ser quando explicitado o contrário, a unidade *rad* utilizada neste trabalho refere-se a *rad elétrico*.

Além disso, as simulações feitas neste trabalho foram numéricas.

Capítulo 2

Introdução às Redes Neo-fuzzy-Neuron

2.1 Introdução

O processo de estimação de estados de sistemas dinâmicos exige um mecanismo de identificação do sistema e consiste na obtenção de um modelo que mais se aproxime do sistema em questão. Os métodos clássicos de identificação de sistemas baseiam-se em modelos matemáticos de sistemas dinâmicos, particularmente aqueles com uma única entrada e uma única saída (SISO), lineares e invariantes no tempo [74]. Admitindo certas simplificações, alguns sistemas dinâmicos podem ser representados por modelos deste tipo, e assim ser tratados pelos métodos clássicos de identificação. O erro admitido nestas simplificações pode ser desprezível para sistemas simples, numa grande faixa de operação. Contudo, à medida que o grau de complexidade do sistema a ser identificado aumenta, o erro pode tornar-se demasiado grande e a faixa de operação muito pequena, inviabilizando a identificação, ou ainda tornando-a computacionalmente “pesada” (exigindo um tempo de cálculo muito grande). Nestes casos, deve-se partir para técnicas de identificação mais adequadas para sistemas não-lineares, variantes no tempo, de várias entradas e várias saídas (MIMO), sujeitos a distúrbios e incertezas.

As Redes Neurais Artificiais (RNAs) são uma boa alternativa para a identificação de sistemas deste tipo devido às suas características de aprendizado, adaptação e generalização. A topologia mais comumente utilizada é a *perceptron* multicamadas (MLP), que usa o treinamento supervisionado, geralmente, através do algoritmo *back-propagation* ou suas variações.

O processo de ajustes de pesos das redes MLP utilizando o algoritmo *back-propagation* é na verdade um problema de otimização. O problema consiste em otimizar

uma *função-objetivo* (a função de erro, por exemplo). A solução viável que otimiza a função, denomina-se *solução ótima*, e é obtida iterativamente, gerando uma seqüência de pontos $\mathbf{x}^{(0)}, \mathbf{x}^{(1)}, \dots, \mathbf{x}^{(j)}, \dots$ (onde $\mathbf{x}^{(j)} = [x_1^{(j)} \ x_2^{(j)} \ \dots \ x_n^{(j)}]^T$) que convergirão para um ponto desejável $\mathbf{x}^d$, que é, em geral, a solução do problema. Esta solução poderá ser um ponto de *mínimo local* ou um ponto de *mínimo global*. A existência de mínimos locais pode dificultar a obtenção do mínimo global, que é a solução realmente desejada. A convergência dos métodos de otimização não-lineares depende da condição inicial e do comportamento da função-objetivo [63].

O treinamento das redes MLP com o algoritmo *backpropagation* consiste na minimização de uma função não-linear, devido à característica não-linear da função de ativação dos neurônios. Por isto, a função-objetivo não é estritamente convexa, apresentando mínimos locais [108], e além disso, a condição inicial é determinada aleatoriamente. Assim, a convergência não é assegurada.

Modelos de identificação não-lineares podem gerar superfícies de erro com muitos mínimos locais, o que torna impossível provar sua convergência global [56]. O algoritmo Neo-Fuzzy-Neuron, proposto por Yamakawa e outros [108] em 1992, resolve o problema de mínimos locais porque a função-objetivo a ser minimizada, dada a estrutura da rede, é quadrática e convexa. Como exemplos de aplicações deste algoritmo pode-se citar: previsão de temperaturas para alimentos em congelamento [73], identificação de sistemas [14], predição de comportamentos caóticos [108] e observação de estados em acionamentos elétricos [50], [52] e [53].

Neste capítulo, será vista a estrutura da rede Neo-Fuzzy-Neuron (NFN), bem como seu algoritmo de aprendizagem. Será mostrado também um algoritmo para determinar a taxa de aprendizado que garante a convergência para a solução ótima em apenas um passo de cálculo.

2.2 Algoritmo Neo-Fuzzy-Neuron (NFN)

2.2.1 Estrutura do Neo-Fuzzy-Neuron [108]

Na fig.2.1, pode-se ver a estrutura do NFN. As entradas $x_1, \dots, x_i, \dots, x_I$ da rede passam por *blocos de nebulização-desnebulização*, representados por $f_1, \dots, f_i, \dots, f_I$, para gerar as saídas $y_1, \dots, y_i, \dots, y_I$, respectivamente. I é o número de entradas e o universo de discurso da entrada x_i está particionada em M_i funções de pertinência. Cada bloco f_i é composto pela *partição nebulosa* $\mu_{i1}, \dots, \mu_{im_i}, \dots, \mu_{iM_i}$ e cada elemento de partição (ou função de pertinência) μ_{im_i} está vinculada a um peso variável W_{im_i} . A soma dos termos $\mu_{im_i} \cdot W_{im_i}$ ($i = 1, \dots, I; m_i = 1, \dots, M_i$) gera uma saída nebulizada, que passa por um *processo de desnebulização* para gerar a saída y_i , chamado de *processamento sináptico*. A saída do neurônio, y , é a soma de todas as saídas y_i .




Figura 2.1- Estrutura do NFN

Assim, a saída do NFN pode ser representada pela seguinte equação

$$y = \sum_{i=1}^I y_i = \sum_{i=1}^I f_i(x_i) \quad (2.1)$$

O processamento sináptico está associado a um conjunto de regras nebulosas do tipo *se-então*. Como o universo de discurso da entrada x_i está particionado de acordo com M_i funções de pertinência, temos as seguintes M_i regras:

- R_i^1 : se x_i é A_{i1} então y_i é W_{i1} ;
- R_i^2 : se x_i é A_{i2} então y_i é W_{i2} ;
- $\vdots$
- $R_i^{m_i}$: se x_i é A_{im_i} então y_i é W_{im_i} ;
- $\vdots$
- $R_i^{M_i}$: se x_i é A_{iM_i} então y_i é W_{iM_i} .

Para este conjunto de regras nebulosas, x_i e y_i são variáveis linguísticas com universo $\mathbb{R}$, A_{im_i} são termos linguísticos cujos significados são dados por conjuntos nebulosos, definidos por $\mu_{im_i}(x_i)$ e W_{im_i} são termos linguístico conseqüentes (pesos da rede). Considerando funções de pertinência triangulares e complementares (fig.2.2), o valor da função de pertinência, $\mu_{im_i}(x_i)$, é diferente de zero somente para uma ou duas funções de pertinência. Assim, para cada variável de entrada x_i , no máximo duas das M_i regras são ativadas, sendo indexadas por k_i e $k_i + 1$. Além disso, elas são consecutivas.




Figura 2.2- Funções de pertinência

Utilizando o produto para implementar a relação nebulosa associada à respectiva regra (fig.2.3), o mecanismo *max – min* de inferência nebulosa e o método do centro de gravidade para efetuar a *desnebulização*, os valores das sinapses podem ser determinados por

$$\begin{aligned} y_i &= f_i(x_i) = \frac{\sum_{m_i=1}^{M_i} \mu_{im_i}(x_i) \cdot W_{im_i}}{\sum_{m_i=1}^{M_i} \mu_{im_i}(x_i)} \\ &= \frac{\mu_{ik_i}(x_i) \cdot W_{ik_i} + \mu_{i(k_i+1)}(x_i) \cdot W_{i(k_i+1)}}{\mu_{ik_i}(x_i) + \mu_{i(k_i+1)}(x_i)} \end{aligned} \quad (2.2)$$

Como as funções de pertinência são complementares, a soma do grau de pertinência de duas funções consecutivas é igual a 1. Assim, temos a expressão final para a saída y_i :

$$y_i = f_i(x_i) = \mu_{ik_i}(x_i) \cdot W_{ik_i} + \mu_{i(k_i+1)}(x_i) \cdot W_{i(k_i+1)} \quad (2.3)$$




Figura 2.3- Processamento de um NFN

Durante o treinamento do NFN, apenas um ou dois pesos correspondentes às funções de pertinência ativadas são ajustados de forma a minimizar o erro. Isto sugere que o NFN pode exibir um período de treinamento muito menor do que as RNAs convencionais [108].

2.2.2 Algoritmo de Aprendizado [108]

O treinamento do NFN é *supervisionado*, podendo ser *em lote* ou *de local* (também conhecido como *incremental*). No treinamento em lote, são apresentados ao NFN todos os padrões (de treinamento), onde cada padrão consiste no par $\{x, y^d\}$, sendo x o vetor de entradas da rede de um determinado padrão e y^d a saída desejada. Para cada vetor de entrada x apresentado à rede, esta fornecerá um valor de saída y que será comparada com o valor desejado y^d . O erro quadrático desta comparação, ε , é usado para ajustar os parâmetros da rede após a apresentação de todos os padrões. Estes passos são repetidos até que a rede tenha “aprendido”. A capacidade de generalização do NFN é verificada após o treinamento, na *etapa de validação*. No treinamento de modo local, os parâmetros são atualizados a cada apresentação do par $\{x, y^d\}$ à rede [23].

Além disso, o treinamento pode ser *on-line* ou *off-line*. No treinamento *off-line*, os parâmetros variam durante a etapa de treinamento e são mantidos fixos na etapa de validação. No treinamento *on-line*, os parâmetros são ajustados para cada padrão apresentado. Convém salientar que o treinamento *off-line* pode ser feito em lote ou de modo local, enquanto que o treinamento *on-line* só pode ser feito de modo local.

Para a identificação de sistemas dinâmicos rápidos, variantes no tempo e sujeitos a distúrbios, o treinamento supervisionado *on-line*, sem treinamento prévio, é o mais indicado. Desde que se garanta a sua convergência num período de tempo menor do que a menor constante de tempo do sistema a ser identificado, a rede pode se adaptar às variações paramétricas ou distúrbios do sistema, com a vantagem de não demandar tempo de treinamento prévio.

Assim, o método de treinamento utilizado neste trabalho foi do tipo supervisionado *on-line*, sem treinamento prévio. Os parâmetros a serem ajustados são os pesos da rede NFN (resultantes dos consequentes das regras nebulosas) W_{im_i} (fig. 2.4).




Figura 2.4- Diagrama de blocos do treinamento do NFN

2.2.2.1 Atualização dos Pesos com Taxa de Aprendizado Ótima [14]

Seja $X = (x_1, x_2, \dots, x_i, \dots, x_I)$ o padrão aplicado à entrada do Neo-Fuzzy-Neuron, y a saída calculada e y^d seu respectivo valor desejado. O erro quadrático para o padrão de entrada é definido como

$$\varepsilon = \frac{1}{2} (y - y^d)^2 = \frac{1}{2} e^2 = \varepsilon(\mathbf{W}) \quad (2.4)$$

onde $\mathbf{W} = [w_{11} \ w_{12} \ \dots \ w_{1m_i} \ \dots \ w_{Im_i}]$.

O algoritmo de treinamento consiste na atualização dos pesos, para cada padrão de entrada, de modo que o erro ε possa ser minimizado. O problema a ser resolvido pode ser descrito da seguinte forma:

$$(P_1) \left[\begin{array}{c} \min \varepsilon(W_{im_i}) \\ W_{im_i} \in \Re \\ \forall i = 1, \dots, I; m_i = 1, \dots, M_i \end{array} \right] \quad (2.5)$$

Para cada coordenada de entrada x_i , dentre as entradas apresentadas ao NFN, somente as funções $\mu_{ik_i}(x_i)$ e $\mu_{i(k_i+1)}(x_i)$ são diferentes de zero. Assim podemos reescrever o problema P_1 como:

$$(P_2) \left[\begin{array}{c} \min \varepsilon(W_{im_i}) \\ W_{im_i} \in \Re \\ \forall i = 1, \dots, I; m_i = k_i, k_i + 1 \end{array} \right] \quad (2.6)$$

onde neste caso $\mathbf{W} = [w_{1k_1} \ w_{1(k_1+1)} \ w_{2k_2} \ w_{2(k_2+1)} \ \dots \ w_{ik_i} \ w_{i(k_i+1)} \ \dots \ w_{Ik_I} \ w_{I(k_I+1)}]$.

Resolvendo P_2 , a função a ser minimizada tem $2.I$ variáveis, independentemente do número de funções de pertinência, enquanto que resolvendo P_1 , o número de variáveis a ser minimizado é $M_i.I$. A função a ser minimizada em P_2 , $\varepsilon(\mathbf{W})$, é quadrática e convexa e o seu mínimo local é mínimo global [14].

Como a função $\varepsilon(\mathbf{W})$ é não-linear, P_2 é um problema de programação não-linear, onde a convergência para uma solução ótima depende do ponto inicial, da direção de busca e do comprimento do passo. Para o NFN, a condição inicial será nula, sem prejuízo para a convergência do algoritmo, como será visto mais adiante.

A seqüência de pontos gerados pelos métodos iterativos utilizados advém de passos sucessivos. Assim, a partir de $\mathbf{x}^{(j)}$, escolhe-se como caminho ou direção, um vetor $\mathbf{h}$ [63]. Para a escolha da direção, o método do *gradiente* será aqui adotado. Além de ser o mais simples, ele permite a obtenção da taxa de aprendizado que leva à convergência do algoritmo em apenas um passo de cálculo. O vetor gradiente, calculado no ponto $\mathbf{x}$, aponta na direção de maior crescimento da função. O método do gradiente escolhe como direção aquela oposta, ou seja, a de menor crescimento. Assim, temos:

$$\mathbf{h}^{(j)} = -\nabla \varepsilon(\mathbf{W}^{(j)}) \quad (2.7)$$

onde j é o número de iteração.

A variação dos pesos é dada por:

$$\Delta W^{(j)} = \alpha \cdot \mathbf{h}^{(j)} \quad (2.8)$$

assim,

$$\Delta W_{ik_i}^{(j)} = -\alpha^{(j)} \cdot \frac{\partial \varepsilon(W_{ik_i}^{(j)})}{\partial W_{ik_i}^{(j)}} = -\alpha^{(j)} \cdot \frac{\partial \varepsilon^{(j)}}{\partial e^{(j)}} \frac{\partial e^{(j)}}{\partial y^{(j)}} \frac{\partial y^{(j)}}{\partial W_{ik_i}^{(j)}} \quad (2.9)$$

Portanto, uma componente $W_{ik_i}^{(j)}$ é atualizada da seguinte forma

$$W_{ik_i}^{(j+1)} = W_{ik_i}^{(j)} - \alpha^{(j)} \cdot (y^{(j)} - y^d) \cdot \mu_{ik_i}^{(j)}(x_i) \quad (2.10)$$

O comprimento do passo, α (chamado de *taxa de aprendizagem* no contexto de redes neurais), pode ser determinado heurísticamente ou através de algum método de busca unidirecional.

Os métodos de busca unidirecional se dividem em [63]:

1. Reduções sucessivas de intervalos: após limitar α no intervalo $[a, b]$, reduzir este intervalo até a precisão desejada. Podem ser:
 - (a) diretos: exigem funções unimodais; não exigem diferenciabilidade (método de Fibonacci, método da seção áurea, etc.);
 - (b) aproximação por polinômios: exigem funções “bem comportadas”, ou seja, funções convexas ou continuamente diferenciáveis de primeira ou de segunda ordem (método de Newton, método da secante, método DSC-Powell e assim por diante).
2. Finitos ou aprofundamento: exigem derivadas direcionais no ponto de partida, porém não exigem convexidade. Não se preocupam em minimizar a função; apenas em “reduzi-la bastante” (método de Armijo, método de Goldstein e assim por diante).

Levando em consideração que a função objetivo do NFN a ser minimizada é quadrática e convexa, Caminhas [14] propôs um método de obtenção dinâmica da taxa de aprendizagem que obtém os pesos do NFN que proporcionam erro de aproximação nulo **em apenas um passo**, dado por:

$$\alpha^{(j)} = \frac{1}{\sum_{i=1}^I \left[\left(\mu_{ik_i}^{(j)}(x_i) \right)^2 + \left(\mu_{i(k_{i+1})}^{(j)}(x_i) \right)^2 \right]} \quad (2.11)$$

2.2.3 Neo-Fuzzy-Neuron Generalizado [14]

A estrutura do NFN mostrada na fig.2.1 apresenta apenas uma saída. Portanto, permite um mapeamento não-linear entre um espaço multidimensional e um espaço unidimensional. Para o caso de sistemas MIMO, o mapeamento deve ser de um espaço multidimensional para outro. Assim, pode-se utilizar L NFN independentes para um sistema com L saídas. Contudo, a etapa de nebulização deverá ser feita L vezes. Usando a estrutura em forma de rede chamada de *Neo-Fuzzy-Neuron generalizada* (fig.2.5), a etapa de nebulização é feita apenas uma vez, a cada passo de cálculo.




Figura 2.5- a) Diagrama de blocos do Neo-Fuzzy-Neuron generalizado b) Bloco $F_i(x_i)$

De maneira análoga ao NFN, as saídas y_l e y_{il} do NFN generalizado são dados por:

$$f_{il}(x_i^{(j)}) = \mu_{ik_i}(x_i^{(j)}) \cdot W_{ik_i l} + \mu_{i(k_i+1)}(x_i^{(j)}) \cdot W_{i(k_i+1)l} \quad (2.12)$$

$$y_l^{(j)} = \sum_{i=1}^I y_{il}^{(j)} = \sum_{i=1}^I f_{il}(x_i^{(j)}) \quad (2.13)$$

Se y_l é a saída calculada e y_l^d é o seu respectivo valor desejado, onde $l = 1, 2, \dots, L$ (L é o número de saídas), pode-se definir os L erros quadráticos como

$$\varepsilon_l^{(j)} = \frac{1}{2}(y_l^{(j)} - y_l^d)^2 = \varepsilon_l(W_{im_i l}^{(j)}) \quad (2.14)$$

O treinamento do NFN generalizado consiste na minimização dos l erros (para cada padrão apresentado) acima.

O novo peso é calculado por

$$W_{ik_i l}^{(j+1)} = W_{ik_i l}^{(j)} - \alpha^{(j)} \cdot (y_l^{(j)} - y_l^d) \cdot \mu_{ik_i}(x_i^{(j)}) \quad (2.15)$$

Os principais passos do algoritmo são:

- escolha das I entradas e L saídas da rede;
- escolha do número de funções de pertinência M_i e dos valores máximo e mínimo de cada entrada, assim como do tipo de funções de pertinência;
- escolha do valor inicial dos pesos $W_{im_i l}$;
- cálculo das funções $f_{il}(x_i)$ (eq. 2.12);
- cálculo das saídas y_l (eq. 2.13);
- cálculo da taxa de aprendizagem α (eq. 2.11);
- atualização dos pesos (eq. 2.15).

Devido ao fato do NFN generalizado possuir mais de uma saída, em analogia às RNAs, o NFN generalizado pode ser encarado como *uma rede NFN*.

2.3 Conclusões

Neste capítulo foi mostrada a estrutura da rede Neo-Fuzzy-Neuron (NFN), bem como o algoritmo de aprendizagem. Foi mostrada também uma expressão para determinar a taxa de aprendizado que garante a convergência para a solução ótima em apenas um passo de

cálculo. Esta rápida convergência possibilita a utilização da rede NFN em treinamento em tempo real.

Capítulo 3

Observadores de Estados

Neo-Fuzzy-Neuron

3.1 Introdução

A rede NFN pode ser utilizada na observação de estados de sistemas dinâmicos. Devido às suas características, não é necessário a definição do número de camadas intermediárias nem da respectiva quantidade de neurônios (como nas MLPs convencionais), o que torna o seu projeto simples. Conforme visto anteriormente (item 2.2.2), o treinamento do NFN pode ser feito *on-line* ou *off-line*.

Na utilização do NFN com treinamento *off-line*, o tempo de treinamento pode ser relativamente longo (embora não tão longo quanto o das redes neurais convencionais [108]) e o erro de predição (durante a etapa de validação, com os pesos fixos) pode ser considerável para sistemas dinâmicos muito complexos.

Na utilização do NFN com treinamento *on-line* na observação de estados, torna-se necessária a utilização de uma *equação de mapeamento* entre os estados observados, $\hat{y}_l$, e os estados observados ($\hat{z}_l$) a serem comparados com os medidos, z_l^d , já que os estados a serem observados, y_l , são desconhecidos. Para isto, é necessário algum conhecimento do sistema cujos estados se quer observar. Uma vez obtida uma equação de mapeamento, pode ser possível obter uma taxa de aprendizado tal que permita a convergência do observador em apenas um passo de cálculo, sem a necessidade de treinamento prévio ou de métodos para uma melhor inicialização dos pesos. Portanto, o observador de estados desenvolvido neste trabalho utiliza treinamento *on-line*.

No restante do capítulo será demonstrado um teorema que permite a adequada escolha de uma equação de mapeamento, dentre aquelas candidatas. Serão desenvolvidas expressões válidas para equações de mapeamento que possuam inversa e cujas derivadas (da equação de mapeamento e de sua inversa) sejam diferentes de zero. Será mostrado que estas expressões poderão ser aplicadas no problema de observação de qualquer sistema dinâmico em tempo real que possibilite a obtenção deste tipo de equação de mapeamento. Em seguida, será restringindo o universo de equações de mapeamento para uma determinada classe, sendo demonstrada uma expressão para atualização dos pesos com taxa de aprendizado ótima, que levará o observador à convergência em apenas **um passo de cálculo**. Serão então desenvolvidos quatro observadores de estados (um observador de fluxos de rotores e três observadores de velocidade rotórica) com equações de mapeamento pertencentes a esta classe, para aplicação em sistemas de acionamento de máquinas de indução, cujo tempo de resposta deve ser rápido o suficiente para um satisfatório desempenho dinâmico do acionamento.

3.2 Observador de Estados NFN [53]

Conforme dito anteriormente, a utilização do NFN com treinamento *on-line* para a observação de estados requer uma *equação de mapeamento*, já que o estado a ser observado, y_l , é desconhecido. As equações de mapeamento nada mais são do que um *estimador* que relaciona os estados a serem observados com os estados a serem comparados.

Assim, a saída da rede NFN, $\hat{y}_l$, é mapeada para o estado observado, $\hat{z}_l$, que será comparado com o sinal desejado, z_l^d , gerando o erro a ser usado para a correção dos pesos, sendo $g(.)$ uma função qualquer que mapeia a entrada x_i para y_l (fig. 3.1 e fig. 3.2). A função (ou equação) de mapeamento $h(.)$ é tal que:

$$\hat{z}_l \triangleq h(\hat{y}_l), l = 1 \dots L \quad (3.1)$$




Figura 3.1- a) Diagrama de blocos de um observador de estados com rede NFN b) Bloco $F_i(x_i)$




Figura 3.2- Processo de ajuste dos pesos do observador de estados NFN

A escolha de uma equação de mapeamento adequada, dentre as candidatas, pode ser facilitada com a utilização do teorema a seguir:

Lemma 1 *Seja $\hat{z} = h(\hat{y})$ uma função contínua e estritamente monotônica pertencente ao intervalo $[\hat{y}_1, \hat{y}_2]$. Assim, se $\hat{y}_1 \neq \hat{y}_2$ então $h(\hat{y}_1) \neq h(\hat{y}_2)$.*

A proposição acima pode ser verificada graficamente, como mostra a fig. 3.3.




Figura 3.3- Exemplo de função contínua estritamente monotônica crescente

Teorema 2 *Seja y_l o estado desconhecido a ser observado e seja z_l^d qualquer estado relacionado a y_l através da equação de mapeamento $h(\cdot)$ (eq. 3.1), onde $h(\cdot)$ é uma função contínua e estritamente monotônica no intervalo $[\hat{y}_1, \hat{y}_2]$ tal que h^{-1} exista no intervalo $[\hat{z}_1, \hat{z}_2]$. Além disso, as suas respectivas derivadas existem nos seus respectivos domínios. Seja $\hat{z}_l$ o estado observado a ser comparado com o estado desejado z_l^d que irá gerar o erro $e_z = \hat{z}_l - z_l^d$. Seja também $\hat{y}_l$ o estado observado relacionado a $\hat{z}_l$ através da equação de mapeamento $h(\cdot)$ que irá gerar o erro de observação $e_y = \hat{y}_l - y_l$. Então, $e_y = 0$ se $e_z = 0$, $\dot{h}(\hat{y}) \neq 0$ e $\dot{h}^{-1}(\hat{z}) \neq 0$, $\forall \hat{y} \in (\hat{y}_1, \hat{y}_2)$ e $\forall \hat{z} \in (\hat{z}_1, \hat{z}_2)$.*

Prova:

Seja $e_z = 0$, $\dot{h}(\hat{y}) \neq 0$ e $\dot{h}^{-1}(\hat{z}) \neq 0$. Assim, $\hat{z}_l = z_l^d$. Então $y_l = h^{-1}(z_l^d) = h^{-1}(\hat{z}_l)$, o que implica que $\hat{z}_l = h(y_l)$. Pelo lema 1, existe apenas um y_l que satisfaz a última relação. Assim, $\hat{y}_l = y_l$ e $e_y = \hat{y}_l - y_l = 0$.

O Teorema 1 é muito útil para a escolha da equação de mapeamento $h(\cdot)$, de modo que um erro nulo de observação entre $\hat{z}_l$ e z_l^d ($e_z = 0$) garanta um erro nulo de observação

entre $\hat{y}_l$ e y_l ($e_y = 0$), que é o que realmente interessa.

Uma vez obtida uma equação de mapeamento adequada, é importante garantir um erro nulo de observação entre $\hat{z}_l$ e z_l^d ($e_z = 0$). Isto é feito através da atualização adequada dos pesos da rede.

Conforme visto no item 2.2.3, as saídas $\hat{y}_l$ e y_{il} da rede NFN são dados por:

$$f_{il}(x_i^{(j)}) = \mu_{ik_i}(x_i^{(j)}) \cdot W_{ik_i l} + \mu_{i(k_i+1)}(x_i^{(j)}) \cdot W_{i(k_i+1)l} \quad (3.2)$$

$$\hat{y}_l^{(j)} = \sum_{i=1}^I y_{il}^{(j)} = \sum_{i=1}^I f_{il}(x_i^{(j)}) \quad (3.3)$$

Se $\hat{z}_l$ é a saída calculada (a partir das eq. 3.1, 3.2 e 3.3) e z_l^d é o seu respectivo valor desejado, onde $l = 1, 2, \dots, L$, pode-se definir os L erros quadráticos como:

$$\varepsilon_l(W_{im_i l}^{(j)}) = \frac{1}{2}(\hat{z}_l^{(j)} - z_l^d)^2 = \frac{1}{2}(e_l^{(j)})^2 \quad (3.4)$$

De maneira análoga ao item 2.2.2, os novos pesos da rede NFN serão dados por:

$$W_{ik_i l}^{(j+1)} = W_{ik_i l}^{(j)} - \eta^{(j)} \cdot \frac{\partial \varepsilon_l(W_{ik_i l}^{(j)})}{\partial W_{ik_i l}^{(j)}} \quad (3.5)$$

Das eq. 3.1, 3.2, 3.3 e 3.4, obtém-se:

$$\frac{\partial \varepsilon_l(W_{ik_i l}^{(j)})}{\partial W_{ik_i l}^{(j)}} = \frac{\partial \varepsilon_l^{(j)}}{\partial e_l^{(j)}} \frac{\partial e_l^{(j)}}{\partial \hat{z}_l^{(j)}} \frac{\partial \hat{z}_l^{(j)}}{\partial \hat{y}_l^{(j)}} \frac{\partial \hat{y}_l^{(j)}}{\partial W_{ik_i l}^{(j)}} = e_l^{(j)} \cdot \frac{\partial \hat{z}_l^{(j)}}{\partial \hat{y}_l^{(j)}} \cdot \mu_{ik_i}(x_i^{(j)}) \quad (3.6)$$

A equação de atualização dos pesos desejada é obtida de 3.5 e 3.6:

$$W_{ik_i l}^{(j+1)} = W_{ik_i l}^{(j)} - \eta^{(j)} \cdot e_l^{(j)} \cdot \frac{\partial \hat{z}_l^{(j)}}{\partial \hat{y}_l^{(j)}} \cdot \mu_{ik_i}(x_i^{(j)}) \quad (3.7)$$

A taxa de aprendizado pode ser fixa ou pode variar a cada iteração. Uma taxa de aprendizado fixa pode ser obtida através de simulações. Uma taxa de aprendizado variável pode ser obtida através de algum dos métodos de busca unidirecional ([63]) ou por algum método direto.

3.2.1 Equação de Atualização dos Pesos com Taxa de Aprendizado Ótima para uma Determinada Classe de Equações de Mapeamento

O método desenvolvido por [14] será adaptado para o desenvolvimento de uma expressão para o cálculo da taxa de aprendizado ótima, levando-se em consideração a inclusão de uma equação de mapeamento.

Para isto, considerar-se-á uma equação de mapeamento da classe:

$$\hat{z}_l = h(\hat{y}_l) = K_{0l} + K_{1l} \cdot \hat{y}_l, l = 1 \dots L \quad (3.8)$$

onde K_{0l} e K_{1l} podem ser constantes ou variáveis independentes de y_l , com K_{1l} diferente de zero.

De 3.8, pode-se obter:

$$\dot{h}(\hat{y}_l) = \frac{d\hat{z}_l(\hat{y}_l)}{d\hat{y}_l} = K_{1l} \quad (3.9)$$

$$y_l = h^{-1}(\hat{z}_l) = \left(\frac{1}{K_{1l}} \right) \cdot \hat{z}_l - \left(\frac{K_{0l}}{K_{1l}} \right) \quad (3.10)$$

$$\dot{h}^{-1}(\hat{z}_l) = \frac{d\hat{y}_l(\hat{z}_l)}{d\hat{z}_l} = \frac{1}{K_{1l}} \quad (3.11)$$

De 3.9 e 3.11, pode-se ver que a eq. 3.8 satisfaz o Teorema 1. Portanto, levando-se o erro de observação entre $\hat{z}_l$ e z_l^d a zero ($e_z = 0$), tem-se um erro nulo de observação entre $\hat{y}_l$ e y_l ($e_y = 0$).

Em virtude de cada peso da rede NFN estar relacionado a apenas uma saída (fig. 3.1), a rede com L saídas pode ser vista como L redes de apenas uma saída. Este fato simplifica bastante o projeto de observadores NFN, pois em uma única rede podem existir L observadores de estados independentes, cada um com sua respectiva equação de mapeamento. Assim, o desenvolvimento feito a seguir será genérico e valerá para quaisquer observadores NFN que utilizem uma equação de mapeamento da classe da eq. 3.8.

A partir das eq. 3.7 e 3.8, considerando-se os pesos iniciais nulos, pode-se obter a seguinte equação:

$$W_{ik_i l}^{(j+1)} = -\eta^{(j)} \cdot e_l^{(j)} \cdot K_{1l} \cdot \mu_{ik_i}(x_i^{(j)}) \quad (3.12)$$

Seja um dado padrão de entrada $\mathbf{x} = (x_1, x_2, \dots, x_i, \dots, x_I)$, e os valores desejados $\mathbf{z}^d = (z_1^d, z_2^d, \dots, z_l^d, \dots, z_L^d)$ para o mapeamento dado pelas eq. 3.2, 3.3 e 3.8. Dada a matriz de pesos $\mathbf{W}^{(j)}$, o objetivo é encontrar $\eta^{(j)}$ tal que o erro

$$\epsilon_l^{(j+1)} = \frac{1}{2} \left(e_l^{(j+1)} \right)^2 = 0 \quad (3.13)$$

onde

$$\begin{aligned} e_l^{(j+1)} &= \left(\hat{z}_l^{(j+1)} - z_l^d \right) = \left(K_{0l} + K_{1l} \cdot \hat{y}_l^{(j+1)} - z_l^d \right) = \\ &= K_{0l} + K_{1l} \cdot \sum_{i=1}^I [\mu_{ik_i}(x_i^{(j)}) \cdot W_{ik_i l}^{(j+1)} + \mu_{i(k_i+1)}(x_i^{(j)}) \cdot W_{i(k_i+1)l}^{(j+1)}] - z_l^d \end{aligned} \quad (3.14)$$

e

$$e_l^{(j)} = K_{0l} - z_l^d \quad (3.15)$$

para

$$W_{ik_i l}^{(j+1)} = -\eta^{(j)} \cdot e_l^{(j)} \cdot K_{1l} \cdot \mu_{ik_i}(x_i^{(j)}) \quad (3.16)$$

e

$$W_{i(k_i+1)l}^{(j+1)} = -\eta^{(j)} \cdot e_l^{(j)} \cdot K_{1l} \cdot \mu_{i(k_i+1)}(x_i^{(j)}) \quad (3.17)$$

A equação 3.13 é satisfeita se :

$$K_{0l} + K_{1l} \sum_{i=1}^I \left[\mu_{ik_i}(x_i^{(j)}) \cdot W_{ik_i l}^{(j+1)} + \mu_{i(k_i+1)}(x_i^{(j)}) \cdot W_{i(k_i+1)l}^{(j+1)} \right] = z_l^d \quad (3.18)$$

Multiplicando ambos os lados da eq. 3.16 por $\mu_{ik_i}(x_i^{(j)})$ e da eq. 3.17 por $\mu_{i(k_i+1)}(x_i^{(j)})$, tem-se:

$$\mu_{ik_i}(x_i^{(j)}) \cdot W_{ik_i l}^{(j+1)} = -\eta^{(j)} \cdot e_l^{(j)} \cdot K_{1l} \cdot \mu_{ik_i}^2(x_i^{(j)}) \quad (3.19)$$

e

$$\mu_{i(k_i+1)}(x_i^{(j)}) \cdot W_{i(k_i+1)l}^{(j+1)} = -\eta^{(j)} \cdot e_l^{(j)} \cdot K_{1l} \cdot \mu_{i(k_i+1)}^2(x_i^{(j)}) \quad (3.20)$$

para $i = 1, 2, \dots, I$.

Somando as $2 \cdot I$ equações, obtém-se

$$\begin{aligned} & \sum_{i=1}^I \mu_{ik_i}(x_i^{(j)}) \cdot W_{ik_i l}^{(j+1)} + \mu_{i(k_i+1)}(x_i^{(j)}) \cdot W_{i(k_i+1)l}^{(j+1)} = \\ & -\eta^{(j)} \cdot e_l^{(j)} \cdot K_{1l} \cdot \sum_{i=1}^I \left[\mu_{ik_i}^2(x_i^{(j)}) + \mu_{i(k_i+1)}^2(x_i^{(j)}) \right] \end{aligned} \quad (3.21)$$

Multiplicando a eq. 3.21 por K_{1l} e somando K_{0l} em ambos os lados, tem-se:

$$\begin{aligned} & K_{0l} + K_{1l} \cdot \sum_{i=1}^I \mu_{ik_i}(x_i^{(j)}) \cdot W_{ik_i l}^{(j+1)} + \mu_{i(k_i+1)}(x_i^{(j)}) \cdot W_{i(k_i+1)l}^{(j+1)} = \\ & K_{0l} - \eta^{(j)} \cdot e_l^{(j)} \cdot K_{1l}^2 \cdot \sum_{i=1}^I \left[\mu_{ik_i}^2(x_i^{(j)}) + \mu_{i(k_i+1)}^2(x_i^{(j)}) \right] \end{aligned} \quad (3.22)$$

Das eq. 3.15, 3.18 e 3.22, pode-se obter:

$$\eta^{(j)} \cdot e_l^{(j)} \cdot K_{1l}^2 \cdot \sum_{i=1}^I \left[\mu_{ik_i}^2(x_i^{(j)}) + \mu_{i(k_i+1)}^2(x_i^{(j)}) \right] = e_l^{(j)} \quad (3.23)$$

Do item 2.2.2.1, tem-se:

$$\alpha^{(j)} = \frac{1}{\sum_{i=1}^I \left[\left(\mu_{ik_i}^{(j)}(x_i) \right)^2 + \left(\mu_{i(k_i+1)}^{(j)}(x_i) \right)^2 \right]} \quad (3.24)$$

De 3.23 e 3.24:

$$\eta^{(j)} = \frac{1}{K_{1l}^2 \cdot \sum_{i=1}^I \left[\mu_{ik_i}^2(x_i^{(j)}) + \mu_{i(k_i+1)}^2(x_i^{(j)}) \right]} = \frac{\alpha^{(j)}}{K_{1l}^2} \quad (3.25)$$

Assim, o observador de estados NFN utilizando a equação de mapeamento do tipo da eq. 3.8 convergirá em **um passo**, se a atualização dos pesos for dada por:

$$W_{ik_i l}^{(j+1)} = -\alpha^{(j)} \cdot \left(\hat{z}_l^{(j)} - z_l^d \right) \cdot \left(\frac{1}{K_{1l}} \right) \cdot \mu_{ik_i}(x_i^{(j)}), l = 1 \dots L \quad (3.26)$$

$$W_{i(k_i+1)l}^{(j+1)} = -\alpha^{(j)} \cdot \left(\hat{z}_l^{(j)} - z_l^d \right) \cdot \left(\frac{1}{K_{1l}} \right) \cdot \mu_{i(k_i+1)}(x_i^{(j)}), l = 1 \dots L \quad (3.27)$$

onde a taxa de aprendizado α é dada pela eq. 3.24, $\hat{z}_l^{(j)}$ é obtida através das eq. 3.2, 3.3 e 3.8, e os pesos iniciais são $W_{ik_i l}^{(j)}$ e $W_{i(k_i+1)l}^{(j)}$ nulos.

Convém aqui salientar a diferença entre o passo da malha de controle, n , e o passo da malha do observador, j . Em cada passo n , os estados acessíveis da máquina de indução são medidos, e a partir destes, os estados inacessíveis são observados e as variáveis de controle da MI são definidas de forma a levá-la ao próximo estado desejado. No primeiro passo da malha de observação, j , o observador de estados NFN calcula as saídas observadas, $\hat{y}_l^{(j)}$ e $\hat{z}_l^{(j)}$, utilizando as entradas atuais, $x_l^{(j)} = x_l^{(n)}$, e os pesos atuais,

$W_{ik_i l}^{(j)}$ e $W_{i(k_i+1)l}^{(j)}$ (nulos no nosso caso). O erro de observação, $e_z = \hat{z}_l - z_l^d$, é utilizado para calcular os pesos ($W_{ik_i l}^{(j+1)}$ e $W_{i(k_i+1)l}^{(j+1)}$) que levarão o observador a um erro nulo. No segundo passo da malha de observação, $j + 1$ (ainda no primeiro passo da malha de controle), as saídas observadas, $\hat{y}_l^{(j+1)}$ e $\hat{z}_l^{(j+1)}$, são calculadas com os pesos $W_{ik_i l}^{(j+1)}$ e $W_{i(k_i+1)l}^{(j+1)}$ e as entradas atuais ($x_l^{(j+1)} = x_l^{(n)}$), gerando um erro de observação supostamente nulo.

Assim, para a obtenção de um erro nulo de observação em apenas um passo da malha de controle n , são efetuados dois passos da malha do observador em cada n .

Pode-se notar, portanto, que apenas os pesos e as saídas da rede NFN variam a cada passo da malha de observação j .

As equações de atualização dos pesos com taxa de aprendizado ótima (eq. 3.26 e 3.27) permitem a convergência do observador de estados NFN em apenas um passo, não sendo, portanto, iterativas.

Em resumo, para projetar o observador de estados NFN, deve-se determinar o número de saídas L , a equação de mapeamento $h(\cdot)$, o número e o tipo de funções de pertinência M_i para cada entrada x_i , a taxa de aprendizado α (para treinamento com α 's fixos) e o número de entradas I (assim como seus respectivos universos de discurso).

A utilização de funções de pertinência triangulares e complementares permite a ativação de no máximo duas funções de pertinência por vez. Assim, serão necessárias apenas duas funções de pertinência para cada entrada da rede.

Os principais passos do algoritmo do *observador de estados NFN* são:

1. inicialização dos pesos $W_{im_i l}$;
2. cálculo do grau de pertinência de acordo com o valor de cada entrada;
3. cálculo da função $f_{il}(x_i)$ (eq. 3.2);
4. cálculo das saídas (eq. 3.3 e 3.8);
5. cálculo da taxa de aprendizado (para treinamento com α 's variáveis. eq. 2.11);
6. atualização dos pesos (eq. 3.5).

3.3 Observador de Fluxo Rotórico Utilizando o Algoritmo Neo-Fuzzy-Neuron [50]

Nesta seção será proposto um observador de fluxo de rotor para máquinas de indução, baseado no observador de estados do item 3.2.

As principais características deste observador são:

- Necessidade das informações de correntes de estator e posição do rotor;
- Rápida convergência e alta precisão;
- Adaptabilidade às variações da dinâmica do sistema;
- Robustez às variações da indutância de magnetização, L_m (e conseqüentemente da indutâncias próprias de rotor, L_r , e de estator, L_s) e às variações de carga;
- Sensibilidade muito baixa às variações da resistência rotórica, R_r ;
- Independência da resistência estatórica, R_s ;
- Bom desempenho numa ampla faixa de velocidade (inclusive à velocidade zero);
- Baixo custo computacional;
- Aprendizado em tempo real sem a necessidade de treinamento prévio.

3.3.1 Definição da topologia da rede

Para a definição das entradas da rede, foi feita uma análise de correlação entre todas as variáveis do motor de indução (correntes, tensões, conjugado eletromagnético, fluxos, velocidade) e os fluxos de rotores de eixo d e q . A análise de correlação serve para indicar qual destas variáveis possui relação de causa-efeito entre si. Para isto, foi feita uma simulação em linguagem C[®] de um ensaio de partida e reversão de velocidade de um motor de indução sob controle vetorial por orientação pelo fluxo de rotor. O programa gerou um arquivo de pontos no padrão Matlab, de modo a se utilizar todo o ferramental gráfico que o mesmo oferece, inclusive pacotes de funções. Foi utilizada a função “myccf.m” do Matlab [3], que mostra o gráfico de correlação entre duas variáveis, para auxiliar na escolha

das entradas da rede NFN.

Algumas destas correlações estão apresentadas nas fig. 3.4 e 3.5. As duas linhas tracejadas horizontais limitam a região na qual a correlação é estatisticamente nula. Além disso, para uma relação entrada-saída (que foi a utilizada neste estudo), deve ser analisado o lado de abcissa negativa do gráfico (para uma relação saída-entrada, deve ser analisado o lado de abcissa positiva do gráfico) [15].

Analisando os gráficos, verifica-se que as variáveis que apresentaram alguma correlação, ou seja, possuem alguma relação de causa-efeito com os fluxos de rotores de eixo d e q (λ_{rd} e λ_{rq} , respectivamente), foram os próprios fluxos de rotores, o conjugado eletromagnético (T_e), os fluxos de estator de eixo d e q (λ_{sd} e λ_{sq} , respectivamente), e as correntes e tensões de estator (e de rotor) de eixo d e q (I_{sd} , I_{sq} , V_{sd} e V_{sq} , respectivamente). Como existe uma razoável correlação entre as correntes de estator de eixo d e q , e as demais variáveis que têm correlação com os fluxos de rotor de eixo d e q (algumas destas correlações estão apresentadas nas fig. 3.4 e 3.5), isto significa que a informação contida nestas variáveis também está presente nas correntes de estator de eixo d e q , o que as torna forte candidatas a entradas da rede. Portanto, escolheu-se como entradas da rede, as seguintes variáveis:

- $I_{sd}^{(n)}$;
- $I_{sq}^{(n)}$.

Assim, a topologia da rede NFN utilizada foi a seguinte:

1. Entradas:

- (a) $I_{sd}^{(n)}$;
- (b) $I_{sq}^{(n)}$.

2. Funções de pertinência: duas;

3. Saídas:

- (a) $\hat{\lambda}_{rd}^{(n)}$;
- (b) $\hat{\lambda}_{rq}^{(n)}$.

Além disso, é necessário o valor da posição do rotor θ_r para a mudança de referência do sistema de eixos dq , como será visto mais adiante.

Embora a rede não seja recorrente, as informações da dinâmica do sistema estão nos termos de correção (integrais de corrente de estator) e são fornecidas à rede através do ajuste dos pesos.




Figura 3.4- Correlação-cruzada de I_{sd} com λ_{rd}

3.3.2 Desenvolvimento do Observador

Conforme visto no item 3.2 é necessário a obtenção de uma equação de mapeamento entre os estados observados ($\hat{\lambda}_{rd}^{(j)}$ e $\hat{\lambda}_{rq}^{(j)}$) e algum dos estados da máquina de indução (MI) que possam ser medidos (ou obtidos a partir das medições).

A partir das equações de tensão rotórica e de enlace de fluxo de rotor da máquina de indução (apêndice B), em um referencial genérico, pode-se obter a seguinte equação:

$$\vec{I}_s^e = \frac{\vec{\lambda}_r^e}{L_m} + \left(\frac{L_r}{L_m \cdot R_r} \right) \cdot \frac{d\vec{\lambda}_r^e}{dt} + j \cdot \left(\frac{L_r}{L_m \cdot R_r} \right) \cdot (\omega_e - \omega_r) \cdot \vec{\lambda}_r^e \quad (3.28)$$




Figura 3.5- Correlação-cruzada de I_{sq} com λ_{rq}

A escolha do sistema de eixos dq fixo no rotor irá minimizar potenciais dependências do observador às variações dos parâmetros da MI através da eliminação do último termo da eq. 3.28. Além disso, a utilização desta equação na forma integral evitará o cálculo de derivadas de segunda ordem no cálculo da taxa de aprendizagem ótima, o que poderia levar a erros numéricos consideráveis. Assim, tem-se a seguinte expressão para a equação de mapeamento:

$$\int \vec{I}_s^r dt = \frac{\int \vec{\lambda}_r^r dt}{L_m} + \left(\frac{L_r}{L_m \cdot R_r} \right) \cdot \vec{\lambda}_r^r \quad (3.29)$$

que na forma escalar resulta em

$$\int I_{sd}^r dt = \frac{\int \lambda_{rd}^r dt}{L_m} + \left(\frac{L_r}{L_m \cdot R_r} \right) \cdot \lambda_{rd}^r \quad (3.30)$$

$$\int I_{sq}^r dt = \frac{\int \lambda_{rq}^r dt}{L_m} + \left(\frac{L_r}{L_m \cdot R_r} \right) \cdot \lambda_{rq}^r \quad (3.31)$$

Para tornar a notação matemática menos carregada, será omitido das equações daqui por diante o r sobrescrito, tendo-se em mente que todas as equações do observador de fluxo NFN estão com o referencial fixo no rotor.

Pode-se denotar as duas saídas da rede NFN por $\hat{y}_l$, os seus respectivos valores mapeados por $\hat{z}_l$ e os valores desejados por z_l^d , $l = 1, 2$ (fig. 3.6), onde:

$$\hat{y}_1 = \hat{\lambda}_{rd} \quad (3.32)$$

$$\hat{y}_2 = \hat{\lambda}_{rq} \quad (3.33)$$

$$\hat{z}_1 = \int \hat{I}_{sd} dt \quad (3.34)$$

$$\hat{z}_2 = \int \hat{I}_{sq} dt \quad (3.35)$$

$$z_1^d = \int I_{sd} dt \quad (3.36)$$

$$z_2^d = \int I_{sq} dt \quad (3.37)$$




Figura 3.6- Diagrama de blocos do observador de fluxo rotórico NFN

Assim, a função de mapeamento entre a saída da rede NFN ($\hat{y}_l$) e o valor observado ($\hat{z}_l$) a ser comparado com o valor desejado, z_l^d , é dada por:

$$\hat{z}_l = h(\hat{y}_l) = \frac{\int \hat{y}_l dt}{L_m} + \left(\frac{L_r}{L_m \cdot R_r} \right) \cdot \hat{y}_l \quad (3.38)$$

Discretizando a eq. 3.38, considerando um “hold” de ordem zero, a regra do retângulo e período de amostragem T , tem-se:

$$\hat{z}_l = K_{0l} + K_{1l} \cdot \hat{y}_l, l = 1, 2 \quad (3.39)$$

onde

$$K_{0l} = \frac{\int_0^{t-T} \hat{y}_l d\tau}{L_m} \quad (3.40)$$

$$K_{1l} = \left(\frac{L_r}{L_m \cdot R_r} + \frac{T}{L_m} \right) \quad (3.41)$$

e $\hat{y}_l$ é dado pelas eq. 3.2 e 3.3.

3.3.2.1 Equação de Atualização dos Pesos com Taxa de Aprendizado Ótima

A equação de mapeamento escolhida para o observador de fluxos de rotores NFN (eq. 3.39) é da mesma classe que a da eq. 3.8.

Embora o Teorema 1 tenha sido demonstrado para equações de mapeamento no domínio contínuo do tempo, ver-se-á que seus resultados também são válidos para equações de mapeamento no domínio discreto do tempo, como é o caso da eq. 3.39.

Desta forma, de 3.4, 3.26, 3.27, 3.32, 3.33 e 3.41 pode-se chegar a:

$$W_{ik_i 1}^{(j+1)} = -\alpha^{(j)} \cdot \left(\hat{z}_1^{(j)} - z_1^d \right) \cdot \left[\frac{1}{\left(\frac{L_r}{L_m \cdot R_r} + \frac{T}{L_m} \right)} \right] \cdot \mu_{ik_i}(x_i^{(j)}) \quad (3.42)$$

$$W_{i(k_i+1)1}^{(j+1)} = -\alpha^{(j)} \cdot \left(\hat{z}_1^{(j)} - z_1^d \right) \cdot \left[\frac{1}{\left(\frac{L_r}{L_m \cdot R_r} + \frac{T}{L_m} \right)} \right] \cdot \mu_{i(k_i+1)}(x_i^{(j)}) \quad (3.43)$$

$$W_{ik_i 2}^{(j+1)} = -\alpha^{(j)} \cdot \left(\hat{z}_2^{(j)} - z_2^d \right) \cdot \left[\frac{1}{\left(\frac{L_r}{L_m \cdot R_r} + \frac{T}{L_m} \right)} \right] \cdot \mu_{ik_i}(x_i^{(j)}) \quad (3.44)$$

$$W_{i(k_i+1)2}^{(j+1)} = -\alpha^{(j)} \cdot \left(\hat{z}_2^{(j)} - z_2^d \right) \cdot \left[\frac{1}{\left(\frac{L_r}{L_m \cdot R_r} + \frac{T}{L_m} \right)} \right] \cdot \mu_{i(k_i+1)}(x_i^{(j)}) \quad (3.45)$$

onde a taxa de aprendizado α é dada pela eq. 3.24, $z_l^{(j)}$ é obtida através das eq. 3.2, 3.3 e 3.39 e z_l^d é obtida através das eq. 3.36 e 3.37.

Portanto, o observador de fluxos de rotores NFN utilizando a equação de mapeamento 3.39 convergirá em **um passo**, se a atualização dos pesos for dada pelas eq. 3.42 a 3.45.

O observador de fluxos de rotores NFN é composto pela rede NFN descrita no item 3.3.1, um bloco de equações de mapeamento (eq. 3.39), um bloco $\alpha\beta/dq$, um bloco $dq/\alpha\beta/\vec{\lambda}_r$ e dois blocos integradores. Ele tem como entradas I_{sd} , I_{sq} e ω_r e fornece como saídas $\hat{\lambda}_r$ e $\hat{p}_r$ (fig 3.6).

3.4 Observador de Velocidade Rotórica Utilizando o Algoritmo Neo-Fuzzy-Neuron: Primeira e Segunda Propostas

Nesta seção, serão propostos dois observadores de velocidade rotórica (NFN-1 e 2) para máquinas de indução, baseado no observador de estados do item 3.2

As principais características destes observadores são:

- necessidade do valor do conjugado eletromagnético, T_e , e do vetor fluxo de rotor, $\vec{\lambda}_r$;
- grande sensibilidade às variações da indutância mútua, L_m , e à erros no vetor fluxo de rotor;
- robustez às variações da resistência rotórica, R_r , numa ampla faixa de velocidade;
- robustez às variações de carga numa ampla faixa de velocidade;
- independência da resistência estatórica, R_s ;
- rápida convergência e alta precisão;
- adaptabilidade às variações da dinâmica do sistema;
- baixo custo computacional;
- aprendizado em tempo real sem a necessidade de treinamento prévio;
- sua equação de atualização de pesos apresenta pontos singulares.

3.4.1 Definição da topologia da rede

De maneira análoga ao observador de fluxo de rotor, foi feita uma análise de correlação entre todas as variáveis do motor de indução (correntes, tensões, conjugado eletromagnético, fluxos, velocidade) e a velocidade rotórica.


As variáveis que apresentaram alguma correlação com a velocidade foram a própria velocidade e o conjugado eletromagnético. As outras variáveis da máquina de indução apresentaram correlação estatisticamente nula. Algumas destas correlações estão apresentadas nas fig.3.7 e 3.8. Assim, escolheu-se como entradas da rede, as seguintes variáveis:

- $T_e^{(n)}$;
- $T_e^{(n-1)}$.

A informação da dinâmica do sistema é passada para a rede através dos pesos, durante o treinamento *on-line*. Os pesos são atualizados pelas equações adequadas, de modo a garantirem erro nulo de observação em um passo de cálculo, como será visto mais tarde.

Assim, a topologia da rede NFN utilizada para cada observador de velocidade foi a seguinte:

1. Entradas:
 - (a) $T_e^{(n)}$;
 - (b) $T_e^{(n-1)}$.
2. Funções de pertinência: duas;
3. Saída:
 - (a) $\hat{\omega}_r^{(n)}$.

Figura 3.7- Correlação-cruzada de T_e com ω_r




Figura 3.8- Correlação-cruzada de $I_{s\alpha}$ com ω_r

3.4.2 Desenvolvimento do Observador

Para o treinamento on-line do NFN, as correntes de estator foram escolhidas como valores de referência, por estarem disponíveis. Deve-se, portanto, obter uma função de mapeamento entre a velocidade de rotor observada e o vetor de correntes de estator observado.

A partir da eq. 3.28, considerando o sistema de eixos dq do modelo da MI fixo no estator, pode-se obter a seguinte equação vetorial:

$$\vec{I}_s^s = \frac{\vec{\lambda}_r^s}{L_m} + \left(\frac{L_r}{L_m \cdot R_r} \right) \cdot \frac{d\vec{\lambda}_r^s}{dt} - j \cdot \left(\frac{L_r}{L_m \cdot R_r} \right) \cdot \omega_r \cdot \vec{\lambda}_r^s \quad (3.46)$$

que, na forma escalar, resulta em

$$I_{s\alpha} = \frac{\lambda_{r\alpha}}{L_m} + \left(\frac{L_r}{L_m \cdot R_r} \right) \cdot \frac{d\lambda_{r\alpha}}{dt} + \left(\frac{L_r}{L_m \cdot R_r} \right) \cdot \omega_r \cdot \lambda_{r\beta} \quad (3.47)$$

$$I_{s\beta} = \frac{\lambda_{r\beta}}{L_m} + \left(\frac{L_r}{L_m \cdot R_r} \right) \cdot \frac{d\lambda_{r\beta}}{dt} - \left(\frac{L_r}{L_m \cdot R_r} \right) \cdot \omega_r \cdot \lambda_{r\alpha} \quad (3.48)$$

O sistema de eixos dq foi escolhido com o referencial fixo no estator (representado pelos subscritos α e β) de modo a se obter diretamente a velocidade multiplicada pelo fluxo de rotor, em vez de escorregamento. Evita-se assim a necessidade da obtenção da frequência de alimentação para o cálculo da velocidade. Entretanto, isto torna os observadores mais sensíveis aos erros em $\lambda_{r\alpha}$ e a $\lambda_{r\beta}$, como será visto posteriormente.

A eq. 3.46 na forma integral, apesar de eliminar a derivação de $\vec{\lambda}_r$, não é da classe da eq. 3.8, e por isto não foi utilizada neste trabalho.

Para a observação da velocidade é necessária a utilização de apenas uma das duas equações. Neste caso, torna-se natural a utilização do NFN convencional, com apenas uma saída. Entretanto, pode-se utilizar as duas equações e obter duas velocidades observadas numa só rede NFN, o que nos leva ao NFN generalizado. A título de comparação, será utilizada uma rede NFN com dois observadores de velocidade.

Pode-se denotar as duas saídas da rede NFN por $\hat{y}_l$, os seus respectivos valores mapeados por $\hat{z}_l$ e os valores desejados por z_l^d , $l = 1, 2$ (fig.3.9), onde:

$$\hat{y}_1 = \hat{\omega}_{r1} \quad (3.49)$$

$$\hat{y}_2 = \hat{\omega}_{r2} \quad (3.50)$$

$$\hat{z}_1 = \hat{I}_{s\alpha} \quad (3.51)$$

$$\hat{z}_2 = \hat{I}_{s\beta} \quad (3.52)$$

$$z_1^d = I_{s\alpha} \quad (3.53)$$

$$z_2^d = I_{s\beta} \quad (3.54)$$

Assim, a função de mapeamento entre a saída da rede NFN, $\hat{y}_l$, e o valor observado ($\hat{z}_l$) a ser comparado com o valor de referência, z_l^d , é dada por

$$\hat{z}_l = K_{0l} + K_{1l} \cdot \hat{y}_l, l = 1, 2 \quad (3.55)$$




Figura 3.9- Diagrama de blocos do observador de velocidade NFN: primeira e segunda propostas

onde

$$K_{01} = \frac{\lambda_{r\alpha}}{L_m} + \left(\frac{L_r}{L_m \cdot R_r} \right) \cdot \frac{d\lambda_{r\alpha}}{dt} \quad (3.56)$$

$$K_{11} = \left(\frac{L_r}{L_m \cdot R_r} \right) \cdot \lambda_{r\beta} \quad (3.57)$$

$$K_{02} = \frac{\lambda_{r\beta}}{L_m} + \left(\frac{L_r}{L_m \cdot R_r} \right) \cdot \frac{d\lambda_{r\beta}}{dt} \quad (3.58)$$

$$K_{12} = - \left(\frac{L_r}{L_m \cdot R_r} \right) \cdot \lambda_{r\alpha} \quad (3.59)$$

e $\hat{y}_l$ é dado pelas eq. 3.2 e 3.3.

Os fluxos de rotores de eixos alfa e beta ($\lambda_{r\alpha}$ e $\lambda_{r\beta}$, respectivamente) são funções senoidais de valor médio nulo. Isto significa que eles passam por zero duas vezes em cada período, levando K_{11} e K_{12} a zero também, nestes instantes. Embora as condições estabelecidas pelo Teorema 1 não sejam válidas *nestes instantes*, ainda pode ser possível obter os observadores de velocidade rotórica utilizando as equações de mapeamento 3.55, conforme será visto em seguida.

3.4.2.1 Equação de Atualização dos Pesos com Taxa de Aprendizado Ótima

A equação de mapeamento escolhida para o observador de velocidades rotóricas NFN (eq. 3.55) é da mesma classe que a da eq. 3.8. Além disso, K_{1l} independe de $\hat{y}_l$, uma vez que entre dois passos de iteração apenas $\hat{y}_l$ varia, devido à variação dos pesos.

Desta forma, de 3.4, 3.26, 3.27, 3.49, 3.50, 3.57 e 3.59 pode-se chegar a:

$$W_{ik_i 1}^{(j+1)} = -\alpha^{(j)} \cdot \left(\hat{z}_1^{(j)} - z_1^d \right) \cdot \left(\frac{L_m \cdot R_r}{L_r} \right) \cdot \left(\frac{1}{\lambda_{r\beta}} \right) \cdot \mu_{ik_i}(x_i^{(j)}) \quad (3.60)$$

$$W_{i(k_i+1)1}^{(j+1)} = -\alpha^{(j)} \cdot \left(\hat{z}_1^{(j)} - z_1^d \right) \cdot \left(\frac{L_m \cdot R_r}{L_r} \right) \cdot \left(\frac{1}{\lambda_{r\beta}} \right) \cdot \mu_{i(k_i+1)}(x_i^{(j)}) \quad (3.61)$$

$$W_{ik_i 2}^{(j+1)} = -\alpha^{(j)} \cdot \left(\hat{z}_2^{(j)} - z_2^d \right) \cdot \left(\frac{L_m \cdot R_r}{L_r} \right) \cdot \left(\frac{1}{\lambda_{r\alpha}} \right) \cdot \mu_{ik_i}(x_i^{(j)}) \quad (3.62)$$

$$W_{i(k_i+1)2}^{(j+1)} = -\alpha^{(j)} \cdot \left(\hat{z}_2^{(j)} - z_2^d \right) \cdot \left(\frac{L_m \cdot R_r}{L_r} \right) \cdot \left(\frac{1}{\lambda_{r\alpha}} \right) \cdot \mu_{i(k_i+1)}(x_i^{(j)}) \quad (3.63)$$

onde a taxa de aprendizado α é dada pela eq. 3.24, $\hat{z}_i^{(j)}$ é obtida através das eq. 3.2, 3.3 e 3.55 e z_i^d é obtida através das eq. 3.53 e 3.54.

Para a obtenção das eq. 3.60 a 3.63, foram feitas as simplificações $\frac{\lambda_{r\alpha}}{\lambda_{r\alpha}^2} = \frac{1}{\lambda_{r\alpha}}$ e $\frac{\lambda_{r\beta}}{\lambda_{r\beta}^2} = \frac{1}{\lambda_{r\beta}}$.

Portanto, os observadores de velocidade rotórica NFN utilizando a equação de mapeamento 3.55 convergirão em **um passo**, se a atualização dos pesos for dada pelas eq. 3.60 a 3.63.

Os observadores de velocidade rotórica NFN são compostos pela rede NFN descrita no item 3.4.1, um bloco de equações de mapeamento (eq. 3.55), um bloco de diferenciação e um bloco de atraso. Eles têm como entradas I_{sd} , I_{sq} e T_e e fornecem como saídas $\hat{\omega}_{r1}$ e $\hat{\omega}_{r2}$ (fig 3.9).

Embora nas equações de mapeamento utilizadas pelos observadores de velocidade propostos (eq. 3.55) o K_{1i} não seja igual a zero, ele é uma função de funções senoidais e passa por zero duas vezes em cada período ($\lambda_{r\alpha}$ e $\lambda_{r\beta}$). Este fato pode degradar estes observadores nos pontos de singularidade (nos quais $\lambda_{r\alpha}$ e $\lambda_{r\beta}$ passam por zero) onde as condições do Teorema 1 são violadas e onde as equações de atualização dos pesos (eq. 3.60 a 3.63) atingem valores infinitos. Para evitar erros de *overflow* nestes instantes, pode-se limitar os pesos a valores adequados, ou evitar-se observar a velocidade nestes instantes, utilizando a observação do passo anterior.

Na fig. 3.10 pode-se ver o gráfico da função singular $\frac{1}{\lambda_{r\alpha}}$, onde a abscissa varia de -2π a 2π e a ordenada, embora varie de $-\infty$ a $+\infty$, foi limitada em ± 100 .




Figura 3.10- Função singular $\frac{1}{\lambda_{r\alpha}}$

3.5 Observador de Velocidade Rotórica Utilizando o Algoritmo Neo-Fuzzy-Neuron: Terceira Proposta [52]

Para contornar os problemas dos pontos singulares nas equações de atualização de pesos dos observadores propostos na seção 3.4, será proposto um terceiro observador de velocidade rotórica (NFN-3) para máquinas de indução, também baseado no observador de estados do item 3.2.

As principais características deste observador são:

- necessidade do valor do conjugado eletromagnético (T_e), da tensão de estator de eixo alfa ($V_{s\alpha}$), da tensão de estator de eixo beta ($V_{s\beta}$), da corrente de estator de eixo alfa ($I_{s\alpha}$), da corrente de estator de eixo beta ($I_{s\beta}$) e da posição do vetor fluxo de rotor;
- robustez às variações da resistência de rotor e de estator, R_r e R_s respectivamente, e às variações de carga numa ampla faixa de velocidade;
- sensibilidade às variações da indutância mútua, L_m (e conseqüentemente das indutâncias próprias de rotor e de estator, L_r e L_s , respectivamente);
- rápida convergência e alta precisão;

- adaptabilidade às variações da dinâmica do sistema;
- baixo custo computacional;
- aprendizado em tempo real sem a necessidade de treinamento prévio;
- sua equação de atualização de pesos não apresenta pontos singulares.

3.5.1 Definição da topologia da rede

De maneira análoga aos observadores de velocidade de rotor da seção 3.4, foram escolhidas como entradas da rede as seguintes variáveis:

- $T_e^{(n)}$;
- $T_e^{(n-1)}$.

A topologia da rede NFN utilizada para este observador de velocidade foi a seguinte:

1. Entradas:
 - (a) $T_e^{(n)}$;
 - (b) $T_e^{(n-1)}$;
 - (c) $T_e^{(n-2)}$;
 - (d) $T_e^{(n-3)}$.
2. Funções de pertinência: duas;
3. Saídas:
 - (a) $\hat{\omega}_{sr}^{(n)}$;
 - (b) $\hat{\omega}_s^{(n)}$.

3.5.2 Desenvolvimento do Observador

Para evitar que as variáveis do observador sejam senoidais (evitando assim uma equação de atualização de pesos com singularidades), em vez de referencial dq fixo no estator, o referencial será considerado fixo em um dos campos girantes. Isto resultará em variáveis

não-senoidais e até mesmo contínuas em regime permanente. Além disso, uma adicional simplificação será obtida considerando-se o eixo d alinhado com o vetor fluxo de rotor ($\vec{\lambda}_r$). Para simplificar a notação, as equações serão desenvolvidas sem o sobrescrito referente ao referencial fixo no $\vec{\lambda}_r$, tendo-se em mente que todas as equações do observador de velocidade NFN-3 estão com o referencial fixo no $\vec{\lambda}_r$.

A partir da eq. 3.28, considerando o sistema de eixos dq do modelo da MI fixo no vetor fluxo de rotor, pode-se obter a seguinte equação vetorial:

$$\vec{I}_s = \frac{\vec{\lambda}_r}{L_m} + \left(\frac{L_r}{L_m \cdot R_r} \right) \cdot \frac{d\vec{\lambda}_r}{dt} + j \cdot \left(\frac{L_r}{L_m \cdot R_r} \right) \cdot \omega_{sr} \cdot \vec{\lambda}_r \quad (3.64)$$

cuja componente de eixo q é dada por:

$$I_{sq} = \left(\frac{L_r}{L_m \cdot R_r} \right) \cdot \lambda_r \cdot \omega_{sr} \quad (3.65)$$

A eq. 3.65 é bastante simples, independente de derivadas ou integrais, dependente de poucos parâmetros da MI e portanto, potencialmente mais robusta às variações paramétricas. Entretanto ao utilizá-la como equação de mapeamento, é possível a obtenção apenas da velocidade angular de escorregamento ω_{sr} .

É necessário, então, a obtenção da velocidade angular síncrona da máquina, ω_s , para possibilitar o cálculo da velocidade angular do rotor. Isto será feito com uma outra equação de mapeamento, que será obtida a seguir.

A partir das equações de tensão de estator e de enlace de fluxo de rotor e de estator da máquina de indução (apêndice B), também com o referencial fixo no vetor fluxo de rotor, pode-se obter a seguinte equação:

$$\vec{V}_s = R_s \cdot \vec{I}_s + \sigma \cdot L_s \cdot \frac{d\vec{I}_s}{dt} + \frac{L_m}{L_r} \cdot \frac{d\vec{\lambda}_r}{dt} + j \cdot \left(\sigma \cdot L_s \cdot \vec{I}_s + \frac{L_m}{L_r} \cdot \vec{\lambda}_r \right) \cdot \omega_s \quad (3.66)$$

cuja componente de eixo q é dada por:

$$V_{sq} = R_s \cdot I_{sq} + \sigma \cdot L_s \cdot \frac{dI_{sq}}{dt} + \left(\sigma \cdot L_s \cdot I_{sd} + \frac{L_m}{L_r} \cdot \lambda_r \right) \cdot \omega_s \quad (3.67)$$

Uma simplificação adicional das eq. 3.67 pode ser obtida, considerando-se o fluxo de rotor já estabelecido.

A componente de eixo d da eq. 3.65 e 3.64 é dada por:

$$I_{sd} = \frac{\lambda_r}{L_m} + \left(\frac{L_r}{L_m \cdot R_r} \right) \cdot \frac{d\lambda_r}{dt} \quad (3.68)$$

Após o estabelecimento do fluxo, tem-se:

$$I_{sd} = \frac{\lambda_r}{L_m} \quad (3.69)$$

De 3.65, 3.67 e 3.69:

$$I_{sq} = \tau_r \cdot I_{sd} \cdot \omega_{sr} \quad (3.70)$$

$$V_{sq} = R_s \cdot I_{sq} + \sigma \cdot L_s \cdot \frac{dI_{sq}}{dt} + L_s \cdot I_{sd} \cdot \omega_s \quad (3.71)$$

onde:

$$\tau_r = \frac{L_r}{R_r} \quad (3.72)$$

Assim, para este observador de velocidade de rotor NFN, serão utilizadas as eq. 3.70 e 3.71.

De maneira análoga ao desenvolvimento dos observadores na seção 3.4, cada

um dos observadores (de ω_{sr} e de ω_s) será tratado como dois observadores independentes numa mesma rede NFN.

Pode-se denotar as duas saídas da rede NFN generalizado por $\hat{y}_l$, os seus respectivos valores mapeados por $\hat{z}_l$ e os valores desejados por z_l^d , $l = 1, 2$ (fig.3.11), onde:

$$\hat{y}_1 = \hat{\omega}_{sr} \quad (3.73)$$

$$\hat{y}_2 = \hat{\omega}_s \quad (3.74)$$

$$\hat{z}_1 = \hat{I}_{sq} \quad (3.75)$$

$$\hat{z}_2 = \hat{V}_{sq} \quad (3.76)$$

$$z_1^d = I_{sq} \quad (3.77)$$

$$z_2^d = V_{sq} \quad (3.78)$$

Portanto, a função de mapeamento entre a saída do NFN, $\hat{y}_l$, e o valor observado ($\hat{z}_l$) a ser comparado com o valor de referência, z_l^d , é dada por

$$\hat{z}_l = K_{0l} + K_{1l} \cdot \hat{y}_l, l = 1, 2 \quad (3.79)$$

onde

$$K_{01} = 0 \quad (3.80)$$

$$K_{11} = \tau_r \cdot I_{sd} \quad (3.81)$$

$$K_{02} = R_s \cdot I_{sq} + \sigma \cdot L_s \cdot \frac{dI_{sq}}{dt} \quad (3.82)$$

$$K_{12} = L_s \cdot I_{sd} \quad (3.83)$$

e $\hat{y}_l$ é dado pelas eq. 3.2 e 3.3.




Figura 3.11- Diagrama de blocos do observador de velocidade NFN: terceira proposta

3.5.2.1 Equação de Atualização dos Pesos com Taxa de Aprendizado Ótima

A equação de mapeamento escolhida para o observador de velocidade de rotor NFN (eq. 3.79) é da mesma classe que a da eq. 3.8. Além disso, K_{1l} independe de $\hat{y}_l$, uma vez que entre dois passos de iteração apenas $\hat{y}_l$ varia, devido às variação dos pesos.

Desta forma, de 3.4, 3.26, 3.27, 3.73, 3.74, 3.81 e 3.83 pode-se chegar a:

$$W_{ik_i 1}^{(j+1)} = -\alpha^{(j)} \cdot (\hat{z}_1^{(j)} - z_1^d) \cdot \left(\frac{1}{\tau_r \cdot I_{sd}} \right) \cdot \mu_{ik_i}(x_i^{(j)}) \quad (3.84)$$

$$W_{i(k_i+1)1}^{(j+1)} = -\alpha^{(j)} \cdot (\hat{z}_1^{(j)} - z_1^d) \cdot \left(\frac{1}{\tau_r \cdot I_{sd}} \right) \cdot \mu_{i(k_i+1)}(x_i^{(j)}) \quad (3.85)$$

$$W_{ik_i 2}^{(j+1)} = -\alpha^{(j)} \cdot (\hat{z}_2^{(j)} - z_2^d) \cdot \left(\frac{1}{L_s \cdot I_{sd}} \right) \cdot \mu_{ik_i}(x_i^{(j)}) \quad (3.86)$$

$$W_{i(k_i+1)2}^{(j+1)} = -\alpha^{(j)} \cdot (\hat{z}_2^{(j)} - z_2^d) \cdot \left(\frac{1}{L_s \cdot I_{sd}} \right) \cdot \mu_{i(k_i+1)}(x_i^{(j)}) \quad (3.87)$$

onde a taxa de aprendizado α é dada pela eq. 3.24, $\hat{z}_l^{(j)}$ é obtida através das eq. 3.2, 3.3 e 3.79 e z_l^d é obtida através das eq. 3.77 e 3.78.

Portanto, o observador de velocidade de rotor NFN utilizando a equação de mapeamento 3.79 convergirá em **um passo**, se a atualização dos pesos for dada pelas eq. 3.84 a 3.87.

Nota-se nas eq. 3.84 a 3.87 a presença de I_{sd} no denominador. No controle vetorial por orientação pelo vetor fluxo de rotor (DUFOR), que é o utilizado neste trabalho, a I_{sd} é nula apenas *no primeiro passo* n . Uma potencial fonte de erros neste observador de velocidade é o valor nulo de I_{sd} (causando indeterminação nas eq. 3.84 a 3.87) e a sua variação (causando algum erro na eq. 3.69), que ocorrem na partida. Entretanto, isto foi facilmente contornado pela desabilitação do observador da velocidade alguns milissegundo iniciais do acionamento, quando a velocidade é conhecida (nula).

O observador de velocidade de rotor NFN é composto pela rede NFN descrita no

item 3.5.1, um bloco de equações de mapeamento (eq. 3.79), um bloco $\alpha\beta/dq$, três blocos de atraso, um bloco diferenciador e um bloco de filtro passa-baixas. Ele tem como entradas $I_{s\alpha}$, $I_{s\beta}$, $V_{s\alpha}$, $V_{s\beta}$, λ_r , e T_e e fornece como saídas $\hat{\omega}_r$ (fig 3.11).

O filtro passa-baixas é necessário para reduzir os “ruídos” injetados pelo cálculo numérico da derivada de I_{sq} (eq. 3.71) A velocidade observada, $\hat{\omega}_r$, é obtida de:

$$\hat{\omega}_r^{(j)} = \hat{\omega}_s^{(j)} - \hat{\omega}_{sr}^{(j)} \quad (3.88)$$

3.6 Conclusões

Neste capítulo foi mostrada a aplicação da rede NFN na observação de estados de sistemas dinâmicos. Foi visto que a utilização da rede NFN com treinamento on-line exige a utilização de uma equação de mapeamento entre os estados observados, $\hat{y}_l$, e os estados observados ($\hat{z}_l$) a serem comparados com os estados medidos, z_l^d .

Foi demonstrado no Teorema 1 que permite a determinação adequada de uma equação de mapeamento, dentre as candidatas. Em seguida, foram desenvolvidas expressões válidas para equações de mapeamento com determinadas características. Estas expressões podem ser aplicadas no problema de observação de qualquer sistema dinâmico em tempo real que possibilite a obtenção deste tipo de equação de mapeamento.

Objetivando uma aplicação prática do Observador de Estados NFN, foi demonstrada uma expressão para atualização dos pesos com taxa de aprendizado ótima (o que permite a convergência do observador em apenas **um passo de cálculo**) para uma determinada classe de equações de mapeamento. Este resultado torna o observador potencialmente rápido e adequado para aplicações em tempo real, além de não precisar da etapa de treinamento off-line. Baseado neste resultado, foram desenvolvidas quatro propostas de observadores de estado: um observador de fluxos de rotores e três observadores de velocidade de rotor.

Os observadores serão aplicados em um sistema de acionamento de máquinas de indução (cujo tempo de resposta deve ser rápido o suficiente para o satisfatório desempenho do acionamento), para avaliação da proposta (cap. 4).

Convém salientar que um erro na equação de mapeamento, implicará em um erro no estado observado, que poderá ser desprezível ou não. Portanto, para um projeto satisfatório do observador de estados NFN, além da adequada escolha da equação de mapeamento (com o auxílio do Teorema 1) é necessário uma análise da influência do erro da equação de mapeamento na observação dos estados.

A utilização de uma taxa de aprendizado ótima garante a convergência do observador em apenas **um passo de cálculo**. Embora tenha sido obtida uma expressão para taxa de aprendizado ótima para uma classe particular de equações de mapeamento (eq. 3.8), pode ser possível obter uma expressão equivalente para outros tipos de equação de mapeamento. Caso a obtenção de uma expressão para a taxa de aprendizado ótima seja difícil ou até mesmo impossível, no projeto de observadores NFN para algum sistema em particular, pode ser possível obter bons resultados em processos de observação em tempo real utilizando apenas a eq. 3.7 e uma taxa de aprendizado fixa adequada, obtida heurísticamente através de simulações prévias.

Capítulo 4

Validação das Propostas e Análise dos Resultados

4.1 Introdução

A fim de validar os observadores de fluxo e velocidade NFN propostos, os mesmos foram utilizados na obtenção de resultados de simulação e experimentais com a estratégia de controle vetorial direto por orientação pelo fluxo de rotor *sensorless* (DUFOR, [7], [16], [93] e [96]), cujo esquema está na fig. 4.1. O observador de fluxos de rotor NFN recebe as informações de velocidade observada e correntes de estators do motor, fornecendo o módulo e a posição do vetor fluxo de rotor que serão utilizados na malha de controle e no observador de velocidade NFN. O observador de velocidade (terceira proposta, seção 3.5) recebe as informações de correntes e tensões de estators de eixo α e β , de conjugado eletromagnético e a posição do vetor fluxo de rotor, fornecendo a velocidade. O conjugado eletromagnético é calculado a partir do fluxo de rotor e da corrente de estator de eixo d .

O vetor fluxo é usado para orientar o eixo d , proporcionando controle independente da malha de fluxo e conjugado, através das malhas de controle de corrente de eixo d e q , respectivamente. Estas malhas de controle utilizam cinco controladores PI para o controle de: velocidade, conjugado eletromagnético, corrente de eixo d , amplitude do fluxo de rotor e corrente de eixo q . As saídas dos controladores de corrente de eixo d e q , após a adição dos termos de desacoplamento (V_{dx} e V_{dy} , [96]), fornecem as tensões de referência usadas pelo PWM (V_{sa}^* , V_{sb}^* e V_{sc}^*) para sintetizar as tensões que irão alimentar a máquina de indução (fig. 4.1).

Os controladores do tipo PI são fáceis de implementar e de ajustar. Entretanto,

eles são especialmente adequados para controles de sistemas lineares, o que não é o caso da máquina de indução. Portanto, é necessário reajustá-los para cada faixa de operação e para cada alteração nos pólos do sistema, e os ajustes podem ser demorados. A inclusão de observadores na malha de controle altera os pólos do sistema, alterando a resposta dos controladores. No caso do sistema utilizado neste trabalho, foram necessários novos ajustes dos controladores PI para cada faixa de velocidade (ajustes para velocidades baixas, e para velocidades médias e altas), para cada tipo de ensaio (ajustes para partida e reversão de velocidade e para aplicação e retirada de carga) ou após a inclusão dos observadores de fluxo e de velocidade na malha de controle. Embora fosse mais adequado uma nova análise e ajuste dos controladores, a mesma encontrava-se fora do escopo deste trabalho, ficando como sugestão para trabalhos futuros.

Entretanto, pode-se avaliar o efeito da introdução dos observadores na malha de controle, através da análise da *rigidez dinâmica* do sistema, como será visto na seção 4.7.4.




Figura 4.1- Esquema de controle DUFOR *sensorless*

Os observadores de velocidade NFN da primeira e segunda propostas (seção 3.4) foram utilizados apenas no controle de velocidade. A utilização da velocidade fornecida por estes observadores no observador de fluxos de rotores NFN (ou no de Gopinath) e do próprio fluxo observado nos referidos observadores de velocidade levava o sistema à instabilidade, não sendo possível obter um acionamento *sensorless* experimental com eles. Entretanto, eles não foram descartados devido ao seu ótimo desempenho na malha de controle de velocidade e por acreditar-se que a sua utilização em um acionamento *sensorless* experimental ainda poderá ser bem-sucedida, ficando esta tarefa como sugestão para trabalhos futuros.

Para os resultados de simulação, foi utilizado um programa em linguagem C[®] consistindo no modelo da MI e no controle DUFOR com o observador de fluxo NFN e os observadores de velocidade NFN. Foram feitos vários testes para avaliar o desempenho dos observadores. Estes testes estão descritos na seção 4.3.

Para a obtenção dos resultados práticos, foi utilizado o sistema experimental para acionamentos elétricos que será descrito na próxima seção. Também foram feitos os testes descritos na seção 4.3.

Os valores de erro de observação e de controle (assim como todas as curvas apresentadas neste trabalho) foram obtidos a partir dos pontos dos arquivos de simulação e experimentais gerados pelo programa em linguagem C[®], no aplicativo gráfico DSN.

Neste capítulo, será apresentado o sistema experimental, utilizado para a validação prática dos observadores propostos, bem como os testes e critérios de avaliação dos mesmos. Serão abordados os índices de desempenho utilizados para avaliar o sistema de acionamentos elétricos. Será feita uma análise dos observadores propostos, a partir dos resultados de simulação e experimentais obtidos, com o auxílio dos testes e critérios de avaliação.

4.2 Sistema Experimental para Acionamentos Elétricos

A finalidade da pesquisa na área de acionamentos elétricos é a obtenção de novas técnicas (ou o melhoramento das existentes) utilizadas nos acionamentos, em busca da obtenção de melhores índices de desempenho ([8]). Assim, deve-se utilizar experimentos práticos que validem as técnicas em estudo. Para tanto faz-se necessário o uso de um sistema experimental.

O sistema experimental de acionamentos elétricos utilizado neste trabalho é composto por (fig. 4.2):

- Uma máquina de indução de 2 cv (apêndice A);
- Uma máquina CC de 2 cv (apêndice A);
- Um microcomputador PC Pentium com placa de aquisição de dados;
- Um programa de controle;
- Um sub-sistema experimental.

A máquina de indução é o sistema que se deseja controlar, configurada como motor. Acoplado ao seu eixo, existe um tacogerador (responsável pela medição de velocidade) e uma máquina CC (responsável pela aplicação de carga ao motor de indução). A máquina CC está configurada como gerador, com a alimentação do enrolamento de campo fixa. Ao alimentar um banco de resistores, o gerador CC funciona como uma carga mecânica para o motor de indução. O microcomputador está equipado com uma placa de aquisição de dados (responsável por passar os valores medidos ao micro) e com uma placa de PWM (responsável pelo comando das chaves do inversor). O programa de controle e o sub-sistema experimental serão vistos com mais detalhes nas próximas seções.

4.2.1 Programa de Controle

O programa de controle foi feito em linguagem C[®] [96], operando em tempo real, e consiste em cinco etapas:




Figura 4.2- Diagrama de blocos do sistema experimental para acionamentos elétricos utilizado

- Inicialização das interrupções do PC, dos contadores das interfaces PWM e das variáveis de controle do sistema;
- Aquisição dos sinais, pela placa de aquisição de dados;
- Processamento dos sinais em tempo real, a fim de gerar os sinais de comando a partir dos valores de tensão, corrente e velocidade da MI, adquiridos na etapa anterior;
- Atuação no circuito de potência, através dos sinais de comando enviados para a placa de PWM;
- Armazenamento dos dados após a saída do programa, em arquivos que são gravados no *Winchester* do micro, a fim de permitir a análise gráfica das variáveis.

O programa de controle original foi alterado de modo a incluir os observadores de fluxos e de velocidade NFN.

4.2.2 Sub-Sistema Experimental

O sub-sistema experimental consiste em uma placa de condicionamento de sinais (montada a partir do projeto de Parma [77]), em um conversor estático CA/CC/CA e em um *chopper* de frenagem. Além disso, foi montada uma placa para a medição (digital) [78] da tensão PWM aplicada ao motor, para ser utilizada no controle. Assim, pode-se utilizar as tensões de estators de referência, a tensão “medida” pela placa de medição digital de tensão ou a própria tensão PWM filtrada, no programa de controle.

O conversor estático é composto por um retificador a diodos e ponte inversora trifásicos. A rede trifásica alimenta a ponte retificadora a diodos, cuja saída está ligada ao barramento CC. Em paralelo com o barramento, existem dois capacitores em série entre si (com um resistor equalizador de tensão em paralelo com cada um deles), para filtrar a tensão do barramento (fig. 4.3). O barramento alimenta a ponte inversora trifásica a IGBTs, que é controlada pela placa de PWM localizada no micro.

Em paralelo com o barramento CC, existe um “chopper” de frenagem, composto

por um IGBT e um resistor. Durante a frenagem do motor, a energia cinética da MI é convertida em um fluxo de potência elétrica que segue na direção do barramento, o que faz com que sua tensão aumente. O “chopper” é então acionado para descarregar este fluxo de potência adicional através do resistor, diminuindo a tensão do barramento até um valor seguro. Os IGBTs são controlados através de *drivers* da Semikron (pois possuem grande confiabilidade de operação e proporcionam excelente proteção aos IGBTs).

Para a energização da parte de potência do inversor, comanda-se uma resistência que fica em série com os capacitores do barramento CC (não representado na fig. 4.3), de forma a limitar a corrente de pico nos capacitores. Quando a tensão do barramento atinge um certo valor, a resistência é curto-circuitada, permitindo o carregamento rápido e completo dos capacitores, elevando assim a tensão do barramento até o seu valor nominal. A saída do inversor está ligada à máquina de indução.

Para controlar a máquina, o programa de controle é carregado com os valores de tensão e corrente que a alimentam, e a sua velocidade. Para isto, são feitas as medições de duas correntes e das tensões (as três no caso da medição digital ou duas, no caso de filtragem). A velocidade é obtida do observador de velocidade NFN-3 (seção 3.5) ou por medição. A medição de velocidade é feita através de um tacogerador, solidário ao eixo da MI, que gera um sinal de tensão proporcional à velocidade da MI. A medição de corrente é feita através de sensores de efeito Hall, que fornecem sinais de corrente proporcionais às correntes que passam através deles. Estes sinais de corrente são convertidos em sinais de tensão colocando-se um resistor na saída dos sensores de efeito Hall.

Estes sinais de tensão vão para a placa de condicionamento de sinais [77], que filtra e ajusta os sinais (de modo a variarem dentro da faixa admitida pela placa de aquisição de dados) e os fornece à placa de aquisição de dados.

4.3 Testes e Critérios de Avaliação dos Observadores de Fluxo e de Velocidade da Máquina de Indução

Os testes de avaliação consistem em submeter a máquina de indução a situações que




Figura 4.3- Conversor CA/CC/CA - Chopper

explorem ao máximo a sua dinâmica, durante um acionamento elétrico, a fim de verificar as limitações do acionamento. Alguns exemplos de testes de avaliação são o *teste de Robustez a Distúrbios*, o *teste de Partida e Reversão de Velocidade*, o *teste de Operação à Velocidade e Frequência Nulas* e o *teste de Aplicação de Onda Quadrada Simétrica de Conjugado de Referência*.

Os critérios de avaliação constituem uma ferramenta complementar dos testes (de avaliação), no sentido de fornecer valores ou faixa de valores desejáveis de grandezas do acionamento para uma determinada aplicação. Estes valores servem como referência, diante das respostas do MI nos testes de avaliação aplicados. Alguns critérios utilizados são a *Rapidez*, *Precisão* e *Robustez de Resposta* ([8], [93]), as *Funções de Erro de Observação e de Controle*, e o *Custo Computacional*.

A seguir são mostrados os testes e critérios de avaliação utilizados para análise dos resultados de simulação e práticos obtidos.

4.3.1 Teste de Partida e Reversão de Velocidade (PRV)

Este teste consiste na aplicação de um degrau de referência de velocidade, estabelecimento do valor de regime permanente, e sua inversão. Uma característica importante deste teste é a capacidade de excitar as dinâmicas e não-linearidades mais importantes do sistema.

A fim de verificar o desempenho do acionamento em uma ampla faixa de velocidade, este teste pode ser feito em velocidades baixas (aqui assumidas como aquelas abaixo de 2% da nominal), médias (aqui assumidas como aquelas entre 2% e 80% da nominal), normais (aqui assumidas como aquelas entre 80% e 100% da nominal) ou altas (aquelas acima da nominal, ou na *região de enfraquecimento de campo*).

4.3.2 Teste de Robustez a Distúrbios

Neste texto, os distúrbios são caracterizados como qualquer perturbação que ocorre no

sistema. Assim, as variações paramétricas não consideradas na modelagem da MI e a aplicação e retirada de cargas são consideradas como distúrbios.

Este teste consiste em acionar a MI e, após o estabelecimento do regime permanente:

- *variar os parâmetros da MI utilizados pelo programa de controle*: normalmente, os parâmetros da MI variam lentamente, de acordo com o tempo de funcionamento da máquina (R_r e R_s), com o seu ponto de operação (L_m , L_s e L_r) ou devido a questões de imponderabilidade (B e J). A variação destas grandezas em degrau é algo que não ocorre naturalmente (a não ser durante alguma falha do sistema). Assim, utiliza-se este tipo de variação como sendo o pior caso possível;
- *aplicação e retirada de carga (ARC)*.

4.3.3 Teste de Operação à Velocidade e Frequência Nulas

Este teste consiste no acionamento da MI à velocidade nula e à frequência de alimentação nula. Ele permite avaliar o desempenho dos observadores de fluxo e de velocidade nas faixas de velocidade em que seu funcionamento é mais crítico (baixas velocidades [87], [93] e [101] e velocidade nula [87]).

4.3.4 Teste de Aplicação de Onda Quadrada Simétrica de Conjugado de Referência [32]

Este teste consiste na desabilitação da malha de controle de velocidade e aplicação de uma onda quadrada simétrica de conjugado eletromagnético de referência, com a máquina operando em vazio.

Como a carga predominante é a inércia do rotor, o melhor indicativo do desempenho do sistema é a velocidade do rotor. A aplicação de uma onda quadrada simétrica de conjugado como referência permite a avaliação da precisão do fluxo observado

e da sintonia do controle vetorial, utilizando-se a informação da velocidade medida.

Considerando o sistema de eixos dq do modelo da MI (apêndice B) com o eixo d orientado segundo o vetor fluxo de rotor ($\lambda_{rd} = \lambda_r$ e $\lambda_{rq} = 0$), a partir das equações de conjugado eletromagnético (sem conjugado de carga e desprezando o conjugado referente ao atrito) obtém-se a seguinte equação:

$$T_e = \left(\frac{3}{2}\right) \cdot \left(\frac{P}{2}\right) \cdot \left(\frac{L_m}{L_r}\right) \cdot \lambda_r \cdot I_{sq} = \left(\frac{2}{P}\right) \cdot J \cdot \frac{d\omega_r}{dt} \quad (4.1)$$

o que leva a

$$\hat{T}_e = K \cdot \hat{\lambda}_r \cdot I_{sq} = J \cdot \frac{d\omega_r}{dt} \quad (4.2)$$

Nos instantes em que o conjugado real da máquina se mantém constante, a relação 4.2 mostra que a velocidade deve variar a uma taxa constante. Assim a forma de onda esperada de velocidade no tempo é uma onda triangular. Se isto ocorrer, significa que o conjugado controlado, obtido a partir do fluxo observado e da corrente de estator medida, corresponde ao conjugado real da máquina. Portanto, o fluxo observado representa o fluxo real da máquina, e o controle vetorial está bem sintonizado. Além disso, a curva T_e versus ω_r deve ter a forma de um retângulo.

4.3.5 Funções de Erro de Observação e Erro de Controle

Para auxiliar na análise dos observadores propostos, pode-se definir as funções de erro de observação absoluto (ou simplesmente funções de erro de observação) e as funções de erro de controle absoluto (ou simplesmente funções de erro de controle).

Para o erro de observação do módulo do vetor fluxo de rotor, tem-se:

$$e_{o\lambda_r} \triangleq \hat{\lambda}_r - \lambda_r \quad (4.3)$$

$$e_{o\lambda_r} \% \triangleq \frac{\hat{\lambda}_r - \lambda_r}{\lambda_r^*} \quad (4.4)$$

Para o erro de controle do módulo do vetor fluxo de rotor, tem-se:

$$e_{c\lambda_r} \triangleq \lambda_r^* - \hat{\lambda}_r \quad (4.5)$$

$$e_{c\lambda_r} \% \triangleq \frac{\lambda_r^* - \hat{\lambda}_r}{\lambda_r^*} \quad (4.6)$$

Para o erro de observação da velocidade de rotor, tem-se:

$$e_{o\omega_r} \triangleq \hat{\omega}_r - \omega_r \quad (4.7)$$

$$e_{o\omega_r} \% \triangleq \frac{\hat{\omega}_r - \omega_r}{\omega_r^*} \quad (4.8)$$

Para o erro de controle da velocidade de rotor, tem-se:

$$e_{c\omega_r} \triangleq \omega_r^* - \omega_r \quad (4.9)$$

$$e_{c\omega_r} \% \triangleq \frac{\omega_r^* - \omega_r}{\omega_r^*} \quad (4.10)$$

4.3.6 Custo Computacional

A avaliação do custo computacional consiste na contabilização das principais operações matemáticas envolvidas no algoritmo. Esta avaliação é muito importante pois, dependendo do tempo que se tem para adquirir as variáveis da máquina, processar os dados, e controlá-la, o custo computacional do observador pode inviabilizar o controle. Além disso, quanto menos tempo se gastar no observador propriamente dito, maior poderá ser o tempo computacional investido no controle.

4.4 Resultados de Simulação e Discussão de Resultados do Observador de Fluxos NFN

A fim de avaliar apenas o observador de fluxos NFN, os ensaios feitos nesta seção utilizaram a velocidade fornecida pelo tacogerador. Assim, o acionamento feito aqui não foi *sensorless*.

4.4.1 Teste de Partida e Reversão de Velocidade

4.4.1.1 Acionamento em Baixas Velocidades

Para verificar o funcionamento do observador em baixas velocidades, fez-se uma partida e reversão de velocidade a 5 rad/s, equivalente a 1,4% da nominal.

Na fig. 4.4, pode-se verificar o fluxo observado. O máximo erro de observação NFN foi $2,6 \times 10^{-3}$ ou 0,52% (fig. 4.5).

Na fig. 4.6, vemos a corrente de estator de eixo d , o conjugado eletromagnético observado e a velocidade do modelo.

4.4.1.2 Acionamento em Médias Velocidades

Este teste foi feito com as velocidades de referência de 150 rad/s e -150 rad/s (em torno de 40% da nominal). A fig. 4.7 mostra o bom desempenho dinâmico do acionamento da MI com controle DUFOR. A corrente de estator de eixo d (I_{sd}), responsável pelo fluxo de rotor, inicialmente atinge o valor máximo, a fim de estabelecer o fluxo o mais rapidamente possível. Após o estabelecimento do fluxo, permite-se que o conjugado eletromagnético (T_e) comece a crescer (a fim de elevar a velocidade do motor- ω_r - até o valor de referência - ω_r^*). O conjugado observado $\hat{T}_e$ é obtido a partir do fluxo de rotor observado ($\hat{\lambda}_r$) e pela corrente de estator de eixo q , I_{sq} (eq. 4.2). O tempo de resposta no controle da velocidade foi de aproximadamente 200 ms na partida, com o T_e saturado em 5 N.m. Utilizando-




Figura 4.4- Resultados de simulação: teste de PRV em baixas velocidades ($\hat{\lambda}_r$ NFN)




Figura 4.5- Resultados de simulação: teste de PRV em baixas velocidades ($\hat{\lambda}_r$ NFN)




Figura 4.6- Resultados de simulação: teste de PRV em baixas velocidades ($\hat{\lambda}_r$ NFN)

se o T_e nominal (aproximadamente igual a 8,2 N.m), o tempo de resposta cairá para aproximadamente 120 ms. Neste ponto, é conveniente salientar que a quase justaposição das curvas de T_e^* e $\hat{T}_e$, juntamente com o controle desejado de velocidade, só é possível graças a uma observação de fluxo eficiente e a uma malha de controle bem sintonizada.




Figura 4.7- Resultados de simulação: teste de PRV em médias velocidades ($\hat{\lambda}_r$, NFN)

O plano de fase $\hat{T}_e$ versus ω_r (fig. 4.8) representa bem este teste: na partida, com velocidade inicialmente nula, o conjugado eletromagnético cresce até o valor máximo (5 N.m, em torno de 62% do nominal), levando ao aumento da velocidade até o valor de referência (150 rad/s), quando então o conjugado vai para quase zero (a fim de suprir apenas as perdas por atrito e ventilação). Após o comando de reversão de velocidade, o conjugado cresce até o valor máximo negativo (-5 N.m) levando à diminuição da velocidade, parada do motor e rotação em sentido contrário. Quando a velocidade atinge o valor de referência negativo (-150 rad/s), o conjugado vai para quase zero, novamente.

Na fig. 4.9, pode-se ver os fluxos de rotor de eixo α e β (Wb) observados ($\hat{\lambda}_{r\alpha}$ e $\hat{\lambda}_{r\beta}$) e a amplitude do fluxo de rotor real (λ_r) e observado ($\hat{\lambda}_r$). Apesar dos fluxos terem sido observados num sistema de eixos fixos no rotor, optou-se por mostrá-los num sistema de eixos fixos no estator, por ser este sistema “mais próximo” da realidade física do sistema.




Figura 4.8- Resultados de simulação: teste de PRV em médias velocidades ($\hat{\lambda}_r$ NFN)

Nota-se que as curvas das amplitudes do fluxo real e observado estão justapostas (fig. 4.9 c). Na fig. 4.10, pode-se melhor visualizar o erro de observação NFN, cujo valor máximo é $6,9 \times 10^{-3}$ ou 1,38%.

Estes valores de erro do observador NFN foram maiores do que os observados no teste de partida e reversão de velocidade a 5 rad/s, porque a integração torna-se numericamente mais precisa a baixas frequências.

Vale ressaltar que o observador NFN foi projetado para convergir (erro nulo) em um passo. Entretanto, a taxa de aprendizado ótima garante erro nulo entre os valores medidos (integrais das correntes de estator medidas) e os valores observados (integrais de correntes de estator observadas) em apenas um passo. A fig. 4.11 mostra que este erro atingiu um máximo da ordem de 10^{-7} , o que é *praticamente zero*. O erro entre as integrais das correntes de estator medidas e as observadas ficou nesta ordem de grandeza em todas as simulações e acionamentos práticos realizados.

Como o erro entre as integrais de correntes de estator observadas e as medidas é quase nulo, era de se esperar que o erro de observação de fluxo também fosse quase




Figura 4.9- Resultados de simulação: teste de PRV em médias velocidades ($\hat{\lambda}_r$, NFN)




Figura 4.10- Resultados de simulação: teste de PRV em médias velocidades ($\hat{\lambda}_r$, NFN)

nulo. Entretanto, o erro de observação depende da equação de mapeamento, e por isto está potencialmente sujeito às variações de L_m , L_r e R_r , bem como a erros numéricos de integração (eq. 3.38). Assim, como nesta simulação os parâmetros da MI foram considerados constantes, o erro observado deveu-se à erros numéricos de integração. Nota-se que este tipo de erro não afeta o desempenho do observador. Os erros devido às variações paramétricas serão analisados na seção 4.4.2.




Figura 4.11- Resultados de simulação: teste de PRV em médias velocidades ($\hat{\lambda}_r$ NFN)

4.4.1.3 Acionamento em Altas Velocidades

Para verificar o funcionamento do observador em altas velocidades, fez-se uma partida e reversão de velocidade à 500 rad/s (dentro da faixa de velocidades altas), equivalente a 139% da nominal. Nestes testes não foi modelada a saturação da MI, por não fazer parte do escopo deste trabalho; foi modelado apenas o enfraquecimento de campo.

Na fig. 4.12, pode-se ver o fluxo de rotor observado pelo NFN. A redução na amplitude do fluxo ocorre quando a velocidade ultrapassa os limites da velocidade nominal (em torno de 360 rad/s). O máximo erro de observação NFN foi $13,5 \times 10^{-3}$ ou 2,7% (fig. 4.13).




Figura 4.12- Resultados de simulação: teste de PRV em altas velocidades ($\hat{\lambda}_r$ NFN)




Figura 4.13- Resultados de simulação: teste de PRV em altas velocidades ($\hat{\lambda}_r$ NFN)

4.4.2 Teste de Robustez a Distúrbios

4.4.2.1 Teste de Robustez às Variações Paramétricas

Como o erro entre a integral da corrente de estator observada e a medida é praticamente nulo, o erro de observação de fluxo é proveniente da equação de mapeamento entre o fluxo observado e a integral de corrente de estator observada (eq. 3.29). Assim, espera-se que a variação nas indutâncias mútua e de rotor bem como na resistência de rotor e a precisão numérica sejam os pontos fracos deste observador.

Pode-se notar pela eq. 3.29, que uma variação em L_r é compensada por uma variação equivalente em L_m , pois $L_r = L_{lr} + L_m$. Além disso, um passo de integração muito pequeno torna os erros numéricos de integração muito pequenos (o passo de integração utilizado neste trabalho foi $T = 250 \times 10^{-6} \text{s}$). Assim, os pontos potencialmente fracos deste observador restringem-se apenas às variações de L_m e R_r .

A fim de verificar a sensibilidade do observador de fluxo às variações paramétricas, foi aplicado um degrau de aumento de 20% na resistência de estator e de rotor, e um degrau de diminuição de 20% da indutância mútua *do modelo da MI* (separadamente) após um segundo de simulação, com o motor em regime permanente (fig. 4.14). Para a escolha da direção da variação dos parâmetros, levou-se em consideração que há um aumento nas resistências durante a operação normal da MI (devido ao aumento da temperatura no estator e no rotor) e uma diminuição nas indutâncias da MI na região de saturação.

Acionamento em Baixas Velocidades: Foi feito um acionamento a 5 rad/s, com a aplicação de um degrau de variação nas resistências de estator e de rotor, e na indutância mútua, após um segundo de simulação, separadamente. Na fig. 4.15, pode-se ver o fluxo observado pelo NFN. Na fig. 4.16 vê-se o erro do observador NFN. As três curvas são idênticas para os três tipos de perturbação. Nota-se que o observador de fluxo NFN não apresentou nenhuma degradação à variação da resistência de estator ou de rotor, nem da indutância mútua. O erro máximo do observador NFN foi de $2,6 \times 10^{-3}$ ou 0,52%.




Figura 4.14- Resultados de simulação: teste de robustez a variações paramétricas ($\hat{\lambda}_r$ NFN)




Figura 4.15- Resultados de simulação: teste de robustez a variações paramétricas em baixas velocidades ($\hat{\lambda}_r$ NFN)




Figura 4.16- Resultados de simulação: teste de robustez a variações paramétricas em baixas velocidades ($\hat{\lambda}_r$ NFN)

Acionamento em Médias Velocidades: Para um acionamento a 150 rad/s, o observador de fluxo NFN não apresentou nenhuma degradação à variação da resistência de estator nem da indutância mútua. Houve uma pequena perturbação no observador para a variação da resistência de rotor. O erro máximo do observador NFN foi de 1×10^{-2} ou 2% (fig. 4.17).




Figura 4.17- Resultados de simulação: teste de robustez a variações de R_r em médias velocidades ($\hat{\lambda}_r$ NFN)

Acionamento em Altas Velocidades: Para um acionamento a 500 rad/s, novamente o observador de fluxo NFN não apresentou nenhuma degradação à variação da resistência de estator nem da indutância mútua. Houve uma pequena perturbação no observador NFN para a variação da resistência de rotor, cujo erro máximo (de 34×10^{-3} ou 6,8%) pode ser visto na fig. 4.18.

4.4.2.2 Teste de Robustez à Aplicação e Retirada de Carga (ARC)

Para a verificação da sensibilidade do observador de fluxo a aplicações e retiradas de carga, foi feita uma aplicação (após 1 s) e posterior retirada de uma carga de 5 N.m (em torno de 63% da nominal), após 2,5 s de simulação.




Figura 4.18- Resultados de simulação: teste de robustez a variações de R_r em altas velocidades ($\hat{\lambda}_r$ NFN)

Acionamento em Baixas Velocidades: Para um acionamento a 5 rad/s, o observador NFN apresentou uma sensibilidade muito pequena à aplicação e retirada de cargas. O erro máximo do observador NFN foi de $3,1 \times 10^{-3}$ ou 0,62% (fig. 4.19).




Figura 4.19- Resultados de simulação: teste de robustez a ARC em baixas velocidades ($\hat{\lambda}_r$, NFN)

Acionamento em Médias Velocidades: Para um acionamento a 150 rad/s, o observador NFN apresentou uma desprezível sensibilidade à ARC. O erro máximo do observador NFN foi de $6,3 \times 10^{-3}$ ou 1,26% (fig. 4.20).

Acionamento em Altas Velocidades: Também para um acionamento a 500 rad/s, o observador NFN apresentou uma sensibilidade desprezível à ARC. O erro máximo do observador NFN foi de $1,3 \times 10^{-2}$ ou 2,6% (fig. 4.21).

4.4.3 Teste de Operação à Velocidade e Frequência Nulas

Um dos pontos críticos dos observadores de fluxo é a operação em velocidade nula. A situação de velocidade nula com frequência nula (ou quase nula) é obtida quando não há carga para a MI e o escorregamento torna-se desprezível. Para avaliar o desempenho do




Figura 4.20- Resultados de simulação: teste de robustez a ARC em médias velocidades ($\hat{\lambda}_r$ NFN)




Figura 4.21- Resultados de simulação: teste de robustez a ARC em altas velocidades ($\hat{\lambda}_r$ NFN)

observador nesta situação, ajustou-se a velocidade de referência para 0 rad/s. Foram feitas duas aplicações e retiradas de carga subsequentes, de modo a termos cinco intervalos de tempo com velocidade nula (dois deles à frequência nula), como pode ser visto nas fig. 4.22 e 4.23.




Figura 4.22- Resultados de simulação: teste de operação à velocidade nula ($\hat{\lambda}_r$, NFN)

Na fig. 4.23, pode-se verificar o fluxo observado, e os intervalos de tempo em que a frequência é nula. O máximo erro de observação NFN foi $2,7 \times 10^{-3}$ ou 0,54% (fig. 4.24).

4.4.4 Análise da Influência da Taxa de Aprendizado

A partir das eq. 3.25, 3.39, 3.40 e 3.41 pode-se obter a relação entre a taxa de aprendizagem da rede NFN *sem equação de mapeamento*, α , e a taxa de aprendizagem da rede NFN *com equação de mapeamento*, η , para o observador de fluxos NFN:

$$\eta^{(j)} = \frac{\alpha^{(j)}}{\left(\frac{L_r}{L_m \cdot R_r} + \frac{T}{L_m}\right)^2} \quad (4.11)$$




Figura 4.23- Resultados de simulação: teste de operação à velocidade nula ($\hat{\lambda}_r$, NFN)




Figura 4.24- Resultados de simulação: teste de operação à velocidade nula ($\hat{\lambda}_r$, NFN)

A taxa de aprendizado α , num teste de PRV, varia no intervalo $[0,13 \text{ a } 0,31]$ (fig. 4.25). A taxa de aprendizado η , por sua vez, varia no intervalo $[1,65 \text{ a } 3,94]$ (eq. 4.11 e Apêndice A).

Através de simulações, pode-se obter os seguintes limites de variação das taxas de aprendizado que mantêm o sistema estável:

$$\alpha^{(j)} \in [0,05 \text{ a } 0,32] \quad (4.12)$$

$$\eta^{(j)} \in [0,64 \text{ a } 4,06] \quad (4.13)$$

Convém salientar que estes limites não foram obtidos analiticamente; apenas através de simulações.

A fim de verificar a influência da taxa de aprendizado do observador de fluxos NFN, foram feitas algumas simulações com teste de PRV utilizando taxa de aprendizado fixa. O melhor resultado obtido foi com $\alpha=0,2$ ($\eta=2,54$), para o qual o erro máximo entre z_l e z_l^d foi da ordem de 10^{-3} (Fig. 4.26). Para taxa de aprendizado ótima, o respectivo erro máximo foi da ordem de 10^{-7} . O máximo erro de observação obtido ficou em torno de 0,9% (fig. 4.27), bem próximo do obtido com taxa de aprendizado ótima (0,6%).

Isto mostra ser possível obter bons resultados na observação de fluxo rotórico em tempo real (em um teste de PRV) utilizando apenas a eq. 3.7 e um η fixado adequadamente. Entretanto, ainda não se pode afirmar que com este η fixo seja possível obter um bom resultado para qualquer situação. Utilizando-se um η ótimo, garante-se o melhor resultado para qualquer situação sem a necessidade de simulações prévias.

Portanto, ao se projetar um observador de estados NFN, deve-se primeiramente tentar obter uma expressão para a taxa de aprendizado ótima. Se isto for difícil ou até mesmo impossível, pode-se tentar utilizar uma taxa de aprendizado fixa, obtida através de simulações.




Figura 4.25- Resultados de simulação: teste de PRV com $\eta=2,56$ ($\hat{\lambda}_r$ NFN)




Figura 4.26- Resultados de simulação: teste de PRV com $\eta=2,56$ ($\hat{\lambda}_r$ NFN)




Figura 4.27- Resultados de simulação: teste de PRV com $\eta=2,56$ ($\hat{\lambda}_r$ NFN)

Modelo Preditor	Soma/Subtração	Multiplicação/Divisão	Seno/Cosseno	Exp.	Outros
Gopinath-mod. A3	42	77	2	1	0
Luemberger-mod. B1	41	88	2	1	0
Luemberger-mod. D1	43	100	2	1	0
Gopinath com PI	32	67	2	1	0
Modos Deslizantes	32	47	1	0	3
NFN	46	58	2	0	0

Tabela 4.1: Custo Computacional de Observadores

4.4.5 Custo Computacional do Observador de Fluxo NFN

Luiz, em [61] mostra numa tabela o custo computacional de alguns estimadores (modelo em tensão e em corrente) e observadores (Gopinath, Luemberger e modos deslizantes) de fluxo para a máquina de indução. Esta tabela está reproduzida na Tabela 4.1, apenas com os observadores e acrescida do custo computacional do observador NFN. Pode-se verificar que, dentre estes observadores, o observador NFN é um dos que apresenta menor custo computacional.

4.4.6 Comparação com o Observador de Gopinath de Ordem Reduzida

Para fins de comparação, todos os testes de simulação realizados com o observador de fluxos NFN foram também realizados com o observador de fluxos de Gopinath de ordem reduzida, ao mesmo tempo. O fluxo observado NFN foi utilizado para orientação pelo campo e na malha de controle de fluxo, enquanto que o fluxo observado por Gopinath foi utilizado apenas para estas comparações. O observador de Gopinath foi escolhido para estas comparações por já estar bem estabelecido na literatura. Além disso ele está também implementado no sistema experimental para acionamentos elétricos abordado na seção 4.2.

A fig. 4.28 mostra os fluxos observados pelo NFN (índice N) e por Gopinath (índice G), em um teste de PRV a 5 rad/s, enquanto que a fig. 4.29 mostra os fluxos observados num teste de PRV a 500 rad/s. Os máximos erros de observação dos observadores de fluxo NFN e de Gopinath, obtidos a partir de uma média das simulações (para cada um dos testes realizados) encontram-se resumidos na Tabela 4.2. Pode-se observar que o

máximo erro de observação do observador de fluxo NFN é maior do que o do observador de Gopinath apenas para variações em R_r , em velocidades média e alta, e menor nas outras situações.




Figura 4.28- Resultados de simulação: teste de PRV em baixas velocidades ($\hat{\lambda}_r$, NFN)




Figura 4.29- Resultados de simulação: teste de PRV em altas velocidades ($\hat{\lambda}_r$ NFN)

Testes\Observador	NFN	Gopinath
PRV-5	0,52	0,68
PRV-150	1,38	1,88
PRV-500	2,70	4,80
VEL. 0	0,54	0,72
ΔR_r -5	0,52	0,66
ΔR_s -5	0,52	0,76
ΔL_m -5	0,52	0,78
ΔR_r -150	2,00	1,88
ΔR_s -150	1,10	1,88
ΔL_m -150	1,10	1,88
ΔR_r -500	6,80	4,40
ΔR_s -500	2,70	4,40
ΔL_m -500	2,60	4,40
ARC-5	0,62	0,70
ARC-150	1,26	1,88
ARC-500	2,60	4,40

Tabela 4.2: Máximo erro de observação em fluxo NFN e de Gopinath (obtida de uma média de simulações)

4.5 Resultados Experimentais e Discussão de Resultados do Observador de Fluxo NFN

De maneira análoga à seção 4.4, os testes feitos nesta seção utilizaram a velocidade fornecida pelo tacogerador, a fim de avaliar apenas o observador de fluxo NFN. Portanto, o acionamento feito aqui não foi *sensorless*.

4.5.1 Teste de Partida e Reversão de Velocidade

4.5.1.1 Acionamento em Baixas Velocidades

De maneira análoga às simulações, foi feito um teste de PRV utilizando as velocidades de -5 rad/s e 5 rad/s como referência. Novamente, verifica-se o bom desempenho do sistema. Os picos espúrios no conjugado eletromagnético de referência (T_e^*) e na velocidade (ω_r) são consequência de ruídos de medição de velocidade, que tornam-se mais evidentes para baixos valores de velocidade (fig. 4.30). Na fig. 4.31, pode-se ver o fluxo observado.

O máximo erro de controle do módulo do vetor fluxo de rotor, após o estabelecimento do fluxo, foi de aproximadamente 0,06%.

4.5.1.2 Acionamento em Médias Velocidades

Foi feito um teste de PRV utilizando como referências, as velocidades de 150 rad/s e -150 rad/s. As fig. 4.32 e 4.33 mostram o bom desempenho do controle DUFOR com o observador de fluxo de rotor NFN, e na fig. 4.34, vemos o fluxo observado. Pode-se perceber que o tempo de resposta do controle de velocidade no teste experimental foi um pouco menor do que nas simulações (em torno de 150 ms). Isto deve-se provavelmente a um momento de inércia real um pouco menor do que o utilizado nas simulações.

O máximo erro de controle do módulo do vetor fluxo de rotor, após o estabelecimento do fluxo, foi de aproximadamente 0,6%, e ocorreu no início da reversão de




Figura 4.30- Resultados de experimentais: teste de PRV em baixas velocidades ($\hat{\lambda}_r$ NFN)




Figura 4.31- Resultados de experimentais: teste de PRV em baixas velocidades ($\hat{\lambda}_r$ NFN)

velocidade.




Figura 4.32- Resultados de experimentais: teste de PRV em médias velocidades ($\hat{\lambda}_r$ NFN)

4.5.2 Teste de Robustez de Distúrbios

4.5.2.1 Teste de Robustez à Aplicação e Retirada de Carga (ARC)

Acionamento em Baixas Velocidades: De maneira semelhante às simulações, procedeu-se à uma aplicação e retirada de carga, após a entrada do MI em regime permanente de uma partida a 5 rad/s.

Conforme descrito na seção 4.2, utilizou-se um gerador de CC como carga para o MI. Devido às limitações na carga resistiva, em baixas velocidades só é possível simular cargas mecânicas muito pequenas. Assim, nesta faixa de velocidades, a aplicação de carga foi feita “manualmente” no eixo do motor de indução. A carga aplicada foi de aproximadamente 2,5 N.m (em torno de 30% do valor nominal).

Na fig. 4.35, observa-se a redução da velocidade até a completa parada do motor,




Figura 4.33- Resultados de experimentais: teste de PRV em médias velocidades ($\hat{\lambda}_r$, NFN)

após a aplicação da carga. Os controladores de conjugado e velocidade atuam de modo a levar o motor à velocidade de referência, o que ocorre aproximadamente 600 ms depois. Após a retirada da carga, a velocidade aumenta em aproximadamente 50% e retorna a 5 rad/s logo em seguida. Pode-se observar que durante todo o transitório, o fluxo observado permaneceu no valor de referência, demonstrando o bom funcionamento do observador de fluxos e dos controladores de fluxo.

O máximo erro de controle do módulo do vetor fluxo de rotor, após o estabelecimento do fluxo, foi de aproximadamente 0,06%.

Acionamento em Médias Velocidades: À velocidade de 150 rad/s, foi possível utilizar o gerador CC como carga de maneira conveniente. Efetuou-se a aplicação e retirada de uma carga de 5 N.m (aproximadamente 60% do valor nominal).

Pode-se ver na fig. 4.36 que durante o transitório de ARC, a velocidade foi bem controlada. Além disso, o fluxo também foi eficientemente controlado, o que só é possível com uma boa malha de controle e com uma boa observação de fluxo.




Figura 4.34- Resultados de experimentais: teste de PRV em médias velocidades ($\hat{\lambda}_r$ NFN)




Figura 4.35- Resultados experimentais: teste de robustez a ARC em baixas velocidades ($\hat{\lambda}_r$ NFN)

O máximo erro de controle do módulo do vetor fluxo de rotor, após o estabelecimento do fluxo, foi de aproximadamente 0,2%, e ocorreu durante a aplicação da carga.




Figura 4.36- Resultados experimentais: teste de robustez a ARC em médias velocidades ($\hat{\lambda}_r$ NFN)

4.5.3 Teste de Aplicação de Onda Quadrada Simétrica de Conjugado

Para a aplicação deste teste, desabilitou-se a malha controle de velocidade. Contudo, a malha de controle de fluxo continuou operante, estabelecendo o fluxo rapidamente. Na fig. 4.37, pode-se ver que o conjugado eletromagnético observado ($\hat{T}_e$) acompanhou bem o de referência (T_e^*). Além disso, a forma de onda da velocidade medida (ω_r) é triangular, como era de se esperar.

Na fig. 4.38, pode-se verificar o fluxo observado, e na fig. 4.39 pode-se ver a curva $\hat{T}_e$ versus ω_r .




Figura 4.37- Resultados de experimentais: teste de aplicação de onda quadrada simétrica de T_e^* ($\hat{\lambda}_r$ NFN)




Figura 4.38- Resultados de experimentais: teste de aplicação de onda quadrada simétrica de T_e^* ($\hat{\lambda}_r$ NFN)




Figura 4.39- Resultados de experimentais: teste de aplicação de onda quadrada simétrica de T_e^* ($\hat{\lambda}_r$ NFN)

4.6 Resultados e Discussão de Resultados do Observador de Velocidade NFN: Primeira e Segunda Propostas

4.6.1 Resultados de Simulação

De maneira análoga ao observador de fluxos NFN, foram feitos vários testes para avaliar o desempenho do observador de velocidade NFN. A não ser quando especificado o contrário, os testes de simulação foram feitos com a informação de fluxo de rotor fornecida pelo modelo e com os observadores de velocidade NFN fora da malha de controle.

Conforme visto na seção 3.4, os dois observadores de velocidade NFN foram implementados numa só rede NFN, a fim de comparar o desempenho dos dois. Assim, o subscrito 1 refere-se ao observador de velocidade implementado a partir da eq. 3.47 enquanto que o subscrito 2 refere-se ao implementado a partir da eq. 3.48.

Inicialmente, foram feitos três testes de PRV a 150 rad/s. No primeiro teste, foi

utilizado o fluxo de rotor do modelo. A fig. 4.40 mostra as velocidades estimadas e a do modelo da MI. O máximo erro de observação da velocidade foi de 0,06% (fig. 4.41). O máximo erro de observação de $I_{s\alpha}$ e $I_{s\beta}$ foi em torno de 2,5% (fig. 4.42), pois a amplitude de $I_{s\alpha}$ e $I_{s\beta}$ é dois ampéres, em regime permanente.

A equação de atualização dos pesos com taxa de aprendizado ótima (eq. 3.84 a 3.87) deveria garantir um erro bem menor (praticamente zero, como ocorreu com o observador de fluxo). Entretanto, o cálculo da variável mapeada z_l (eq. 3.55) depende do cálculo de uma derivada, que é muito sensível a erros numéricos. Além disso, a referida equação de atualização dos pesos é função de uma função singular, conforme discutido na seção 3.4, o que pode trazer erros nos instantes em que os pontos singulares ocorrem. Verifica-se, contudo, que os erros de observação foram muito pequenos nas simulações.




Figura 4.40- Resultados de simulação: teste de PRV em médias velocidades, utilizando o fluxo do modelo na observação de velocidade ($\hat{\omega}_r$ NFN-1,2)

No segundo teste de PRV, utilizou-se o fluxo observado NFN (que utilizou a velocidade do modelo) com o observador de velocidade NFN, a fim de verificar o efeito do observador de fluxo NFN nos observadores de velocidade NFN. Verificou-se que o erro de observação de fluxo, embora pequeno, refletiu-se num erro considerável de observação de velocidade. A fig. 4.43 mostra as velocidades observadas e a do modelo da MI. O máximo




Figura 4.41- Resultados de simulação: teste de PRV em médias velocidades, utilizando o fluxo do modelo na observação de velocidade ($\hat{\omega}_r$ NFN-1,2)




Figura 4.42- Resultados de simulação: teste de PRV em médias velocidades, utilizando o fluxo do modelo na observação de velocidade ($\hat{\omega}_r$ NFN-1,2)

erro de observação da velocidade foi de 6,6% (fig. 4.44) e ocorreu em praticamente todo o teste. O máximo erro de estimação estacionário de $I_{s\alpha}$ e $I_{s\beta}$ foi em torno de 2,5% (fig. 4.45). Nota-se que este erro aumentou bastante com relação ao erro obtido utilizando o fluxo de rotor do modelo. Este fato pode inviabilizar a utilização destes observadores de velocidade num acionamento *sensorless* em baixas velocidades. Para minimizar estes erros, foram feitos alguns ajustes nos parâmetros do observador de velocidade NFN (penúltimo parágrafo da seção 3.4).




Figura 4.43- Resultados de simulação: teste de PRV em médias velocidades, utilizando o fluxo NFN na observação de velocidade ($\hat{\omega}_r$ NFN-1,2)

O terceiro teste de PRV foi feito com estes ajustes utilizando o fluxo do modelo, sem nenhum tipo de distúrbio. A fig. 4.46 mostra o erro das observações de velocidade. O máximo erro de observação foi de aproximadamente 4,6% e ocorreu apenas durante os transitórios.

Para avaliar-se o desempenho apenas destes observadores de velocidade diante dos testes, foi utilizado o fluxo do modelo nas simulações.

Foram feitos também testes de PRV a 5 e a 500 rad/s, teste de operação à velocidade e frequência nulas, e testes de robustez a variações paramétricas e a aplicação




Figura 4.44- Resultados de simulação: teste de PRV em médias velocidades, utilizando o fluxo NFN na observação de velocidade ($\hat{\omega}_r$ NFN-1,2)




Figura 4.45- Resultados de simulação: teste de PRV em médias velocidades, utilizando o fluxo NFN na observação de velocidade ($\hat{\omega}_r$ NFN-1,2)




Figura 4.46- Resultados de simulação: teste de PRV em médias velocidades, utilizando o fluxo do modelo na observação de velocidade, com ajuste ($\hat{\omega}_r$ NFN-1,2)

Velocidade (rad/s)	Sem Var. Par. PRV	Sem Var. Par. Só Partida	+20% R_s	+20% R_r	-20% L_m	ARC
0	5 rad/s	—————	—————	—————	—————	—————
5	4,0	2,8	2,8	10,0	não funciona	4,3
150	3,3	3,3	3,3	3,3	4,8	3,3
500	1,4	1,0	1,0	2,8	2,8	1,0

Tabela 4.3: Máximo erro de observação (%) dos observadores de velocidade (primeira e segunda propostas)

e retirada de carga, com partidas a 5, 150 e 500 rad/s.

Os erros de observação aumentaram com a redução da velocidade de operação. O mesmo aconteceu com os erros devido às variações paramétricas, o que indica que estes observadores são mais sensíveis a erros em baixas velocidades. Estes erros foram maiores para variações na indutância mútua e menores para variações na resistência de rotor. Não houve nenhuma influência devido às variações na resistência de estator. Os resultados dos testes estão resumidos na Tabela 4.3.

Embora estes observadores tenham se mostrado mais críticos às variações de L_m em baixas velocidades, este problema pode ser facilmente contornado, haja visto que este parâmetro varia mais na região de saturação, quando poderá ser utilizada uma tabela de consulta, onde os valores de L_m são atualizados para cada faixa de operação.

4.6.2 Resultados Experimentais

Estes resultados foram obtidos na montagem experimental descrita na seção 4.2. Os observadores de velocidade NFN foram utilizados na malha de controle de velocidade, no controle DUFOR de um MI. A informação dos fluxos de rotor foi fornecida pelo observador de fluxo NFN. A velocidade medida foi utilizada apenas pelo observador de fluxo NFN. Portanto, não foi utilizado um acionamento *sensorless*. As velocidades observadas pelos observadores 1 e 2 foram equivalentes. Assim, só será mostrada uma curva de velocidade observada.

Foi feito um teste de PRV a 5 rad/s. Na fig. 4.47 (a), pode-se ver a corrente de estator de eixo d , responsável pelo estabelecimento do fluxo. Na fig. 4.47 (b), vemos o

conjugado eletromagnético de referência e o observado (obtido a partir do fluxo de rotor observado pelo NFN).

Na fig. 4.48, pode-se ver a velocidade medida e a observada, bem como o erro do observador NFN. Nota-se um erro maior durante os transitórios. As oscilações devem-se à necessidade de um melhor ajuste na malha de controle de velocidade.

O alto erro verificado na fig. 4.48 (em torno de 50%) na verdade é devido à um atraso entre a velocidade estimada e a medida. O erro percentual entre os picos de velocidade é de 10% (fig. 4.49). Como uma das características deste tipo de observador é a rápida convergência, quando for obtida a adequada equação de atualização dos pesos com taxa de aprendizado ótima, espera-se que o erro reduza-se sensivelmente.

Nota-se também alguns picos de erro (fig. 4.48 b) devido a ruídos de medição.




Figura 4.47- Resultados experimentais: teste de PRV em baixas velocidades, com o observador de velocidade na malha de controle e com o observador de fluxo NFN utilizando a velocidade medida ($\hat{\omega}_r$ NFN-1,2)

A fig. 4.50 mostra a corrente de estator de eixo d e o conjugado eletromagnético de referência e o observado, em um teste de PRV a 150 rad/s. Na fig. 4.51, vemos a velocidade medida e a observada, bem como o erro do observador NFN. O maior erro




Figura 4.48- Resultados experimentais: teste de PRV em baixas velocidades, com o observador de velocidade na malha de controle e com o observador de fluxo NFN utilizando a velocidade medida ($\hat{\omega}_r$ NFN-1,2)




Figura 4.49- Resultados experimentais: teste de PRV em baixas velocidades, com o observador de velocidade na malha de controle e com o observador de fluxo NFN utilizando a velocidade medida ($\hat{\omega}_r$ NFN-1,2)

percentual de velocidade foi 10% (fig. 4.51).




Figura 4.50- Resultados experimentais: teste de PRV em médias velocidades, com o observador de velocidade na malha de controle e com o observador de fluxo NFN utilizando a velocidade medida ($\hat{\omega}_r$ NFN-1,2)

4.7 Resultados de Simulação e Discussão de Resultados do Observador de Velocidade NFN: Terceira Proposta

De maneira análoga ao observador de velocidades NFN-1 e 2 (primeira e segunda propostas), foram feitos vários testes para avaliar o desempenho do observador de velocidade NFN-3 (terceira proposta). O observador de velocidade NFN-3 recebe como entradas a posição do vetor fluxo, o conjugado eletromagnético e as correntes de estators de eixo α e β do modelo. Além disso, serão utilizadas as tensões de estators de eixo α e β de referência (fig. 3.11). O observador NFN-3 fornece a velocidade observada, que será usada no controle de velocidade e na observação do fluxo de rotor. O fluxo observado será utilizado apenas na orientação dos eixos dq do sistema e no controle do fluxo. O observador de velocidade utilizará o fluxo do modelo.

Esta abordagem evidenciará as vantagens e desvantagens inerentes ao




Figura 4.51- Resultados experimentais: teste de PRV em médias velocidades, com o observador de velocidade na malha de controle e com o observador de fluxo NFN utilizando a velocidade medida ($\hat{\omega}_r$ NFN-1,2)

observador de velocidade NFN-3, que poderiam ser mascaradas pela realimentação dos erros de observação de fluxos e de velocidade.

4.7.1 Teste de Partida e Reversão de Velocidade

4.7.1.1 Teste de Operação em Baixas Velocidades

Na fig. 4.52, pode-se ver a corrente de estator de eixo d (a), O conjugado eletromagnético do modelo e o de referência (b) e a velocidade observada, a do modelo e a medida, num teste de PRV a 5 rad/s.




Figura 4.52- Resultados de simulação: teste de PRV em baixas velocidades, utilizando o fluxo do modelo na observação de velocidade ($\hat{\omega}_r$ NFN-3)

Pode-se perceber que a velocidade observada é um pouco “ruidosa”. Isto é devido à alimentação PWM da MI, que provoca naturalmente pequenos “ruídos” em I_{sq} e V_{sq} (bem como em I_{sd} e V_{sd}), que são transmitidos ao observador através das equações de mapeamento. Da mesma forma que as tensões PWM têm como valor médio as fundamentais de tensão, estes “ruídos” têm como valor médio as respectivas fundamentais

de corrente e tensão. Portanto, a própria velocidade observada tem o valor médio da velocidade real. Os seus “ruídos”, embora presentes na malha de controle de velocidade e conjugado, são filtrados pelo sistema, como pode ser observado na fig. 4.53, onde o erro de controle de velocidade é menos ruidoso do que o erro de observação de velocidade.

Assim, o conceito de *erro médio* (como sendo a média dos erros) faz mais sentido aqui do que o erro simplesmente. Doravante será mostrado tanto o erro como o seu respectivo valor médio.

Na fig. 4.53, pode-se ver os erros de observação e de controle de velocidade (e_o e e_c , respectivamente) para o mesmo acionamento. Embora o máximo erro de observação de velocidade tenha sido em torno de 20%, ele durou apenas 50ms, e provavelmente foi causado devido a erros numéricos no cálculo da derivada da corrente de estator de eixo d , que é diferente de zero durante as transições de ω_r^* . O erro de observação em regime permanente foi em torno de 2% e o erro médio de observação foi de aproximadamente 0,2%. O máximo erro de controle foi em torno de 8%.




Figura 4.53- Resultados de simulação: teste de PRV em baixas velocidades, utilizando o fluxo do modelo na observação de velocidade ($\hat{\omega}_r$, NFN-3)

4.7.1.2 Teste de Operação em Médias Velocidades

A fig. 4.54 mostra a corrente de estator de eixo d (a), O conjugado eletromagnético do modelo e o de referência (b) e a velocidade observada, a do modelo e a medida, num teste de PRV a 150 rad/s.

Na fig. 4.55, pode-se ver os erros e_o e e_c . O *máximo erro de observação* foi em torno de 1,3% e erro médio de observação foi de aproximadamente 0,04%. O *máximo erro de controle* em regime permanente foi em torno de 0,3%.




Figura 4.54- Resultados de simulação: teste de PRV em médias velocidades, utilizando o fluxo do modelo na observação de velocidade ($\hat{\omega}_r$ NFN-3)

4.7.2 Teste de Robustez de Distúrbios

Como os erros de observação entre $\hat{I}_{sq}$ ($\hat{V}_{sq}$) e I_{sq} (V_{sq}) são nulos, os erros de observação entre $\hat{\omega}_{sr}$ ($\hat{\omega}_s$) e ω_{sr} (ω_s) são devido apenas às equações de mapeamento (eq. 3.70 e 3.71).

A partir da eq. 3.70, pode-se notar que erros na constante de tempo de rotor podem trazer erros na observação de ω_{sr} . A eq. 3.71 mostra que os erros em R_s , L_s e no




Figura 4.55- Resultados de simulação: teste de PRV em médias velocidades, utilizando o fluxo do modelo na observação de velocidade ($\hat{\omega}_r$ NFN-3)

cálculo da derivada de I_{sq} podem trazer erros no cálculo de $\hat{\omega}_s$.

Entretanto os erros em $\hat{\omega}_s$ predominam sobre os erros em ω_{sr} (devido à diferença numérica destas grandezas), no cálculo de $\hat{\omega}_r$. Além disso, a derivada de I_{sq} só está presente durante as variações de ω_r^* . Assim, as potenciais fontes de erro deste observador estão relacionadas às variações de R_s e L_s (em particular de L_s , pois esta multiplica diretamente ω_s).

4.7.2.1 Teste de Robustez às Variações Paramétricas

De maneira análoga ao observador de fluxo, a fim de verificar a sensibilidade do observador de velocidade às variações paramétricas, foi aplicado um degrau de aumento de 20% na resistência de estator e de rotor, e um degrau de diminuição de 20% da indutância mútua *do modelo da MI* (separadamente) após um segundo de simulação, com o motor em regime permanente. Os resultados destes testes estão resumidos na Tabela 4.4.

Pode-se notar que este observador tem boa robustez às variações de R_r e de

R_s . Entretanto, ele é particularmente sensível às variações da indutância mútua. Como o acionamento utilizado neste trabalho (DUFOR *sensorless*) é feito a fluxo constante, a L_m não varia. Para acionamentos a fluxo variável, pode-se utilizar uma tabela de consulta do valor de L_m para cada valor de λ_r^* . Além disso, pode-se observar que a robustez deste observador às variações paramétricas diminuiu um pouco com a velocidade.

4.7.2.2 Teste de Robustez à Aplicação e Retirada de Carga (ARC)

Para a verificação da sensibilidade do observador de velocidade a aplicações e retiradas de carga, foi feita uma aplicação e posterior retirada de uma carga de 5 N.m em duas faixas de velocidade.

Acionamento em Baixas Velocidades: Na fig. 4.56, pode-se ver o bom desempenho do observador de velocidade numa ARC a 5 rad/s. No instante da aplicação da carga, a velocidade cai (chegando a haver uma pequena reversão) para em seguida voltar ao valor de referência. Ao retirar-se a carga, a velocidade sobe e restabelece-se logo em seguida.

O observador NFN mostrou-se robusto à aplicação e retirada de cargas a 5 rad/s. Embora o erro máximo do observador NFN tenha sido em torno de 40%, ele é devido aos “ruídos” do observador, que são filtrados pelo sistema. O erro médio de observação é de aproximadamente 1,6% e o erro máximo de controle (em regime permanente) é em torno de 10% (fig. 4.57). As variações instantâneas e dinâmicas da velocidade são influenciadas pelo ajuste dos controladores e das limitações impostas às variáveis. Portanto, um melhor ajuste nos controladores reduzirá as variações de velocidade e o tempo de resposta no seu controle.

Acionamento em Médias Velocidades: A fig. 4.58 mostra o bom desempenho do observador de velocidade numa ARC a 150 rad/s. Novamente, a velocidade sofre perturbações durante a aplicação e retirada da carga, mas é levada rapidamente ao valor desejado, no acionamento *sensorless*.

O observador NFN também mostrou-se robusto à aplicação e retirada de cargas




Figura 4.56- Resultados de simulação: teste de robustez a ARC em baixas velocidades ($\hat{\omega}_r$ NFN-3)




Figura 4.57- Resultados de simulação: teste de robustez a ARC em baixas velocidades ($\hat{\omega}_r$ NFN-3)

a 150 rad/s. O máximo erro de observação foi em torno de 1,3%. O erro médio de observação foi de aproximadamente 0,4%. Pode-se observar também a existência de um erro de regime permanente no controle de velocidade durante a aplicação da carga. Entretanto, este erro foi de apenas 0,6% e foi devido à necessidade de um melhor ajuste nos controladores PI. Após a retirada da carga, o erro de controle em regime permanente caiu para 0,1% (fig. 4.59).

4.7.3 Teste de Operação a Velocidade e Frequência Nulas

A fim de verificar o desempenho do observador à velocidade zero e a sua sensibilidade às variações de carga, um degrau de 63% da carga nominal foi aplicado em $t=5s$ e retirado em $t=1,5s$, aplicado novamente em $t=3,5s$ e retirado em $t=4,5s$. Durante este período de tempo, a velocidade de referência é nula (de $t=0s$ até $t=3s$) e igual a 150 rad/s (após $t=3s$).

Na fig. 4.60, pode-se ver a velocidade real e observada (a), assim como o erro de observação em velocidade nula e média (b). O *máximo erro de observação* de velocidade foi em torno de 2 rad/s. Os resultados dos testes estão resumidos na Tabela 4.4.




Figura 4.58- Resultados de simulação: teste de robustez a ARC em médias velocidades ($\hat{\omega}_r$ NFN-3)




Figura 4.59- Resultados de simulação: teste de robustez a ARC em médias velocidades ($\hat{\omega}_r$ NFN-3)




Figura 4.60- Resultados de simulação: teste de operação à velocidade nula, utilizando o fluxo do modelo na observação de velocidade ($\hat{\omega}_r$, NFN-3)

Velocidade (rad/s)	PRV	+20% R_s	+20% R_r	-20% L_m	ARC
0	2 rad/s	—	—	—	—
5	0,20	1,92	2,00	5,2	1,60
150	0,04	0,32	0,40	1,05	0,40

Tabela 4.4: Erro de observação médio (%) do observador de velocidade (terceira proposta)

4.7.4 Análise da Rigidez Dinâmica ([18] e [58])

A *rigidez dinâmica* (RD) do controlador de um sistema é uma figura de mérito definida por:

$$RD(s) = \left| \frac{\text{distúrbio no sistema}(s)}{\text{saída do sistema}(s)} \right| \quad (4.14)$$

A RD pode ser obtida da função de transferência do sistema de forma analítica ou experimental, e está diretamente relacionada às rejeições aos distúrbios no sistema. No caso de um motor de indução com controle vetorial por orientação pelo campo (o tipo de controle utilizado neste trabalho), a RD pode ser definida por:

$$RD(s) = \left| \frac{Tc(s)}{\theta_r(s)} \right| \quad (4.15)$$

ou por:

$$RD(s) = \left| \frac{Tc(s)}{\omega_r(s)} \right| \quad (4.16)$$

A fig. 4.61 mostra uma topologia DUFOR [58]. Na fig. 4.62 pode-se ver a respectiva rigidez dinâmica do MI. Ela informa qual é o erro de posição para um determinado valor de conjugado de carga. Assim, para uma frequência de trabalho de 1 Hz, seria necessário um conjugado de carga de aproximadamente 100 N.m para que se tivesse um erro de 1 rad no controle da posição. Os valores K_{ia} , K_{sa} e b_a são parâmetros dos controladores PI utilizados e J é o momento de inércia da MI. Pode-se perceber que o aumento dos ganhos dos controladores faz com que as assíntotas da RD movam-se na direção de aumento da RD, tornando o controle com maior capacidade de rejeição aos distúrbios. Entretanto, um aumento demasiado dos ganhos dos controladores pode tornar o sistema instável.

Para avaliar-se a degradação que a inclusão de observadores provoca na resposta




Figura 4.61- Topologia de um controlador DUFOR




Figura 4.62- Rigidez Dinâmica de um controlador DUFOR




Figura 4.63- Rigidez Dinâmica ($\left| \frac{T_c(s)}{\omega_r(s)} \right|$) do controle DUFOR da máquina de indução com a velocidade do modelo (- -) e com a velocidade observada (-)

dos controladores, efetuou-se (por meio de simulações) uma análise da rigidez dinâmica do acionamento com a velocidade do modelo e com acionamento *sensorless*. A curva da RD com a velocidade do modelo mostra a melhor resposta possível do sistema, diante de distúrbios de carga, para a sintonia atual dos controladores. A inclusão de medidores ou de observadores de velocidade (que possuem, naturalmente, uma faixa de passagem menor do que a ideal) degrada um pouco esta resposta.

Pode-se ver na fig. 4.63 que para frequências abaixo de 0,04 Hz (aproximadamente 0,25 rad/s), o observador de velocidade introduz uma redução da rejeição de perturbações. Para todo o restante da faixa de frequência, a rejeição de perturbação do controle praticamente não se altera.

4.8 Resultados Experimentais e Discussão de Resultados do Observador de Velocidade NFN: Terceira Proposta

Estes resultados foram obtidos na montagem experimental descrita na seção 4.2. O observador de velocidade NFN foi utilizado na malha de controle de velocidade e no observador de fluxos NFN. A informação dos fluxos de rotor foi fornecida pelo observador de fluxo NFN. Portanto, utilizou-se o controle DUFOR *sensorless* no acionamento da MI mostrado na fig. 4.1. A velocidade medida foi utilizada apenas para comparação com a velocidade observada.

4.8.1 Teste de Partida e Reversão de Velocidade

4.8.1.1 Acionamento em Baixas Velocidades

Foi feito um teste de PRV a 5 rad/s. Na fig. 4.64 (a), pode-se ver a corrente de estator de eixo d , responsável pelo estabelecimento do fluxo. Na fig. 4.64 (b), vê-se o conjugado eletromagnético de referência e o observado (obtido a partir do fluxo de rotor observado pelo NFN). Na fig. 4.64 (c), pode-se ver a velocidade observada, a medida e a de referência. A corrente I_{sd} manteve-se bem controlada e desacoplada de I_{sq} (proporcional a T_e). Além disso, as velocidades observada e real seguiram bem a velocidade de referência.

Na fig. 4.65, pode-se ver os erros de observação e de controle de velocidade (e_o e e_c , respectivamente). Os valores médios de e_o e e_c foram em torno de 16,8% e 15,7%.

4.8.1.2 Acionamento em Médias Velocidades

A fig. 4.66 mostra a corrente de estator de eixo d (a), os conjugados eletromagnéticos de referência e observados (b) e as velocidades observada, medida e de referência (c), em um teste de PRV a 150 rad/s. O controle *sensorless* com os observadores de velocidade NFN-3 e de fluxo NFN apresentou um bom desempenho.




Figura 4.64- Resultados experimentais: teste de PRV em baixas velocidade ($\hat{\omega}_r$ NFN-3)




Figura 4.65- Resultados experimentais: teste de PRV em baixas velocidade ($\hat{\omega}_r$ NFN-3)

A fig. 4.67 mostra os erros de observação e de controle de velocidade (e_o e e_c , respectivamente). Os máximo erro de observação foi em torno de 20% (3,33%, em regime permanente) e o erro máximo de controle em regime permanente foi em torno de 2,6%. Os erros máximos ocorreram durante o regime transitório e foram provavelmente causados por erros na tensão de estator e na observação do fluxo em baixas velocidades, aumentado devido aos efeitos de erros de observação em malha fechada.




Figura 4.66- Resultados experimentais: teste de PRV em médias velocidade ($\hat{\omega}_r$ NFN-3)

4.8.2 Teste de Robustez de Distúrbios

4.8.2.1 Teste de Robustez à Aplicação e Retirada de Carga (ARC)

Para a verificação da sensibilidade do observador de velocidade à variações de carga, foi feita uma aplicação e posterior retirada de carga em duas faixas de velocidade.

Acionamento em Baixas Velocidades: De maneira semelhante às simulações, procedeu-se à aplicação e retirada de uma carga, durante o seu acionamento a 10 rad/s. Devido às dificuldades práticas de ajuste dos controladores, não foi possível realizar este ensaio




Figura 4.67- Resultados experimentais: teste de PRV em médias velocidade ($\hat{\omega}_r$ NFN-3)

à velocidade de 5 rad/s. Novamente, em baixas velocidades não foi possível utilizar o Gerador CC para servir como carga mecânica ao MI, fazendo-se esta aplicação de carga manualmente.

Pode-se ver na fig. 4.68, que após a aplicação de uma carga de aproximadamente 3 N.m, a velocidade caiu para zero, sendo levada para a velocidade de referência em seguida. Após a retirada da carga, a velocidade sobe e é levada novamente pelo controlador para o valor desejado. Além disso, o fluxo observado mantém-se no valor desejado, evidenciando um bom desacoplamento entre as malhas de controle de fluxo e de conjugado. Pode-se perceber um tempo de resposta lento da malha de controle de velocidade. Isto deve-se à necessidade de um melhor ajuste nos controladores PI. Embora o controle de velocidade esteja lento, ele produziu o efeito desejado, mostrando que o valor observado da velocidade estava correto ao menos em regime permanente.

Na fig. 4.69, pode-se ver que o erro máximo de observação em regime permanente (desprezando-se os erros devido aos ruídos de medição) foi de aproximadamente 3%. Este valor foi devido aos ruídos presentes na velocidade observada. O respectivo erro médio de observação de velocidade foi de aproximadamente 2,6%. O erro

máximo de controle em regime permanente foi em torno de 20% na aplicação da carga (o que evidencia a necessidade de um melhor ajuste nos controladores de velocidade) e de aproximadamente 7% na retirada da carga.




Figura 4.68- Resultados experimentais: teste de robustez a ARC em baixas velocidades ($\hat{\omega}_r$, NFN-3)

Acionamento em Médias Velocidades: Também foi feita a aplicação e retirada de uma carga de 2,5 N.m, durante o seu acionamento a 150 rad/s.

Pode-se ver na fig. 4.70, que após a aplicação da carga, a velocidade caiu para aproximadamente 140 rad/s, sendo levada rapidamente para a velocidade de referência. Após a retirada da carga, a velocidade sobe e é levada novamente pelo controlador para o valor desejado, de maneira rápida. Devido ao inadequado ajuste nos controladores PI, a aplicação de uma carga maior leva a velocidade a maiores variações e a um tempo ainda maior de resposta. Por isto optou-se por mostrar aqui os resultados de uma ARC com $T_c=2,5$ N.m.

Na fig. 4.71, pode-se ver que o erro médio de observação em regime permanente ficou em torno de 0,8%. O erro máximo de controle em regime permanente foi em torno de 2% na aplicação da carga (o que evidencia a necessidade de um melhor ajuste nos




Figura 4.69- Resultados experimentais: teste de robustez a ARC em baixas velocidades ($\hat{\omega}_r$ NFN-3)

controladores de velocidade) e de aproximadamente 0,16% na retirada da carga.

4.9 Conclusões

Neste capítulo, foi apresentado o sistema experimental, utilizado para a avaliação prática dos observadores propostos, bem como os testes e critérios de avaliação dos mesmos. Escreveu-se também sobre os índices de desempenho que podem ser utilizados para avaliar os sistemas de acionamentos elétricos.

Foi feita uma análise dos observadores propostos, a partir dos resultados de simulação e experimentais obtidos, com o auxílio dos testes e critérios de avaliação.

O observador de fluxos NFN mostrou ter convergência rápida e precisa, bom desempenho em uma ampla faixa de velocidades (incluindo velocidade zero e acima da nominal) e à frequência nula, e satisfatória robustez a distúrbios (grande robustez às variações de R_s , L_m , L_r e L_s , e boa robustez às variações de R_r e à aplicação e retirada de carga). Também possui baixo custo computacional, boa adaptabilidade à dinâmica do




Figura 4.70- Resultados experimentais: teste de robustez a ARC em médias velocidades ($\hat{\omega}_r$, NFN-3)




Figura 4.71- Resultados experimentais: teste de robustez a ARC em médias velocidades ($\hat{\omega}_r$ NFN-3)

sistema e aprendido em tempo real sem necessidade de treinamento prévio.

Os observadores de velocidade NFN-1 e 2 apresentaram tanto nas simulações como na prática um bom desempenho em velocidades média e alta. Ele possui grande robustez às variações de R_s e à aplicação de carga. Possui também razoável robustez às variações de R_r e baixa robustez às variações de L_m . A inerente sensibilidade às variações de L_m e R_r foi reduzida a níveis aceitáveis com ajustes nos parâmetros do observador de velocidade (exceto a baixas velocidades, para variações em L_m). Entretanto, se a sensibilidade às variações de L_m mostrar-se crítica na prática (mais provavelmente na região de enfraquecimento de campo, em que o fluxo deve variar mais), ela pode ser facilmente contornada a partir do valor do fluxo e a respectiva L_m da MI (cuja relação pode ser obtida através de testes). Com estes observadores de velocidade ainda não foi possível obter um acionamento *sensorless*.

O observador de velocidade NFN-3 mostrou ter rápida convergência, bom desempenho numa ampla faixa de velocidade e robustez às variações de carga. Além disso, ele apresentou uma boa robustez às variações de R_r e R_s em velocidades baixa

e médias e boa robustez às variações de L_m em baixas velocidades. Em velocidades média, ele mostrou-se um pouco sensível às variações de L_m , o que não compromete o acionamento *sensorless*, pois ele é feito na região de fluxo constante, onde este parâmetro não varia. Os mesmos resultados foram obtidos experimentalmente, exceto os resultados em baixas velocidades (que apresentaram uma pequena degradação) e à velocidade nula (que não foram possíveis de se obter). Espera-se, entretanto, que os resultados à velocidade nula e em baixas velocidades melhorem com um melhor ajuste nos controladores.

Capítulo 5

Conclusões Gerais e Propostas de Continuidade

5.1 Conclusões Gerais

Este trabalho apresentou uma nova proposta de observador de estados de sistemas dinâmicos utilizando o algoritmo NFN, com treinamento *on-line*, através da utilização de uma equação de mapeamento entre os estados observados e os estados a serem comparados com os estados medidos.

Foi demonstrado um teorema (Teorema 1) que permite uma escolha adequada de uma equação de mapeamento, dentre as candidatas. Em seguida, foram desenvolvidas expressões válidas para equações de mapeamento que possuam inversa e cujas derivadas (da equação de mapeamento e de sua inversa) sejam diferente de zero. Foi mostrado que estas expressões poderão ser aplicadas no problema de observação de qualquer sistema dinâmico em tempo real que possibilite a obtenção deste tipo de equação de mapeamento.

Foi demonstrada uma expressão para atualização dos pesos com taxa de aprendizado ótima (o que permite a convergência do observador em apenas **um passo de cálculo**) para uma determinada classe de equações de mapeamento. Este resultado torna o observador potencialmente rápido e adequado para aplicações em tempo real, além de não precisar da etapa de treinamento *off-line*. Baseado neste resultado, foram desenvolvidas quatro propostas de observadores de estado: um observador de fluxo de rotor e três observadores de velocidade de rotor para o motor de indução.

Os observadores foram aplicados em um sistema de acionamento de máquina

de indução (cujo tempo de resposta deve ser rápido o suficiente para o satisfatório desempenho do acionamento), para avaliação da proposta.

A utilização de uma taxa de aprendizado ótima garante a convergência do observador em apenas **um passo de cálculo**. Embora tenha sido obtida uma expressão para taxa de aprendizado ótima para uma classe particular de equações de mapeamento (eq. 3.8), pode ser possível obter uma expressão equivalente para outros tipos de equações de mapeamento. Também foi visto a aplicação do observador de fluxos NFN com taxa de aprendizado fixa, tendo sido mostrado ser possível obter bons resultados em processos de observação em tempo real utilizando apenas a eq. 3.7 e uma taxa de aprendizado fixa adequada, obtida heurísticamente através de simulações prévias.

As principais características do observador de fluxo NFN proposto são:

- necessidade das informações de correntes de estator e posição do rotor;
- rápida convergência e alta precisão;
- adaptabilidade às variações da dinâmica do sistema;
- robustez às variações da indutância de magnetização, L_m (e conseqüentemente da indutâncias próprias de rotor, L_r , e de estator, L_s) e às variações de carga;
- baixa sensibilidade às variações da resistência de rotor, R_r ;
- independência da resistência de estator, R_s ;
- bom desempenho numa ampla faixa de velocidade (inclusive à velocidade zero);
- baixo esforço computacional;
- aprendizado em tempo real sem a necessidade de treinamento prévio.

As principais características do observador de velocidade NFN-1 e 2 propostos são:

- necessidade do valor do conjugado eletromagnético, T_e , e do vetor fluxo de rotor, $\vec{\lambda}_r$;
- grande sensibilidade às variações da indutância mútua, L_m e à erros no vetor fluxo de rotor;

- robustez às variações da resistência de rotor, R_r , numa ampla faixa de velocidade;
- robustez às variações de carga numa ampla faixa de velocidade;
- independência da resistência de estator, R_s ;
- rápida convergência e alta precisão;
- adaptabilidade às variações da dinâmica do sistema;
- baixo custo computacional;
- aprendido em tempo real sem a necessidade de treinamento prévio;
- sua equação de atualização de pesos apresenta pontos singulares.

As principais características do observador de velocidade NFN-3 proposto são:

- necessidade do valor do conjugado eletromagnético (T_e), da tensão de estator de eixo alfa ($V_{s\alpha}$), da tensão de estator de eixo beta ($V_{s\beta}$), da corrente de estator de eixo alfa ($I_{s\alpha}$), da corrente de estator de eixo beta ($I_{s\beta}$) e da posição do vetor fluxo de rotor;
- robustez às variações da resistência de rotor, R_r , da resistência de estator, R_s , e às variações de carga numa ampla faixa de velocidade;
- sensibilidade às variações da indutância mútua, L_m (e conseqüentemente das indutâncias próprias de rotor e de estator, L_r e L_s , respectivamente);
- rápida convergência e alta precisão;
- adaptabilidade às variações da dinâmica do sistema;
- baixo custo computacional;
- aprendido em tempo real sem a necessidade de treinamento prévio;
- sua equação de atualização de pesos não apresenta pontos singulares.

5.2 Propostas de Continuidade

Como propostas de continuidade deste trabalho, pode-se citar:

- obtenção de uma expressão para taxa de aprendizado ótima para outras classes de equação de mapeamento (e não apenas para a da classe da eq. 3.8);

-
- estudo da influência da dinâmica dos observadores nos controladores;
 - implementação de controladores mais adequados para atuar em qualquer condição de operação;
 - estudo do efeito da realimentação dos erros de observação no $\hat{\lambda}_r$ NFN e $\hat{\omega}_r$ NFN-3;
 - utilização dos observadores de velocidade NFN-1 e 2 em um acionamento *sensorless*;
 - acréscimo de rotinas de *autocomissionamento* e de *estimação on-line* dos parâmetros da MI;
 - outros tipos de observadores NFN.
-

Bibliografia

- [1] Abbondanti, B. & Brennem, M. B. *Variable Speed induction Motor Drives use Electronic Slip Calculator Based on Motor Voltages and Currents*. IEEE Trans. on Ind. Appl., v. IA-11, n.5, p.483-488, 1975.
 - [2] ABNT, NBR5383. *Máquinas Elétricas Girantes - Máquinas de Indução: Métodos de Ensaio*.
 - [3] Aguirre, L. A. *Notas de Aula da Disciplina Identificação de Sistemas e Estimação de Parâmetros*. Programa de Pós-Graduação em Engenharia Elétrica da UFMG, 1997.
 - [4] Beck, M. & Naunin, D. *A New Method for the Calculation of the Slip Frequency for a Sensorless Speed Control of a Squirrel-Cage Induction Motor*. IEEE Power Electronics Specialist Conference, p.847-854, 1988.
 - [5] Ben-Brahin, L. & Kawamura, A. *A Fully Digitized Field-Oriented Controlled Induction Motor Drive Using Only Current Sensors*. IEEE Trans. Ind. Electron., v.39, n. 3, p.241-249, junho 1992.
 - [6] Ben-Brahin, L. & Kurosawa, R. *Identification of Induction Motor Speed Using Neural Networks*. IEEE PCC, Yokohama, p.689-694, 1993.
 - [7] Blaschke, F. *The principle of Field Orientation as Applied to the New Transvector Closed-Loop System for Rotating Field Machines*. Siemens Review, v. 34, p.217-220, 1972.
 - [8] Boldea, I. Nasar, S. A. *Vector Control of AC Drives*. CRC Press, Flórida, 1992.
 - [9] Bose, B. K. *Power Electronics and AC Drives*. Prentice-Hall Inc., Englewood Cliffs, 1986.
 - [10] Bose, B. K, Simões, M. G., Crecelius, D. R, Rajashekara, K. & Martin, R. *Speed Sensorless Hybrid Vector Controlled Induction Motor Drive*. Proc. IAS, p.137-143, 1995.
 - [11] Bose, B. K. & Patel, N. R. *A Programmable Cascaded Low-Pass Filter-Based Flux Synthesis for a Stator Flux-Oriented Vector-Controlled Induction Motor Drive*. IEE Trans. Ind. Electron., v. 44, n.1, p.140-143, fevereiro 1997.
 - [12] Braga, A. P., Carvalho, A. C. P. L. F., Ludermir, T. B. *Fundamentos de Redes Neurais Artificiais*. XI Escola Brasileira de Computação, 1998.
 - [13] Caminhas, W. M., Takahashi, R. H., Peres, P. L. D. & Tavares, H. M. F. *Observadores de Estados do Motor de Indução com Rejeição de Perturbações Paramétricas*. 1996.
 - [14] Caminhas, Walmir M. *Detecção e Diagnóstico de Falhas em Sistemas Dinâmicos*. Tese de doutorado, FEEC-UNICAMP, São Paulo, SP, Brasil, 1997.
 - [15] Cruz, J. *Identificação de Uma Torre de Retificação de Águas Ácidas Usando Redes Neurais Artificiais*. Belo Horizonte: Escola de Engenharia da UFMG, 1998. 122 p. (Dissertação, Mestrado em Engenharia Elétrica).
 - [16] De Donker, R. W. & Novotny, D. W. *The Universal Field Oriented Controller* IEEE Trans. on Ind. Appl., v. 30, n.1, jan/fev 1994.
-

-
- [17] Degner, M. W. & Lorenz, R. D. *Wide Bandwidth Flux, Position, and Velocity Estimation in AC Machines at any Speed (Including Zero) Using Multiple Saliencies*. European Power Electronics Conference (EPE'97), 1997.
- [18] Filho, B. C. *Notas de Aula da Disciplina Controle de Acionamentos Elétricos*. Programa de Pós-Graduação em Engenharia Elétrica da UFMG, 2000.
- [19] Fitzgerald, A. E., Kingsley Jr., C., Umans, S. D. *Electrical Machinery*. Ed. McGraw-Hill, 5 ed., 1995.
- [20] França, J. L., Borges, S. M., Vasconcellos, A. C. de, Magalhães, M. H. de A. *Manual para Normalização de Publicações Técnico-Científicas*. 3.ed. Minas Gerais (Belo Horizonte): UFMG, 1996. 191p.
- [21] Gheysens, R., Cherif, H. & Poloujadoff, M. *Speed Determination of a Squirrel Cage Induction Motor by Indirect Method*. Proc. of IPEC. p.1137-1143, 1990.
- [22] Gopinath, B. *On the Control of Linear Multiple Input-Output Systems*. The Bell System Technical Journal, vol. 50, n.3, março 1971.
- [23] Haykin, S. *Neural Networks: A Comprehensive Foundation*. 2nd ed., Macmillian, M. Prentice-Hall, New York, 1999.
- [24] Hilairet, M., Auger, F., D. Darengosse. *Two Efficient Kalman Filters for Flux and Velocity Estimation of Induction Motors*. Proc. of Power Electronics Specialist Conference (PESC'00), IEEE, 2000. CD-ROM.
- [25] Hori, Y., Cotter, V. & Kaya, Y. *A Novel Induction Machine Flux Observer and Its Application to a High Performance AC Drive System*. Proc. 10th World Congress on Automatic Control (IFAC'87), v.3, p.355-360.
- [26] Hu, J. & Wu, B. *New Integration Algorithms for Estimating Motor Flux over a Wide Speed Range*. IEE Trans. Power. Electron., v.13, n.5, p.969-977, setembro 1998.
- [27] Hur, N., Hong, K. & Nam, K. *A Robust Adaptive Sensorless Field-Oriented Control Using a Modified Stator Flux Observer*. Proc. of Power Electronics Specialist Conference (PESC'97), IEEE, p.1050-1054, 1997.
- [28] Hurst, K. D., Habetler, T. G., Griva, G. & Profumo, F. *Speed Sensorless Field-Oriented Control of Induction Machines Using Current Harmonic Spectral Estimation*. In proc. of IEEE Industry Application Society Annual Meeting , pp. 601-607, 1994.
- [29] IEEE. *IEEE Standard Test Procedure for Polyphase Induction Motors and Generators*. IEEE Standards Boards, 1992.
- [30] Ishida, M. & Iwata, K. *A New Slip Frequency Detector of an Induction Motor Utilizing Motor Slot Harmonics*. International Semiconductor Power Conversion Conference, p. 408-415, 1982.
- [31] Jang, J.-S. R, Sun, C.-T. & Mizutani, E. *Neuro-Fuzzy and Soft Computing - a Computational Approach to Learning and Machine Intelligence*, Prentice-Hall, 1997.
- [32] Jansen, P. L. & Lorenz, R. D. *A Physically Insightful Approach to the Design and Accuracy Assesment of Flux Observers for Field Oriented Induction Machine Drives*. Proc. of IEEE Industry Application Society Annual Meeting , pp. 570-577, 1992.
-

-
- [33] Jansen, P. L. & Lorenz, R. D. *Accuracy Limitations of Velocity and Flux Estimation in Direct Field Oriented Induction Machines*. European Power Electronics Association (EPE '93), 1993.
- [34] Jansen, P. L., Lorenz, R. D. & Novotny, D. W. *Observer-Based Direct Field Orientation: Analysis and Comparison of Alternative Methods*. IEEE Trans. on Ind. Appl., v.30, n.4, p. 945-953, julho/agosto 1994.
- [35] Jansen, P. L. & Lorenz, R. D. *Tranducerless Position and Velocity Estimation in Induction and Salient AC Machines*. IEEE Trans. on Ind. Appl., v.31, n.2, p.240-247, março/abril 1995.
- [36] Joetten, R. & Maeder, G. *Control Methods for Good Dynamic Performance Induction Motor Drives Based on Current and Voltage as Measuremed Quantities*. IEEE Trans. on Ind. Appl. v.1A-19, p.:356-363, maio/junho 1983.
- [37] Kartalopoulos, Stamatios V. *Understanding Neural Networks and Fuzzy Logic - Basic Concepts and Applications*. IEEE PRESS. 1996.
- [38] Kenneth, K., Liew, A.-C. & Lipo, T. A. *New Observer-Based DFO Scheme for Speed Sensorless Field-Oriented Drives for Low-Zero-Speed Operation*. IEEE Trans. on Power. Electr. v.13, n.5, p.:959-968, agosto 1998.
- [39] Kerkman, R. J., Skibinski, G. L., Schlegel, D. W. *AC Drives: Year 2000 (Y2K) and Beyond*. Proc. APEC'99. CD-ROM, 1999.
- [40] Khambadkone, A. M. & Holtz, J. *Vector-Controlled Induction Motor Drive with a Self-Commissioning Scheme*. IEEE Trans. on Ind. Elec., v.38, n.5, p.:322-327, Outubro 1991.
- [41] Kim, Y.-R., Sul, S.-K. & Park, M.-H. *Speed Sensorless Vector Control of Induction Motor Using Extended Kalman Filter*. IEEE Trans. on Ind. Appl., v.30, n.5, p. :1225-1233, setembro/outubro 1994.
- [42] Klir, George & Folger, T. A. *Fuzzy Sets, Uncertainty and Information*. Prentice-Hall International, 1988.
- [43] Kosko, B. *Fuzzy Systems as Universal Approximators*. IEEE Int. Conf. on Fuzzy Systems, 1153-1162, 1992.
- [44] Kubota, H. et. al. *A New Inverter-Fed Induction Motor Drive with Microprocessor-Based State Observer for Estimating Torque*. IEEE IECON'84 Conference Record, pp. 857-862, 1984.
- [45] Kubota, H., Matsuse, K. & Nakano, T. *New Adaptive Flux Observer of Induction Motor for Wide Speed Range Motor Drives*. Proc. IECON'90. p.921-926, 1990.
- [46] Kubota, H., Matsuse, K. & Nakano, T. *DSP-Based Speed Adaptive Flux Observer of Induction Motor*. IEEE Trans. on Ind. Appl., v.29, n.2, p.344-348, março/abril 1993.
- [47] Lacerda, W. S. *Sistema de Desenvolvimento para Acionamentos Elétricos - Aplicação ao Controle de Posição de uma Máquina Síncrona a Imãs Permanentes*. Dissertação de mestrado, PPGEE-UFG, 1994.
- [48] Landim, R. P., Menezes, B. R. de, Oliveira, J. C. R. de, Aguirre, L. A.. & Caminhas, W. M. *Observador de Fluxo para Máquinas de Indução Utilizando uma Rede Neo-Fuzzy-Neuron-Generalizada*. Anais do Congresso Brasileiro de Automática (CBA'98), v.4, p.1307-1312, 1998.
-

-
- [49] Landim, R. P., Menezes, B. R., Silva, S. R. & Caminhas, W. M. *A Neo-Fuzzy-Neuron With Real Time Training Applied to Flux Observer for an Induction Motor*. Anais do V Simpósio Brasileiro de Redes Neurais (SBRN'98) - IEEE Computer Society, v.1, p.67-72, 1998.
- [50] Landim, R. P., Menezes, B. R., Silva, S. R. & Caminhas, W. M. *Nonlinear System Identification Using a Neo-Fuzzy-Neuron Algorithm: Electrical Drive Application*. International Journal of Neural Systems, v.9, n.3, p.211-217, 1999.
- [51] Landim, R. P., Menezes, B. R., Silva, S. R. & Caminhas, W. M. *Estimação de Estados do Motor de Indução Utilizando uma Rede Neuro-Fuzzy com Aprendizado em Tempo Real*. I Semana de Pós-Graduação da UFMG, v.2, p.112, 1999.
- [52] Landim, R. P., Menezes, B. R., Parma, G. G., Silva, S. R. & Caminhas, W. M. *Speed Sensorless Field-Oriented Control of Induction Machines Using a Real Time Neo-Fuzzy-Neuron Algorithm*. In anais do Industry Applications Conference (INDUSCON'00). IEEE-sul, p.81-86, 2000. CD-ROM.
- [53] Landim, R. P., Menezes, B. R., Silva, S. R. & Caminhas, W. M. *On-Line Neo-Fuzzy-Neuron State Observer*. In anais do VI Simpósio Brasileiro de Redes Neurais (SBRN'00). IEEE Computer Society, v.1, p.196-201, 2000.
- [54] Levi, E., Wang, M. *A Speed Estimator for Sensorless Vector Control of Induction Machines in the Field Weakening Region*. Proc. of Power Electronics Specialist Conference (PESC'00), IEEE, 2000. CD-ROM.
- [55] Lipo, T.A. & Novotny, D.W. *Dynamics and Control of Induction Motor Drives*. Clarendon Press, 1996.
- [56] Lin, C.-J. *SISO Nonlinear System Identification Using a Fuzzy-Neural Hybrid System*. International Journal of Neural Systems. v.8, n.3, p.325-337, 1997.
- [57] Lorenz, R. D. *Future Trends in Power Electronic Control of Drives: Robust, Zero Speed Sensorless Control and New Standard Approaches for Field Orientation*. Proc. of IEE, IPEC, Yokohama, p. 240-247, mar/abr 1995.
- [58] LORENZ, R. D., LIPO, T. A., NOVOTNY, D. W. Motion Control with Induction Motors. In: BOSE, B. K. *Power Electronics and Variable Frequency Drives - Technology and Applications*. IEEE PRESS. 1997. p 209-276.
- [59] Luemberger, D. G. *Observers for Multivariable Systems*. IEEE Trans. on Automatic Control, v.AC-11, n.2, p.190-197, abril 1966.
- [60] Luemberger, D. G. *An introduction to Observers*. IEEE Trans. on Autom. Control v.16, n.6, dezembro 1971.
- [61] Luiz, A.-S. A. *Estudo e Implementação de Observadores de Fluxo para Máquinas de Indução*. Dissertação de mestrado, PPGEE-UFMG, 1996.
- [62] Luiz, A.-S. A., Silva, S. R. & Menezes, B. R. *Analysis and Implementation of Flux Observers for Induction Machine*. IECON'97, v.32, p.494-499, 1997.
- [63] Mateus, G. R. e Luna, H. P. L. *Programação Não-Linear*. V Escola de Computação, BH - MG, 1986.
- [64] Marchesoni, M., Segarich, P. & Soressi, E. *A Simple Approach to Flux and Speed Observation in Induction Motor Drives*. IEEE Trans. on Ind. Electr. v.44, n.40, p.528-535, agosto
-

1997.

- [65] Marino, P., Milano, M. & Vasca, F. *Linear Quadratic State Feedback and Robust Neural Network Estimator for Field-Oriented-Controlled Induction Motors*. IEEE Trans. on Ind. Electr. v.46, n.1, p.150-161, fevereiro 1999.
- [66] Mehrotra, P., Quaicoe, J. E. & Venkatesan, R. *Development of an Artificial Neural Network Based Induction Motor Speed Estimator*. Proc. of Power Electronics Specialist Conference (PESC'96), IEEE, p.682-688, 1996.
- [67] Minami, K., M. V. Reyes & G. C. Verghese. *Multi-Stage Speed and Parameter Identification for Vector Control of Induction*. Proc. of Power Electronics Specialist Conference (PESC'91), IEEE, p.596-604, 1991.
- [68] Moreira, J. C. & Lipo, T. A. *Direct Field Orientation Control Using Third Harmonic Component of the Stator Voltage*. Proc. ICEM, p.1237-1242, Cambridge, MA, 1990.
- [69] Munem, M. A., Foulis, D. J. *Calculus with Analytic Geometry*, Worth Publishers Inc., New York, New York, 1978.
- [70] Nestli, T. F. e Nilsen, R. *Evaluation and Comparison of Predictor Models for Rotor Flux Calculation in Induction Motors*. Proc. of Power Electronics Specialist Conference (PESC'94), IEEE, Taiwan, p.729-737, 1994.
- [71] Neves, F. A. S., Menezes, B. R & Silva, S. R. *A Deadbeat Torque and Flux Field Oriented Controller for Induction Motor Drives*. Anais do XII Congresso Brasileiro de Automática (CBA'98), v.4 p.2243-2247, Uberlândia-MG-Brasil, 1998.
- [72] Neves, F. A. S. *Acionamento de Alto Desempenho com Máquinas de Indução Alimentadas em Tensão: Desenvolvimento de Novas Estratégias de Controle*. Belo Horizonte: Escola de Engenharia da UFMG, 1999. 234 p. (Tese, Doutorado em Engenharia Elétrica).
- [73] Nunes, W. e Gomide, F. A. C. *Previsão de Temperaturas para Alimentos em Congelamento*. Relatório Técnico do Projeto RHAE-CNPq/Multibras - Processo 16081-96. DCA / FEEC / Unicamp.
- [74] Norton, J. P. *An Introduction to Identification*. Academic Press, 1986.
- [75] Ohtani, T., Takada, N. & Tanaka, K. *Vector Control of Induction Motor Without Shaft Encoder*. IEEE Trans. on Ind. Appl., v.28, n.1, p.157-164, janeiro/fevereiro 1992.
- [76] Parma, G.G., Menezes, B. R., Aguirre, L. A., Oliveira, J. C. R. & Braga, A. P. *Observador de Fluxo de Estator para Motores de Indução Usando Treinamento on-line Baseado na Teoria de Sistema de Estrutura Variável*. Anais do XII Congresso Brasileiro de Automática (CBA'98), v.4, p.1301-1306, Uberlândia-MG-Brasil, 1998.
- [77] Parma, G.G. & Menezes, B. R. de. *Bancada Experimental para Acionamento de Máquina de Indução*. Relatório Técnico, UFMG, Belo Horizonte, Brasil, 1998.
- [78] Parma, G. G., Menezes, B. R. & Braga, A. P. *A New Approach to Measure the PWM Voltage Applied to Electrical Machines*. Anais do Industry Applications Conference (INDUSCON'00). IEEE-sul, p.617-622, 2000. CD-ROM.
- [79] Peng, F.-Z. & Fukao, T. *Robust Speed Identification for Speed-Sensorless Vector Control of Induction Motors*. IEEE Trans. on Ind. Appl., v.30, n.5, p.1234-1240, setembro/outubro 1994.

-
- [80] Pedrycz, W. *Computational Intelligence - An Introduction.*, CRC Press LLC, 1998.
- [81] Peterson, B. *Induction Machine Speed Estimation: Observations on Observers.* Tese de doutorado, Industrial Electrical Engineering and Automation (IEA), Lund Institute of Technology (LTH), 1996.
- [82] Profumo, F., Griva, G., Pastorelli, M. & Moreira, J. C. *Universal Field Oriented Controller with Indirect Speed Sensing Based on the Saturation Third Harmonic Voltage.* Proc. of Power Electronics Specialist Conference (PESC'93), IEEE, p.948-955, 1993.
- [83] Rajashekara, K., Kawamura, A. & Matsuse, K. *Sensorless Control of AC Motor Drives : Speed and Position Sensorless Operation.* IEEE Press, 1996.
- [84] Reyes, M. V., Minami, K & Verghese, G. C. *Recursive Speed and Parameter Estimation for Induction Machines.* Proc. IAS, p.607-611, 1989.
- [85] Ribeiro, L. A. de S., Jacobina, C. B. & Lima, A. M. N. *Estimação da Velocidade da Máquina Assíncrona em Acionamentos Estáticos-Parte I: Revisão e Classificação.* Anais do Congresso Brasileiro de Eletrônica de Potência (COBEP'97).
- [86] Ribeiro, L. A. de S., Jacobina, C. B. & Lima, A. M. N. *Estimação da Velocidade da Máquina Assíncrona em Acionamentos Estáticos-Parte II: Estimação com o Modelo Corrente-Tensão.* Anais do Congresso Brasileiro de Eletrônica de Potência (COBEP'97).
- [87] Ritter, C. M. *Controle Vetorial sem Sensor de Velocidade do Motor de Indução.* Dissertação de mestrado, PPGEE-UFMG, 1997.
- [88] Sangwongwanich, S., Yonemoto, T & Okuma, S. *Time Domain Characteristics of Sliding Observer for Flux Estimation of Induction Motor and Its Implementation.* Proc. of Power Electronics Specialist Conference (PESC'91), IEEE, p.592-595, 1991.
- [89] Schauder, C. *Adaptive Speed Identification for Vector Control of Induction Motors Without Rotational Transducers.* IEEE Trans. on Ind. Appl., v.28, n.5, p.1054-1061, setembro/outubro 1992.
- [90] Schroedl, M. & Wieser, R. S. *EMF-Based Rotor Flux Detection in Induction Motors Using Virtual Short Circuits.* IEEE Trans. on Ind. Appl., v.34, n.1, jan/fev 1998.
- [91] Shin, M-H, Hyun, D-S, Cho, S-B & Choe, S-Y. *An Improved Stator Flux Estimation for Speed Sensorless Stator Flux Orientation Control of Induction Motors.* Proc. of Power Electronics Specialist Conference (PESC'98), IEEE, 1998.
- [92] Silva, K. F. da, Lima, A. M. N. & Jacobina, C. B. *Estimação Estocástica de Fluxo Magnético em Máquinas Assíncronas Utilizando Filtro de Kalman.* Anais do III Seminário de Eletrônica de Potência, SOBRAEP/UFSC, p.42-48, 1990.
- [93] Silva, S. R. *Sistemas Elétricos de Alto Desempenho a Velocidade Variável: Estratégias de Controle e aplicações.* Tese para Concurso de Professor Titular, DEE-UFMG, 1995.
- [94] Simões, M. G. & Bose, B. K. *Neural Network Based Estimation of Feedback Signals for a Vector Controlled Induction Motor Drive.* IEEE Trans. on Ind. Appl., v.31, n.3, p.620-629, 1995.
- [95] Soares, G. L. *Algoritmos Genéticos: Estudo, Novas Técnicas e Aplicações.* Dissertação de Mestrado, PPGEE-UFMG, 1997.
-

-
- [96] Stopa, M. M. *Controle do Motor de Indução por Orientação de Campo: Uma Implementação Utilizando um Conversor PWM Reversível*. Dissertação de mestrado, PPGEE-UFMG, 1997.
- [97] Sumner, M. & Asher, G. M. *Autocommissioning for Voltage-Referenced Voltage-Fed Vector Controlled Induction Motor Drives*. IEE Proceedings, v.140, n.3, p.187-200, Maio 1993. Pt.B.
- [98] Tajima, H. & Hori, Y. *Speed Sensorless Field-Oriented Control of the Induction Machine*. IEEE Trans. on Ind. Appl., v.29, n.1, p.175-180, janeiro/fevereiro 1993.
- [99] Theocharis J. & Petridis, V. *Neural Network Observer for Induction Motor Control*. IEEE Control Systems Magazine, 1994.
- [100] Tsoukalas, L. H. e Uhrig, R. E. *Fuzzy Neural Approaches in Engineering*. John Wiley & Sons, 1997.
- [101] Vas, P. *Vector Control of AC Machines*, Oxford University Press, 1990.
- [102] Vas, P. *Parameter Estimation, Condition Monitoring and Diagnosis of Electrical Machines*. Clarendon Press-Oxford, 1993.
- [103] Vas, P. e Stronach, A. F. *Present and Future of Drives, Sensorless and Artificial Intelligence Applications*. European Power Electronics (EPE'97), 1997.
- [104] Vas, P. e Stronach, A. F., Rashed M, Neuroth, M. *DSP Implementation of AI-Based Medium Performance Sensorless Induction Motor Drives*. European Power Electronics (EPE'99), 1999. CDROM.
- [105] Venkataraman, R., Ramaswami, B. & Holtz, J. *Electronic Analog Slip Calculator for Induction Motor Drives*. IEEE Trans. on Ind. Electr. and Control Instrumentation, v.IECI-27, n.2, p.110-116, 1980.
- [106] Verghese, G. C. & Sanders, S. R. *Observers for Flux Estimation in Induction Machines*. IEEE Trans. Ind. Electron., v.35, n.1, p.:85-94, 1988.
- [107] Xu, X. & Novotny, D. W. *Implementation of Direct Stator Flux Orientation Control on a Versatile DSP Based System*. IEEE Trans. on Ind. Appl., v.27, n.4, p.694-700, julho/agosto 1991.
- [108] Yamakwa, T.; Uchino, E.; Miki, T. & Kusanagi. *A Neo Fuzzy Neuron and its Applications to System Identification and Predictions to System Behavior*. Proc. of the 2nd IZUKA-Japan, p.477-483, 1994.
- [109] Yong, S.-I., Choi, J.-W. & Sul, S.-K. *Sensorless Vector Control of Induction Machine Using Frequency Current Injection*. Conf. Rec. IAS, p.503-508, Denver, Colorado, USA outubro 1994.
- [110] Zhen, L. & Xu, B. *A Mutual MRAS Identification Scheme for Position Sensorless Field Orientation Control of Induction Machines*. In Conf. Rec. IAS, 159-165, 1995.
- [111] Zinger, D., Profumo, F., Lipo, T. A. & Novotny, D. W. *A Direct Field-Oriented Controller for Induction Motor Drives Using Tapped Stator Windings*. Proc. of Power Electronics Specialist Conference (PESC'98), IEEE, p.855-861, 1998.
-

Apêndice A

Dados e Parâmetros do Sistema

A.1 Máquina de Indução

Os valores de placa foram fornecidos pelo fabricante, e os parâmetros da máquina foram obtidos a partir de ensaios em regime permanente e transitório de acordo com [2], [19] e [29].

A.1.1 Valores de Placa

- Potência: 2 cv;
 - Tensão: 220/380 V;
 - Corrente: 6,5/3,8 A;
 - Freqüência: 60 Hz;
 - Velocidade: 1715 rpm;
 - Fator de Serviço: 1,15;
 - Regime de Serviço: 1;
 - Classe de Isolamento: B;
 - Grau de Proteção: IP 54;
 - I_p/I_n : 6,3;
 - Categoria: N.
-

A.1.2 Valores dos Parâmetros

- Resistência do estator (R_s): 3,85 Ω ;
- Indutância de dispersão do estator (L_{ls}): 0,00853 H;
- Resistência do rotor (R_r): 3,77 Ω ;
- Indutância de dispersão do rotor (L_{lr}): 0,01273 H;
- Indutância de magnetização (L_m): 0,23711 H;
- Coeficiente de perdas rotacionais (B): 0,00147 N.m.s;
- Momento de inércia (J): 0,00673 N.m.s²;
- Constante de tempo mecânica (τ_m): 4,58s;
- Constante de tempo de estator (τ_s): 0,06s;
- Constante de tempo de rotor (τ_r): 0,06s.

A.2 Máquina de Corrente-Contínua

A.2.1 Valores de Placa

- Potência: 2 cv;
- Tensão de armadura: 150 V;
- Corrente de armadura: 10,5 A;
- Tensão de campo: 150 V;
- Corrente de campo: 1,0 A;
- Velocidade: 1750 rpm;
- Resistência de campo (20⁰ C): 107,5 Ω ;
- Fator de Serviço: 1;
- Regime de Serviço: cont;
- Classe de Isolamento: F;
- Grau de Proteção: IP 23.

Apêndice B

Modelo da Máquina de Indução

A Máquina de Indução (MI) pode ser descrita pelas seguintes equações vetoriais, considerando o sistemas de eixos dq girantes à velocidade arbitrária ω_e [101]:

Equações de tensão:

$$\vec{V}_s^e = R_s \cdot \vec{I}_s^e + \frac{d\vec{\lambda}_s^e}{dt} + j \cdot \omega_e \cdot \vec{\lambda}_s^e \quad (\text{B.1})$$

$$\vec{0}^e = R_r \cdot \vec{I}_r^e + \frac{d\vec{\lambda}_r^e}{dt} + j \cdot (\omega_e - \omega_r) \cdot \vec{\lambda}_r^e \quad (\text{B.2})$$

Equações de enlace de fluxo:

$$\vec{\lambda}_s^e = L_s \cdot \vec{I}_s^e + L_m \cdot \vec{I}_r^e \quad (\text{B.3})$$

$$\vec{\lambda}_r^e = L_r \cdot \vec{I}_r^e + L_m \cdot \vec{I}_s^e \quad (\text{B.4})$$

Equações de conjugado eletromagnético

$$\left(\frac{2}{P}\right) \cdot J \cdot \frac{d\omega_r}{dt} = T_e - T_r = T_e - \left[T_c + \left(\frac{2}{P}\right) \cdot B \cdot \omega_r \right] \quad (\text{B.5})$$

$$T_e = \left(\frac{3}{2}\right) \cdot \left(\frac{P}{2}\right) \cdot \text{Im}\{\vec{\lambda}_s^{e*} \cdot \vec{I}_s^e\} = \left(\frac{3}{2}\right) \cdot \left(\frac{P}{2}\right) \cdot \left(\frac{L_m}{L_r}\right) \text{Im}\{\vec{\lambda}_r^{e*} \cdot \vec{I}_s^e\} \quad (\text{B.6})$$