

Felipe Angelo Correia dos Santos

**Sistema *Neuro-Fuzzy* aplicado ao Controle de Motores de
Indução Trifásicos**

Dissertação apresentada ao Instituto Federal de Educação, Ciência e Tecnologia de São Paulo, sendo parte dos requisitos para obtenção do título de Mestre Profissional em Automação e Controle de Processos.

Orientador: Prof. Dr. Ênio Carlos Segatto

São Paulo

2016

S235s Santos, Felipe Angelo Correia dos.
Sistema Neuro-Fuzzy aplicado ao controle de motores de
indução trifásicos / Felipe Angelo Correia dos Santos. São Paulo:
[s.n.], 2016.
112 f.: il.

Orientador: Prof. Dr. Ênio Carlos Segatto.

Dissertação (Mestrado Profissional em Automação e Controle
de Processos) - Instituto Federal de Educação, Ciência e
Tecnologia de São Paulo, IFSP, 2016.

1. Fuzzy 2. Motores de indução trifásicos 3. Controle
vetorial 4. Controle escalar 5. Neuro-Fuzzy I.
Instituto Federal de Educação, Ciência e Tecnologia de São Paulo.
II. Título

CDU 681.0

ATA DE EXAME DE DEFESA DE DISSERTAÇÃO

Nome do Programa: **Mestrado Profissional em Automação e Controle de Processos**

Nome do(a) Aluno(a): Felipe Angelo Correia dos Santos

Nome do(a) Orientador(a): Prof. Dr. Ênio Carlos Segatto

Nome do(a) Coorientador(a):

Título do Trabalho: "Sistema *Neuro-Fuzzy* aplicado ao controle de motores de indução trifásicos"

Abaixo o resultado de cada participante da Banca Examinadora

Nome completo dos Participantes Titulares da Banca	Sigla da Instituição	Aprovado / Não Aprovado
Prof. Dr. Ênio Carlos Segatto – Orientador	IFSP – SPO	APROVADO
Prof. Dr. Edmarcio Antonio Belati – Membro Externo	UFABC	APROVADO
Prof. Dr. Cesar da Costa – Membro Interno	IFSP – SPO	APROVADO
Nome completo dos Participantes Suplentes da Banca	Sigla da Instituição	Aprovado / Não Aprovado
Profª Drª Patrícia Teixeira Leite – Membro Externo	UFABC	
Prof. Dr. Carlos Frajuca – Membro Interno	IFSP – SPO	

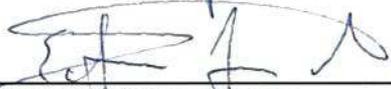
Considerando-o: APROVADO
 NÃO APROVADO

Assinaturas

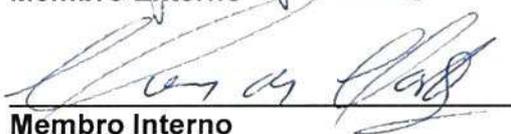
São Paulo, 28 de março de 2016



Presidente da Banca



Membro Externo



Membro Interno

Observações:

“Dedico este trabalho aos meus pais, Afonso e Linalva”

Agradecimentos

A Deus, que tudo provê, por possibilitar as condições para a conclusão de mais esta etapa.

À minha família, pelo apoio incondicional.

Ao prof. Dr. Ênio Carlos Segatto pela orientação e dedicação. Sempre paciente e disposto a colaborar para a conclusão deste trabalho.

Ao Instituto Federal de Educação, Ciência e Tecnologia de São Paulo, por me receber mais uma vez como aluno, permitindo meu desenvolvimento como cidadão e profissional.

Aos funcionários da secretaria da pós-graduação, pela dedicação e profissionalismo.

E a todos que, direta ou indiretamente, contribuíram para a conclusão deste trabalho.

**“Em Ti me tenho apoiado desde meu nascimento;
do ventre materno Tu me tiraste, Tu és motivo
para os meus louvores constantes”**

SALMO, 71-6

**O guerreiro de fé nunca gela, não agrada o injusto e não amarela, o rei dos reis
foi traído e sangrou nessa terra, mas morrer como um homem é o prêmio da
guerra. Mas ó, conforme for se precisar, afogar no próprio sangue assim será,
nosso espírito é imortal sangue do meu sangue, entre o corte da espada e o
perfume da rosa, sem menção honrosa, sem massagem, a vida é loka nêgo,
nela eu tô de passagem...**

RACIONAIS MC'S

Resumo

Este trabalho tem como proposta apresentar o projeto e a aplicação dos controladores *neuro-fuzzy adaptativos* (ANFIS) nos sistemas de controle para motores de indução trifásicos (MIT). O intuito foi obter um sistema de controle capaz de contornar as não-linearidades apresentadas pelo motor de indução e melhorar seu comportamento em regime dinâmico, regime permanente e sua eficiência energética numa ampla faixa de operação. A estrutura de controle aqui apresentada faz uso das equações em regime permanente do MIT para o treinamento do ANFIS que tem como tarefa determinar a tensão e a frequência a serem impostas ao estator do motor. Isso traz a vantagem de mapear o comportamento do MIT sem fazer uso das equações de regime dinâmico e das transformadas de coordenadas, como é o caso do controlador vetorial por orientação de campo (FOC), reduzindo significativamente a complexidade de implementação do controlador e o esforço computacional necessário sem perda de desempenho. Para melhorar o desempenho da estrutura de controle em regime dinâmico foi utilizado um sistema que atua em conjunto com o ANFIS monitorando continuamente a velocidade do rotor de forma a compensar as variações de velocidade. Este sistema de controle garante o escorregamento nominal do motor para qualquer ponto de trabalho dentro de sua faixa de operação, fazendo o MIT trabalhar sempre em condição de máxima eficiência energética. Simulações para análise do desempenho e validação da estrutura de controle foram realizadas no programa *MatLab/Simulink*.

Palavras chaves: Motores de indução trifásicos, controlador vetorial, controlador *neuro-fuzzy*, controle escalar.

Abstract

This work presents the design and the implementation of adaptive neuro-fuzzy controllers (ANFIS) in control systems for induction motors. The objective was to obtain a control system able to circumvent nonlinearities presented by the induction motor and improve its behavior in dynamic regime, permanent regime and energy efficiency in a wide operating range. The control structure presented here makes use of the permanent regime equations of the MIT for the ANFIS training which is tasked to determine the voltage and frequency to be imposed on the motor stator. This has the advantage of mapping the MIT behavior without making use of the dynamic regime equations and the transformed coordinates, as is the case for the vector field oriented controller (FOC), reducing the complexity of the implementation and control effort computing required without loss of performance. To improve the performance of the control system in dynamic regime, was utilized a system that operates in conjunction with the ANFIS, monitoring the rotor speed to compensate the speed variations. This control system ensures the motor rated slip for any operating speed and any load request, making the MIT works always in maximum energy efficiency condition. Simulations to analyze the performance and validation of the control structure were carried out in *Matlab/Simulink* program.

Keywords: Three-phase induction motors, vector control, neuro-fuzzy, scalar control.

Lista de Figuras

Figura 1 - Circuito trifásico do estator do MIT acoplado magneticamente	13
Figura 2 - Circuito trifásico do rotor do MIT acoplado magneticamente.....	16
Figura 3 - Representação das forças magnetomotrizes	19
Figura 4 - Representação gráfica da transformada $\alpha\beta \rightarrow dq$	22
Figura 5 - Estrutura do Bloco PI	30
Figura 6 - Estimador <i>Sensorless</i>	31
Figura 7 - Estrutura Geral do Sistema de Controle PI	32
Figura 8 - Formas de Onda, Corrente do Estator I_s (A), e Modulação PWM.....	33
Figura 9 - Lugar geométrico das raízes da função de transferência do MIT.....	37
Figura 10 - Curva de resposta da velocidade do motor de indução.....	38
Figura 11 - Diagrama do Sistema de Controle para MIT.	40
Figura 12 - Lugar geométrico das raízes da Função de Transferência da Malha de Controle indicando o cancelamento do pólo mecânico com o zero do controlador PI.	41
Figura 13 - Curva de resposta ao arranque utilizando o método de sintonização do controlador PI proposto em (PALMA, 2008)	42
Figura 14 - Detalhe do sobressinal obtido com o método de sintonização do controlador PI proposto em (PALMA, 2008).	42
Figura 15 - Sistema de Controle para MIT construído para levantamento dos dados de treinamento do ANFIS.....	44
Figura 16 - Detalhe do momento da partida do motor com sistema de fase não mínima, rotação de 50 rpm no sentido contrário.....	46
Figura 17 - Curvas de arranque do MIT:	48
Figura 18 - Estrutura do sistema de controle baseado em <i>fuzzy</i>	50
Figura 19 - Implementação feita no MatLab do controlador <i>fuzzy</i>	51
Figura 20 - Implementação feita no MatLab da variável de entrada “Erro de Velocidade”	52

Figura 21 - Implementação feita no MatLab da variável de entrada “Variação do Erro de Velocidade”	53
Figura 22 - Implementação das regras <i>Fuzzy</i> feita no MatLab	54
Figura 23 - Implementação feita no MatLab da variável de saída “Ganho de Tensão”	55
Figura 24 - Curva de superfície do controlador <i>Fuzzy</i> projetado	56
Figura 25 - Detalhe do sobressinal obtido com o controlador do tipo PI e o controlador <i>fuzzy</i>	57
Figura 26 - Curvas de resposta ao arranque obtidas com o controlador do tipo PI e o controlador <i>fuzzy</i>	58
Figura 27 - Curvas de arranque do MIT com controle <i>fuzzy</i> :	59
Figura 28 - Curvas de resposta a variação de carga ao eixo do motor obtidas com o controlador do tipo PI e o controlador <i>fuzzy</i>	60
Figura 29 - Exemplo de funções de pertinência. Conjunto A_1 e A_2	65
Figura 30 - Inferência <i>fuzzy</i> utilizando operado mín..	67
Figura 31 - Arquitetura geral de um sistema <i>fuzzy</i>	68
Figura 32 - Representação de uma função através de um modelo <i>fuzzy</i> paramétrico.....	72
Figura 33 - Inferência <i>fuzzy</i> paramétrica.....	72
Figura 34 - Estrutura de controlador <i>neuro-fuzzy</i> de duas entradas	74
Figura 35 - Estrutura do controle <i>neuro-fuzzy</i> proposto.....	79
Figura 36 - Curva de superfície gerada a partir dos dados de treinamento	82
Figura 37 - Funções de pertinência para a variável “Frequência (Hz)”	84
Figura 38 - Funções de pertinência para a variável “Torque (Nm)”	85
Figura 39 - Metodologia para desenvolvimento do sistema <i>neuro-fuzzy</i>	87
Figura 40 - Curvas de resposta transitória de partida à 30Hz.....	91
Figura 41 - Detalhe das curvas de resposta transitória de partida à 30Hz.	91
Figura 42 - Curva de resposta transitória de partida com imposição de tensão extra na partida pelo sistema de controle <i>neuro-fuzzy</i>	93

Figura 43 - Detalhe da resposta transitória de partida com imposição de tensão extra na partida pelo sistema de controle <i>neuro-fuzzy</i>	94
Figura 44 - Curvas de resposta transitória de partida à 20Hz.....	95
Figura 45 - Detalhe das curvas de resposta transitória de partida à 20Hz.	96
Figura 46 - Curvas de resposta transitória de partida à 40Hz.....	97
Figura 47 - Detalhe das curvas de resposta transitória de partida à 40Hz.	97
Figura 48 - Curvas de resposta transitória ao degrau de carga.....	99
Figura 49 - Detalhe das curvas de resposta transitória ao degrau de carga.	100
Figura 50 - Detalhe do erro em regime do sistema de controle <i>neuro-fuzzy</i>	101
Figura 51 - Detalhe das curvas de resposta transitória ao degrau com variação de carga em $\pm 50\%$	102
Figura 52 - Curvas de resposta transitória de carga em rampa crescente e decrescente	103
Figura 53 - Detalhe da curva de resposta transitória de carga em rampa do controlador <i>neuro-fuzzy</i>	104
Figura 54 - Curva de resposta transitória de velocidade em degrau crescente e decrescente.	105
Figura 55 - Implementação feita no MatLab/Simulink do controlador <i>fuzzy</i>	112
Figura 56 - Implementação feita no MatLab/Simulink do controlador <i>neuro-fuzzy</i>	113

Lista de Tabelas

Tabela 1 - Agrupamento dos dados de treinamento para o controlador <i>Neuro-Fuzzy</i>	81
--	----

Lista de Siglas e Abreviaturas

MIT	Motor de Indução trifásico
CC	Corrente Contínua
ANFIS	<i>Adaptative Neuro-Fuzzy Inference System</i>
IA	Inteligência Artificial
PWM	<i>Pulse Width Modulation</i>
RNA	Redes Neurais Artificias
FOC	<i>Field Oriented Control</i>
DTC	<i>Direct Torque Control</i>
ADALINE	<i>Adaptative Linear Neuron</i>
SVM	<i>Space Vector Modulation</i>
FEK	Filtro Extendido de Kalman
V/f	Relação tensão frequência
Ψ_{qr}	Fluxo do rotor no eixo de quadratura
Ψ_{dr}	Fluxo do estator no eixo direto
L_m	Indutância de magnetização do entreferro
L_r	Indutância de rotor

i_{qs}	Corrente do estator no eixo de quadratura
ω_{sl}	Frequência de escorregamento
R_r	Resistência do rotor
I_s	Corrente do estator
τ_r	Constante de tempo do rotor
τ_m	Constante de tempo mecânico da carga
Ψ_m	Fluxo de magnetização do entreferro
FPGA	<i>Field Programmable Gate Array</i>
ASIC	<i>Application Specific Integrated Circuits</i>
DSP	<i>Digital Signal Processor</i>

Sumário

1	Introdução.....	1
	1.1 Motivação e Relevância.....	1
	1.2 Proposta e Justificativa.....	3
	1.3 Revisão Bibliográfica: Sistemas Baseados em Inteligência Artificial para Controle de MIT.....	5
	1.4 Organização do Texto.....	10
2	Motor de Indução.....	11
	2.1 Introdução.....	11
	2.2 Princípios da Modelagem do MIT.....	12
	2.2 1 Sistema de Coordenadas 123.....	12
	2.2 2 Sistema de Coordenadas $\alpha\beta 0$	18
	2.2 3 Sistema de Coordenadas dq	21
3	Estudo e Implementação Utilizando Técnicas Convencionais de Controle para MIT e Análise da Viabilidade da Proposta.....	27
	3.1 Introdução.....	27
	3.2 Modelo para Determinação dos Dados para Treinamento.....	28
	3.2.1 Sistema de Controle PI.....	29
	3.2.2 Estimção de Velocidade <i>Sensorless</i>	31
	3.2.3 Modulador PWM Trifásico.....	32
	3.3 Análise e Modelagem do Sistema de Controle.....	34
	3.3.1 Análise de Estabilidade do MIT.....	34
	3.3.2 Projeto do Controlador PI de Velocidade.....	39
	3.4 Análise da Assintonia.....	45
	3.4.1 Sensibilidade à Variação de Carga ao Eixo do Motor.....	45
	3.4.2 Sensibilidade à Variação de Velocidade.....	47

3.5	Sistemas <i>Fuzzy</i>	49
3.5.1	Projeto do Controlador <i>Fuzzy</i>	49
3.6	Análise da Viabilidade da Proposta.....	57
3.6.1	Conclusão a respeito da Viabilidade da Proposta.....	61
4	Sistemas <i>Neuro-Fuzzy</i>.....	62
4.1	Introdução.....	62
4.2	Conjuntos e Funções de Pertinência <i>Fuzzy</i>	64
4.2.1	Inferência <i>Fuzzy</i>	66
4.2.2	Estrutura do sistema <i>Fuzzy</i>	68
4.3	Sistemas <i>Neuro-Fuzzy</i> adaptativos	70
4.3.1	Controladores <i>Fuzzy</i> paramétricos.....	70
4.3.2	Estrutura do controlador <i>Neuro-Fuzzy</i>	73
5	Metodologia Proposta para Implementação do Controle <i>Neuro-Fuzzy</i> para MIT.....	77
5.1	Introdução.....	77
5.1.1	Características do sistema de controle proposto.....	78
5.2	Estratégia para levantamento dos dados de treinamento.....	80
5.3	Estrutura do controlador <i>Neuro-Fuzzy</i> para controle do MIT.....	83
5.3.1	Esquema geral de treinamento do controlador <i>Neuro-Fuzzy</i>	87
6	Simulação e Análise dos Resultados do Sistema de Controle <i>Neuro-Fuzzy</i> para MIT	88
6.1	Introdução.....	88
6.1.1	Análise de resposta transitória de partida do MIT.....	90
6.2	Análise de resposta transitória de carga ao eixo do MIT.....	98
6.2.1	Análise de resposta transitória de carga em degrau ao eixo do motor de indução.....	99
6.2.2	Análise de resposta transitória de carga em rampa ao eixo do motor de indução.....	102

6.3	Análise de resposta transitória de velocidade.....	105
7	Conclusões Gerais e Trabalhos Futuros.....	106
7.1	Conclusão.....	106
7.2	Trabalhos futuros.....	108
	Referências Bibliográficas.....	109
	Apêndice A – Modelo do Sistema de Controle <i>Fuzzy</i>	112
	Apêndice B – Modelo do Sistema de Controle <i>Neuro-Fuzzy</i> Proposto	113

1 Introdução

1.1 Motivação e Relevância

O motor de indução trifásico (MIT) foi inventado por Nicolay Tesla no final do século 19. Tão profundo e notável foi seu estudo no desenvolvimento e projeto do MIT que segundo SIMONE (2010), em apenas cinco anos após o primeiro motor ter sido apresentado por Tesla, já existiam motores trifásicos com características próximas as dos motores atuais. Sua robustez e simplicidade construtiva permitiram que o MIT logo fosse aplicado em diversos setores da indústria, no entanto, sua utilização ficava restrita às aplicações onde não necessitava-se de variação de velocidade, para tais aplicações os motores CC supriam esta demanda mesmo possuindo uma construção mais complexa e maior custo de aquisição e manutenção. Com o avanço tecnológico na área da microeletrônica, eletrônica de potência e o avanço nos estudos de modelagem e técnicas de controle aplicado ao MIT, foi possível com o passar tempo melhorar o comportamento dinâmico do mesmo, permitindo seu uso em aplicações onde antes somente os motores CC eram empregados devido ao seu bom comportamento dinâmico. Isso denota um aspecto importantíssimo na área de acionamentos elétricos. Este aspecto trata do emprego de técnicas de controle que façam o MIT ter respostas transitórias mais rápidas e precisas frente às variações de referência de velocidade e carga.

Um outro aspecto importante é o da eficiência energética. Segundo MAMEDE (2012), cerca de 75% da energia utilizada pelas indústrias é consumida por motores elétricos. Este fato denota o quanto é importante ao desenvolvimento de sistemas de controle para MIT a questão da eficiência energética, já que o mesmo pode apresentar

baixa eficiência em função da variação da carga e velocidade de operação. Segundo BOSE (2011), é possível demonstrar com base nas equações do motor que seu fator de potência varia conforme variam a carga e velocidade, podendo desta forma alterar significativamente a eficiência energética do MIT. Sendo assim, o MIT desenvolve fator de potência nominal quando está trabalhando com escorregamento nominal, isso significa dizer que a frequência e a tensão imposta pelo sistema de controle são capazes de criar um torque eletromagnético que satisfaz a solicitação de carga na ponta do eixo do motor com o máximo de rendimento.

Conciliar estes dois aspectos têm sido o objetivo de diversos estudos na área de acionamentos elétricos para MIT. As técnicas convencionais de modelagem e implementação de sistemas de controle muitas vezes resultam em sistemas de elevada complexidade, inviabilizando seu emprego em escala comercial, seja pelo custo de implementação ou pelo desempenho insatisfatório que tais sistemas possam apresentar, isso se dá pelo fato do MIT ser de difícil modelagem matemática e ser extremamente não-linear e multivariável, e em muitos casos, seu emprego se dá em condições onde deve trabalhar numa ampla faixa de operação, o que restringe a utilização de modelos linearizados no sistema de controle. Sendo assim, um sistema de controle eficiente para MIT deve ser capaz de reajustar a frequência e tensão impostas para garantir o escorregamento nominal relativo, obtendo assim o máximo de rendimento do MIT para qualquer ponto de operação, e ainda acompanhar os transitórios de carga na ponta do eixo do motor de forma que possa compensar os eventuais desvios de velocidade com rapidez e precisão (BOSE, 2011).

Para atingir tais requisitos, os *Adaptatives Neuro-Fuzzy Inference Systems* (ANFIS) figuram com grande potencial de aplicação por possuírem capacidade de processar múltiplas entradas, e ainda são capazes de se adaptarem às não-linearidades que o sistema a ser controlado possa apresentar. Uma outra característica do ANFIS é a capacidade de mapeamento de funções de transferência com base em informações corrompidas. Essas informações podem ser provenientes de sinais ruidosos ou de um modelo matemático simplificado que descreva parcialmente o

comportamento do sistema a ser controlado, o que resulta na simplificação do sistema de controle tanto em hardware quanto em software. Tais características justificam o estudo e o emprego desta técnica para a área de acionamentos elétricos (MINOTTI, 2008).

1.2 Proposta e Justificativa

Este trabalho tem como proposta demonstrar a utilização dos controladores *neuro-fuzzy* adaptativos (ANFIS) no projeto e implementação de sistemas de controle para motores de indução trifásicos. A proposta consiste em utilizar as potencialidades do ANFIS de forma a contornar os problemas causados pelas não-linearidades do motor de indução (MIT) objetivando um sistema que contemple todos os requisitos de um controlador, sendo assim, plausível de aplicação prática na indústria.

Atualmente na indústria, as técnicas de controle para MIT mais utilizadas são o controle vetorial e o controle escalar. O controle vetorial é empregado para condições de trabalho em regime dinâmico, onde a velocidade e a carga solicitada variam de forma brusca. Já o controle escalar tem seu emprego em condições de trabalho de regime permanente, onde a velocidade e a carga variam lentamente ou praticamente permanecem constantes. Ambas possuem problemas relacionados à degradação do sistema de controle em função das não-linearidades do MIT, dentre estas não-linearidades estão a variação de parâmetros do motor em função da temperatura de operação, saturação magnética e as perdas na resistência do estator em função da frequência imposta. Tais não-linearidades resultam na necessidade de contínua reparametrização dos sistemas de controle de forma a atingir seu melhor desempenho (LIMA, 2010).

Um sistema de controle ideal para MIT deve garantir estabilidade de rotação do rotor, respostas rápidas e precisas frente às variações de carga e ainda garantir a máxima eficiência do MIT (BOSE, 2007). Todos estes requisitos devem ser atendidos numa ampla faixa de operação de carga e velocidade. Sendo assim, para atender tais requisitos os sistemas de controle baseados em inteligência artificial (IA) apresentam características que tornam seu emprego viável, como por exemplo, a capacidade de contornar as variações paramétricas do MIT. Outro ponto importante é a capacidade destes sistemas lidar com informações corrompidas ou parciais e ainda manter a robustez do sistema de controle. Neste trabalho isso fica evidente já que para o treinamento do ANFIS fez-se o uso das equações em regime permanente do MIT. Estas equações descrevem parcialmente o comportamento do motor, no entanto, como o processo de treinamento se deu em diversos pontos de operação de carga e velocidade o ANFIS conseguiu descrever e mapear (aprender) o comportamento do MIT para pontos nos quais o sistema de controle não foi treinado.

O sistema aqui proposto possui um modulador do tipo PWM trifásico que tem como função impor a frequência e a tensão ao MIT de forma a suprir a demanda de carga na ponta do eixo do motor. O controle propriamente dito, se caracteriza por um controlador híbrido, híbrido porque faz uso em sua estrutura de um estimador de velocidade baseado em equações do MIT. Esse estimador monitora continuamente as grandezas elétricas provenientes dos terminais do motor e calcula a velocidade que servirá como variável de entrada para o bloco do controlador ANFIS. Este, após processar tais variáveis, estabelece o sinal de referência para o disparo do modulador PWM trifásico. Para melhorar o desempenho da resposta transitória em partida do MIT, adotou-se como estratégia impor a máxima tensão ao estator da máquina independente da carga solicitada, isso faz com que o motor saia da inércia desenvolvendo o máximo de torque e garante uma resposta transitória mais eficiente.

Desta forma, objetivou-se neste trabalho apresentar um sistema de controle que contemplasse os diversos aspectos de um controlador plausível de aplicação prática, e

ainda propor um método alternativo para o controle em alto desempenho de motores de indução trifásico.

1.3 Revisão Bibliográfica: Sistemas Baseados em Inteligência Artificial para Controle de MIT

A capacidade de tratar não-linearidades combinada com a capacidade de mapear (aprender) o comportamento do sistema a ser controlado sem a necessidade de um modelo matemático, faz com que os sistemas inteligentes baseados em RNA e lógica *fuzzy* possuam significativo destaque no estudo e desenvolvimento de sistemas de controle para acionamentos elétricos de MIT (GODTEL, 2003).

O escopo da aplicação de sistemas inteligentes para acionamentos elétricos é abrangente. A seguir apresentam-se alguns trabalhos para elucidar o estado da arte neste campo de pesquisa.

Em MINOTTI (2008), é proposto um estimador *fuzzy* de velocidade para MIT do tipo *sensorless*. Para o ajuste dos parâmetros do controlador *fuzzy* foi usada uma rede neural. Esta rede foi treinada tendo como base de dados as informações provenientes de um estimador de torque projetado a partir do modelo matemático do MIT. O autor preocupou-se em validar o sistema para diversas condições de carga, condições estas que são normalmente encontradas na indústria.

Nesta mesma linha é proposto em GODTEL (2007) um estimador de velocidade baseado em RNA. Neste trabalho foram apresentados dois métodos para validação da rede neural. O primeiro foi a bi-validação cruzada onde dados experimentais foram apresentados à rede neural treinada com base nos dados provenientes de um modelo

do MIT criado no *MatLab/Simulink*. Em tais circunstâncias o estimador de velocidade apresentou resultado satisfatório em regime permanente, mas insatisfatório em regime transitório. Com o intuito de melhorar a estimação de velocidade em regime transitório, o autor propôs um método alternativo para a validação da rede neural. Este método chamado de bi-validação cruzada modificada consiste em atribuir dados experimentais ao conjunto de dados de treinamento que antes eram somente compostos por dados gerados em simulação computacional. Esse processo alternativo de validação solucionou o problema de estimação de velocidade em regime transitório e foi o principal contribuição deste trabalho.

Um outro emprego de sistemas inteligentes é apresentado em SILVA (2007). Neste trabalho o autor propõe um estimador de torque baseado em lógica *fuzzy* para identificação de cargas lineares, quadráticas e inversas. Como variáveis de entrada do sistema *fuzzy* foram usadas a tensão, corrente e frequência imposta ao motor. Embora o enfoque deste trabalho seja a de propor um sistema capaz de mapear o comportamento de cargas aplicadas ao eixo do motor, para o correto dimensionamento do mesmo, aumentando assim a eficiência energética da instalação, a metodologia aplicada e os resultados obtidos sugerem que este sistema de identificação de torque baseado em lógica *fuzzy* pode ser utilizado em malhas de sistemas de controle para motores de indução. O autor ainda traça um comparativo entre o estimador de torque baseado em lógica *fuzzy* apresentado em seu trabalho e um estimador de torque baseado em RNA apresentado em GODTEL (2003). Com base nos resultados obtidos pelo autor o sistema baseado em lógica *fuzzy* apresentou um desempenho superior.

Em LIMA (2010) é apresentado um sistema *neuro-fuzzy* aplicado ao Controle Vetorial (FOC) do tipo *sensorless*. Este sistema *neuro-fuzzy* proposto, tem como finalidade determinar a velocidade do eixo do motor para o correto desacoplamento dos eixos direto e de quadratura, garantindo assim o bom desempenho do controlador FOC. O sistema proposto pelo autor foi treinado para uma ampla faixa de velocidade e carga, de forma que o estimador fosse suscetível às não linearidades do motor em toda sua faixa de trabalho. Os dados de treinamento foram levantados no *Simulink* e depois

transferidos para uma bancada experimental para simulação prática. Os resultados obtidos pelo controlador demonstraram robustez, mesmo quando exposto a sinais ruidosos característicos de uma implementação prática, não sendo necessário o emprego de técnicas alternativas para treinamento como aconteceu em GODTEL (2003) que fez uso de uma estrutura do tipo RNA, e ainda com a vantagem do sistema *neuro-fuzzy* trazer uma maior interpretabilidade do sistema controlado provendo assim a possibilidade de uma análise mais consistente dos dados.

Assim como o Controle Vetorial (FOC), o Controle Direto de Torque (DTC) é um método de controle de alto desempenho para motores de indução. O DTC tem como característica o controle dinâmico do ângulo de carga entre os vetores espaciais do fluxo do estator e do rotor, de forma que um incremento ou decremento deste ângulo, através de uma modulação PWM trifásica apropriada, resulta no aumento ou na redução do torque eletromagnético gerado pelo motor de forma rápida e precisa. Da mesma forma que o FOC, o DTC é sensível às variações paramétricas do motor, sendo necessário uma estrutura de controle ajustável para garantir a robustez do sistema de controle. Com base neste contexto, em AZCUE (2010), é proposto um controlador *fuzzy* do tipo PI ajustável para determinar o ângulo de disparo do modulador PWM e, conseqüentemente, o torque eletromagnético gerado. Um comparativo entre o controlador *fuzzy* do tipo PI e um controlador PI convencional foi traçado, demonstrando a superior robustez do controlador *fuzzy* do tipo PI, que garantiu respostas de torque mais rápidas e precisas frente as variações de carga e velocidade.

É comum em sistemas de controle para motores de indução trifásicos, estar presente em suas malhas de controle modelos matemáticos que descrevem o comportamento do conjugado eletromagnético gerado pelo motor. Para o correto funcionamento do sistema de controle, é necessário utilizar estimadores de fluxo eletromagnético. O processo de estimação dos fluxos eletromagnéticos envolvidos na determinação do conjugado faz uso de integradores. A utilização destes integradores resulta na imprecisão da medição devido aos níveis CC que surgem antes e depois da etapa de integração prejudicando o desempenho do sistema de controle. Como

proposta para solucionar este inconveniente, LINDEM (2012) propõe a utilização de filtros adaptativos baseados em RNA ADALINE antes e depois de cada integrador para a eliminação dos níveis CC. O autor justifica a utilização da rede ADALINE devido à sua simplicidade, fácil implementação, ocupação de pouco espaço de memória e, ainda, não possuem frequência de corte inferior permitindo seu emprego em baixas rotações do motor, região esta, onde os problemas gerados pelos níveis CC são mais acentuados. O desenvolvimento deste trabalho consistiu na implementação de um algoritmo em *MatLab/Simulink* que apontou a eficácia da proposta dando suporte para a segunda etapa que foi a implementação prática utilizando microprocessador DSP. Os resultados obtidos demonstram a eficiência do sistema de filtragem proposto, principalmente em baixas velocidades de rotação, quando comparado com sistemas de filtragem convencionais.

Em BOSE (2007), é feita uma apresentação geral da teoria das redes neurais e suas aplicações em sistemas de controle dinâmicos. Em seguida, o autor apresenta a utilização das RNA em eletrônica de potência e acionamentos elétricos para motores. São demonstradas implementações de moduladores PWM senoidal e *Space Vector Modulation* PWM (SVM-PWM) de dois e três níveis baseados totalmente em RNA. Na sequência, é proposta a utilização das redes neurais na estimação de velocidade do eixo do motor e na estimação de fluxo eletromagnético, ambos fazendo uso da técnica de filtragem adaptativa baseada em RNA. O autor termina apresentando um sistema completo de controle vetorial para motor de indução trifásico fazendo uso das técnicas baseadas em RNA apresentadas no artigo, dando foco na implementação de tais sistemas usando tecnologias FPGA, DSP e ASIC.

Os acionamentos para motores de indução industriais, fazem uso de controladores do tipo PI em suas malhas de controle. Para um desempenho satisfatório destes acionamentos, se faz necessário a sintonização dos parâmetros do controlador PI em diversas regiões de trabalho do motor de indução. Na maioria dos acionamentos para MIT industriais não existe a possibilidade de realizar uma parametrização dinâmica do controlador PI, o que pode resultar na degradação dos requisitos de controle

estabelecidos para cada aplicação ao longo da faixa de operação do equipamento. Como proposta para solucionar este inconveniente, OH SEOK *et al* (2002) apresentou um sistema de sintonização automática baseada em Redes Neurais Recorrentes (RNN) fazendo uso de um Filtro Estendido de Kalman (FEK). A função do FEK foi de ajustar os pesos sinápticos dos neurônios objetivando o melhor ajuste da resposta de velocidade do motor de indução para cada ponto de trabalho solicitado. Isso foi possível porque o algoritmo do FEK é baseado em gradientes descendentes que resultam em mínimos locais para cada ponto da curva de trabalho do MIT. Estes mínimos locais representam pontos de estabilidade que permitem ao sistema de controle obter melhor resposta frente as variações de carga e *setpoint* de velocidade. O sistema proposto foi testado em sistema embarcado DSP e seus resultados comparados com um controle do tipo PI. O sistema proposto apresentou desempenho superior mesmo naqueles pontos onde o controle do tipo PI estava otimizado, demonstrando a eficiência e robustez do método proposto.

Da mesma forma que em AZCUE (2010), GRABOWSKI *et al* (2000) propõe a utilização de sistemas baseados em IA para a determinação do ângulo de carga no Controle de Direto de Torque (DTC). Os autores fizeram a utilização de um sistema *neuro-fuzzy* na determinação dos vetores espaciais da modulação PWM que, por sua vez, determinam o ângulo de carga e o torque gerado pelo motor de indução. Esta proposta difere de AZCUE (2010) por não usar IA para a sintonização do controlador PI, o controle *neuro-fuzzy* se encarrega de forma autônoma pela imposição do ângulo de carga ao MIT e, ainda, faz uso de um algoritmo de monitoração e treinamento para o ajuste automático do sistema de controle em função do erro do fluxo e torque. Mesmo propondo uma utilização diferente de IA para o controle DTC, o autor obteve resultados práticos que evidenciam a superior robustez destes sistemas quando comparados com os métodos convencionais de controle e, ainda, a versatilidade quanto a possibilidade de implementações que podem ser empregadas na solução de problemas na área de controle.

1.4 Organização do Texto

Neste capítulo está uma breve introdução dos principais aspectos que envolvem o controle de motores de indução trifásicos e a aplicação de sistemas inteligentes para este fim.

No capítulo 2 são apresentados os aspectos mais relevantes na obtenção das equações que definem o comportamento dinâmico do motor de indução.

No capítulo 3 é apresentado um estudo sobre das técnicas convencionais de controle para MIT utilizando um controlador PI, e a análise da viabilidade da proposta da dissertação através da comparação de desempenho entre o controlador do tipo PI e de um controlador *fuzzy*. Conclusões a respeito dos resultados são feitos ao final do capítulo.

No capítulo 4 é apresentada a teoria referente aos sistemas de controle *fuzzy* e *neuro-fuzzy*, com ênfase para sua composição estrutural e o ajuste de seus parâmetros internos (treinamento).

No capítulo 5 é apresentada a metodologia adotada para o desenvolvimento da proposta. É apresentada também, a composição do sistema de controle proposto, e as justificativas quanto à composição das funções de pertinência e método de treinamento adotado.

No capítulo 6 são apresentados e discutidos os resultados obtidos em simulação. São colocados os critérios de desempenho para cada análise, de forma a evidenciar as características do sistema de controle proposto.

No capítulo 7 são feitas as considerações finais a respeito da proposta e, apresentadas as conclusões com base nos resultados obtidos.

2 Motor de Indução

2.1 Introdução

O principal objetivo deste capítulo é demonstrar de forma sintetizada as equações que descrevem o comportamento do motor de indução trifásico e, que são fundamentais ao estudo dos sistemas de controle para acionamento de motores elétricos de indução.

O capítulo está dividido em três partes. Na primeira parte, são apresentadas as considerações iniciais para o levantamento das equações do motor, com base nestas considerações, é demonstrada a obtenção das equações diferenciais que descrevem o comportamento das grandezas elétricas do motor no sistema trifásico ou sistema de “coordenadas 123”.

Na segunda parte, apresenta-se o processo de transformação de coordenadas das equações do motor do sistema trifásico “coordenadas 123”, para o sistema bifásico ou “coordenadas $\alpha\beta$ ”. Este processo também é conhecido como transformada $\alpha\beta$ ou transformada de CLARK, e seu principal atributo é representar as equações do sistema trifásico num sistema bifásico, o que facilita a análise da máquina já que o número de equações diferenciais fica reduzido.

Na terceira e última parte, é apresentada a transformada dq ou transformada de PARK. Este tipo de transformada implica numa representação física do motor com enrolamentos estáticos fixos e enrolamentos rotóricos pseudo-estacionários, cabendo a representação do ângulo de rotação somente às componentes elétricas do motor. As equações obtidas com o emprego desta transformada são úteis na análise do comportamento dinâmico do motor e no emprego de estratégias de controle mais

sofisticadas, onde se faz necessário o conhecimento preciso da rotação do eixo do motor e a imposição correta de corrente e frequência (BARBI, 1985).

2.2 Princípios da Modelagem do MIT

2.2.1 Sistema de Coordenadas 123

Será demonstrado neste item o equacionamento matemático do motor de indução com base no sistema de “*coordenadas reais*” ou “*coordenadas 123*”. A análise com base neste tipo de coordenadas fornece um conjunto de equações que descrevem o motor de indução em seu referencial trifásico.

Antes de iniciar, algumas convenções devem ser adotadas. Estas convenções visam considerar o circuito magnético do motor como um circuito linear o que facilita a análise matemática, (BARBI, 1985), a saber:

- As bobinas que compõem o estator possuem as mesmas características elétricas;
- As bobinas que compõem o rotor possuem as mesmas características elétricas;
- Tanto as bobinas que constituem o estator e o rotor, estão dispostas 120° entre si respectivamente;
- O entreferro será considerado constante;

- O circuito magnético será considerado linear e ideal, sem perdas magnéticas e com distribuição de fluxo magnético no entreferro sendo radial e senoidal;
- A máquina será considerada bipolar.

Com base nestas convenções segue-se o equacionamento do motor. Primeiro serão demonstradas as equações que descrevem a tensão e o fluxo no estator. Assumindo tais convenções tem-se: $R_{s1}=R_{s2}=R_{s3}=R_s$, $L_{s1}=L_{s2}=L_{s3}=L_s$, sendo R_s a resistência estatórica em cada bobina do estator, L_s a indutância estatórica em cada bobina do estator e M_s a indutância mútua entre os enrolamentos do estator da máquina. A figura 1 esquematiza a composição do circuito do estator do motor de indução com base nas convenções adotadas.

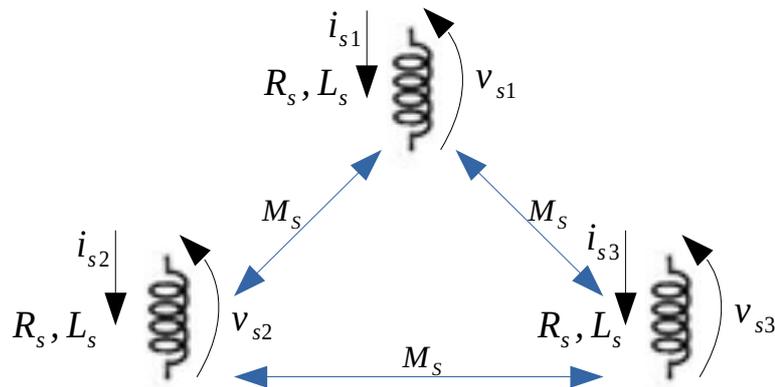


Figura 1 – Circuito trifásico do estator do MIT acoplado magneticamente

(Fonte: Do Autor)

Para as três tensões do estator, seguem:

$$v_{s1} = R_s i_{s1} + \frac{d\Psi_{s1}}{dt} \quad (1)$$

$$v_{s2} = R_s i_{s2} + \frac{d\Psi_{s2}}{dt} \quad (2)$$

$$v_{s3} = R_s i_{s3} + \frac{d\Psi_{s3}}{dt} \quad (3)$$

Sendo cada uma das variáveis:

- v_{s1} , v_{s2} e v_{s3} as tensões impostas por fase no estator;
- i_{s1} , i_{s2} e i_{s3} as correntes que atravessam cada fase do estator;
- L_s as indutâncias de magnetização em cada fase do estator;
- Ψ_{s1} , Ψ_{s2} e Ψ_{s3} os fluxos ligados por fase no estator.

Na forma matricial as equações das tensões do estator podem ser escritas como seguem:

$$[v_s] = R_s [i_s] + \left[\frac{d\Psi_s}{dt} \right] \quad \text{para:} \quad [v_s] = \begin{bmatrix} v_{s1} \\ v_{s2} \\ v_{s3} \end{bmatrix}, \quad [i_s] = \begin{bmatrix} i_{s1} \\ i_{s2} \\ i_{s3} \end{bmatrix} \quad \text{e} \quad \left[\frac{d\Psi_s}{dt} \right] = \begin{bmatrix} \frac{d\Psi_{s1}}{dt} \\ \frac{d\Psi_{s2}}{dt} \\ \frac{d\Psi_{s3}}{dt} \end{bmatrix} \quad (4)$$

Demonstradas as tensões do estator, têm-se, a seguir, as equações que descrevem os fluxos do estator. Adotando a superposição dos fluxos têm-se as equações para cada fase, como seguem:

$$\Psi_{s1} = L_s i_{s1} + M_s i_{s2} + M_s i_{s3} + M_{s1r1} i_{r1} + M_{s1r2} i_{r2} + M_{s1r3} i_{r3} \quad (5)$$

$$\Psi_{s2} = L_s i_{s2} + M_s i_{s1} + M_s i_{s3} + M_{s2r1} i_{r1} + M_{s2r2} i_{r2} + M_{s2r3} i_{r3} \quad (6)$$

$$\Psi_{s3} = L_s i_{s3} + M_s i_{s1} + M_s i_{s2} + M_{s3r1} i_{r1} + M_{s3r2} i_{r2} + M_{s3r3} i_{r3} \quad (7)$$

Onde:

- i_{r1} , i_{r2} e i_{r3} as correntes que atravessam cada fase do rotor;
- M_s a indutância mútua do estator;
- M_{sr} as indutâncias mútuas entre estator e rotor.

Na forma matricial a equação do fluxo do estator pode ser escrita como segue:

$$[\Psi_s] = [L_s][i_s] + [L_{sr}][i_r] \quad (8)$$

A matriz $[L_s]$ representa as indutâncias próprias do estator, e a matriz $[L_{sr}]$ representa o acoplamento das indutâncias entre o estator e rotor ou, indutâncias mútuas entre estator e rotor. Ambas as matrizes estão como seguem:

$$[L_s] = \begin{bmatrix} L_s & -M_s & -M_s \\ -M_s & L_s & -M_s \\ -M_s & -M_s & L_s \end{bmatrix}, \quad [L_{sr}] = \begin{bmatrix} M_{sr} \cos(\theta) & M_{sr} \cos(\theta + \gamma) & M_{sr} \cos(\theta - \gamma) \\ M_{sr} \cos(\theta - \gamma) & M_{sr} \cos(\theta) & M_{sr} \cos(\theta + \gamma) \\ M_{sr} \cos(\theta + \gamma) & M_{sr} \cos(\theta - \gamma) & M_{sr} \cos(\theta) \end{bmatrix} \quad (9)$$

sendo $\gamma = 2\pi/3$ e θ o deslocamento angular entre o rotor e o estator da máquina.

Estando descritas as equações do estator, serão descritas, na sequência, as equações que regem o comportamento das tensões e fluxos do rotor. O processo de obtenção das equações do rotor é o mesmo aplicado ao estator e parte das mesmas convenções adotadas, sendo assim, serão apenas descritas as equações do rotor na forma matricial com a troca de seus respectivos índices fazendo referência ao rotor da máquina.

Da mesma forma que para o estator, segue: $R_{r1}=R_{r2}=R_{r3}=R_r$, $L_{r1}=L_{r2}=L_{r3}=L_r$ sendo R_r a resistência rotórica em cada fase do rotor, L_r a indutância rotórica em cada fase do rotor e M_r a indutância mútua entre as fases do rotor da máquina. A figura 2 esquematiza a composição do circuito do rotor do motor de indução.

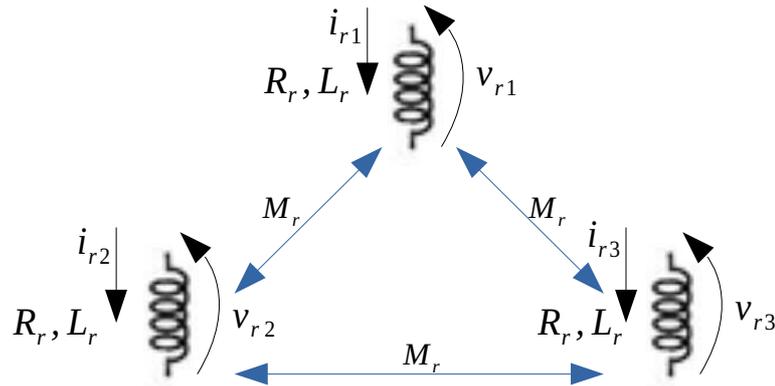


Figura 2 – Circuito trifásico do rotor do MIT acoplado magneticamente

(Fonte: Do Autor)

Na forma matricial as equações das tensões do rotor podem ser escritas como seguem:

$$[v_r]=R_r[i_r]+\left[\frac{d\Psi_r}{dt}\right] \text{ para: } [v_r]=\begin{bmatrix} v_{r1} \\ v_{r2} \\ v_{r3} \end{bmatrix}, [i_r]=\begin{bmatrix} i_{r1} \\ i_{r2} \\ i_{r3} \end{bmatrix} \text{ e } \left[\frac{d\Psi_r}{dt}\right]=\begin{bmatrix} \frac{d\Psi_{r1}}{dt} \\ \frac{d\Psi_{r2}}{dt} \\ \frac{d\Psi_{r3}}{dt} \end{bmatrix} \quad (10)$$

Para uma máquina onde o rotor é em curto-circuito, têm-se $[v_r]=[0]$.

Sendo cada umas das variáveis:

- $[v_r]$ a matriz das tensões induzidas em cada fase do rotor;
- $[i_r]$ a matriz das correntes que atravessam cada fase do rotor;
- $[\frac{d\Psi_r}{dt}]$ a matriz da taxa de variação das indutâncias de magnetização em cada fase do rotor;
- Ψ_{r1} , Ψ_{r2} e Ψ_{r3} os fluxos ligados por fase no rotor.

O fluxo do rotor da máquina é descrito na forma matricial como segue:

$$[\Psi_r]=[L_r][i_r]+[L_{rs}][i_s] \quad (14)$$

A matriz $[L_r]$ representa as indutâncias próprias do rotor, e a matriz $[L_{rs}]$ representa o acoplamento das indutâncias entre o rotor e estator ou, indutâncias mútuas entre o rotor e o estator, e suas matrizes estão definidas a seguir:

$$[L_r]=\begin{bmatrix} L_r & -M_r & -M_r \\ -M_r & L_r & -M_r \\ -M_r & -M_r & L_r \end{bmatrix}, \quad [L_{rs}]=\begin{bmatrix} M_{rs} \cos(\theta) & M_{rs} \cos(\theta+\gamma) & M_{rs} \cos(\theta-\gamma) \\ M_{rs} \cos(\theta-\gamma) & M_{rs} \cos(\theta) & M_{rs} \cos(\theta+\gamma) \\ M_{rs} \cos(\theta+\gamma) & M_{rs} \cos(\theta-\gamma) & M_{rs} \cos(\theta) \end{bmatrix} \quad (15)$$

sendo $\gamma=2\pi/3$ e θ o deslocamento angular entre o rotor e o estator da máquina.

O emprego das equações descritas até aqui, dificulta significativamente a análise do funcionamento do motor de indução quando o objetivo do estudo é o comportamento dinâmico da máquina. Esta dificuldade se dá principalmente pelo elevado número de equações necessárias pra descrever o motor e, também, pelo fato

das indutâncias mútuas que aparecem nas equações estarem magneticamente acopladas, já que o comportamento destas indutâncias é não-linear em função das condições dinâmicas em que o motor possa se encontrar durante o funcionamento (BIM, 2009). A obtenção de modelos mais apropriados para o estudo da dinâmica da máquina serão apresentados nos próximos itens.

2.2.2 Sistema de Coordenadas $\alpha\beta 0$

As equações obtidas no item anterior são de difícil análise do comportamento do motor de indução em regime dinâmico. O principal motivo desta dificuldade se dá pelo acoplamento das indutâncias mútuas que surgem através do acoplamento magnético das fases que compõem a máquina, além das mesmas serem não-lineares em função das condições de carga do motor (BIM, 2009).

É possível obter modelos mais adequados para a análise em regime dinâmico do motor de indução através da transformada de CLARK ou transformada $\alpha\beta 0$. Este tipo de transformada consiste em representar o sistema de “coordenadas 123” (referencial trifásico), num referencial bifásico. O emprego desta técnica favorece a análise matemática do motor de indução porque, além de diminuir o número de equações, fornece um conjunto de equações com as indutâncias mútuas desacopladas, sendo este o segundo passo a ser aplicado para a obtenção de um conjunto de equações que facilitem a análise do motor de indução, (BARBI, 1985). A representação geométrica deste desacoplamento pode ser analisado na figura 3.

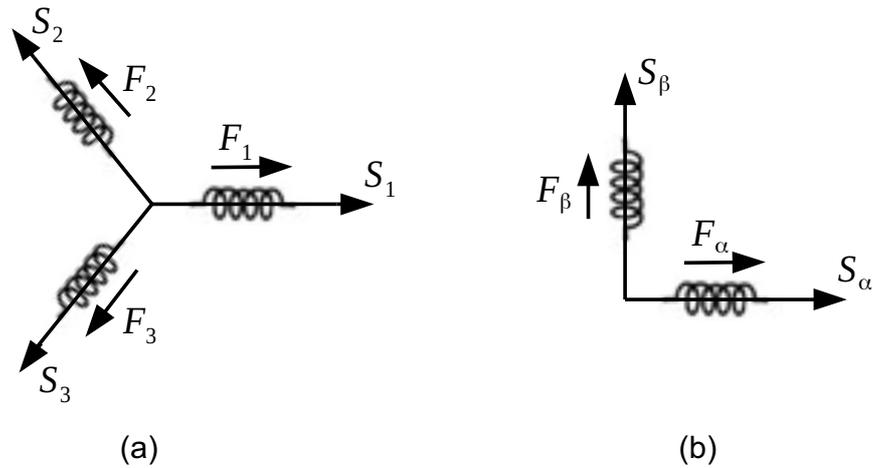


Figura 3

a) Representação das forças magnetomotrizes no referencial 123

b) Representação das forças magnetomotrizes no referencial $\alpha\beta 0$

(Fonte: Do Autor)

A ideia consiste em utilizar uma matriz de transformação $[A]$ que permita escrever as forças magnetomotrizes fictícias F_β e F_α , do referencial bifásico, em função das forças magnetomotrizes reais F_1 , F_2 e F_3 do referencial 123.

Na figura 3.b é possível verificar geometricamente o resultado da transformação, o perpendicularismo que surge entre as forças magnetomotrizes fictícias F_β e F_α garante o desacoplamento destes respectivos fluxos, isso significa que os fluxos eletromagnéticos induzidos em cada uma das bobinas fictícias não interagem entre si, facilitando a análise matemática do motor.

Para exemplificar o processo de obtenção das equações do motor no referencial bifásico, será usado como ponto de partida a equação 16. Esta equação pode descrever as tensões tanto do estator quanto do rotor do motor somente inserindo os respectivos índices.

Assim:

$$[v] = R[i] + \frac{d([\mathcal{L}][i])}{dt} \quad (16)$$

Sendo:

- $[v]$ a matriz das tensões induzidas em cada fase do motor;
- $[i]$ a matriz das correntes que atravessam cada fase do motor;
- $[\mathcal{L}]$ a matriz de indutâncias do motor;
- R a resistência elétrica seja para o rotor ou estator do motor.

Fazendo-se, $[i] = [A][i_{\alpha\beta 0}]$ e $[u_{\alpha\beta 0}] = [A]^{-1}[u]$, e substituindo na equação 16 têm-se:

$$[u_{\alpha\beta 0}] = [A]^{-1}R[A][i_{\alpha\beta 0}] + \frac{d([A]^{-1}[\mathcal{L}][A][i_{\alpha\beta 0}])}{dt} \quad (17)$$

Onde:

$$[A] = \left(\sqrt{\frac{2}{3}}\right) \times \begin{bmatrix} 1 & 0 & 1/\sqrt{2} \\ -1/2 & \sqrt{3}/2 & 1/\sqrt{2} \\ -1/2 & \sqrt{3}/2 & 1/\sqrt{2} \end{bmatrix}, \text{ e } [A]^{-1} = \left(\sqrt{\frac{2}{3}}\right) \times \begin{bmatrix} 1 & -1/2 & -1/2 \\ 0 & \sqrt{3}/2 & \sqrt{3}/2 \\ 1/\sqrt{2} & 1/\sqrt{2} & 1/\sqrt{2} \end{bmatrix}$$

são as matrizes utilizadas para a transformação.

O resultado deste processo está na equação 18, que representa um sistema de equações diferenciais sem acoplamento das tensões e dos fluxos induzidos no motor.

$$[u_{\alpha\beta 0}] = R[i_{\alpha\beta 0}] + \frac{d[\Psi_{\alpha\beta 0}]}{dt}, \quad [\Psi_{\alpha\beta 0}] = [\mathcal{L}_{\alpha\beta 0}][i_{\alpha\beta 0}] \quad (18)$$

Este conjunto de equações servirão como base para a aplicação da transformada dq no item a seguir, fornecendo um conjunto de equações mais adequadas ao estudo do comportamento dinâmico do motor.

2.2.3 Sistema de Coordenadas dq

As equações obtidas no item anterior facilitam a análise do motor de indução por diminuir o número de equações e provê-las na forma de equações diferenciais desacopladas, (BARBI, 1985). No entanto, para máquinas de corrente alternada é interessante proceder as equações que descrevem o motor de indução em coordenadas móveis (PALMA, 2008). A transformada de PARK ou transformada dq , atribui ao conjunto de equações diferenciais do rotor um referencial $\theta(t)$ a rodar em relação a $\alpha\beta$, onde θ é o ângulo que pode ser variável no tempo, figura 4.

A aplicação deste processo transforma a representação bifásica do motor de indução com enrolamentos estatóricos fixos e enrolamentos rotóricos girantes, em enrolamentos estatóricos fixos e rotóricos pseudo-estacionários, (BARBI, 1985). A interpretação física deste processo é a de um motor bifásico com enrolamentos alimentados através de escovas e comutador, o rotor deste tipo de motor é fixo, no entanto, encontra-se em movimento devido à sua construção física que permite impor correntes no enrolamento do rotor de forma a controlar o ângulo $\theta(t)$.

Este tipo de abordagem é muito importante quando o objeto do estudo é o comportamento dinâmico da máquina, já que a localização ângulo $\theta(t)$ tem influência direta na resposta dinâmica do motor é pode ser influenciado pela variação paramétrica dos enrolamentos ou pela condição de carga ao eixo (BIM, 2009).

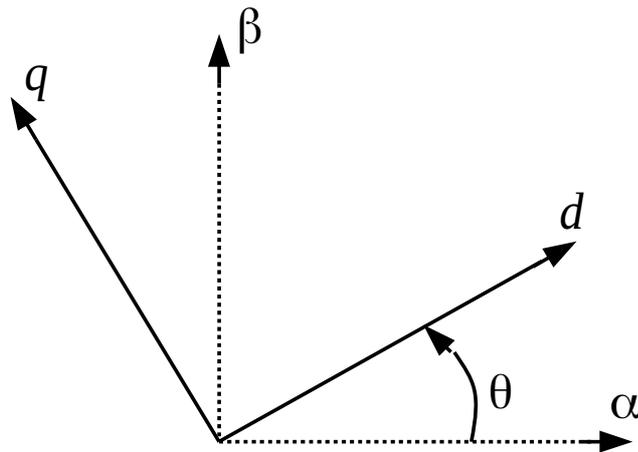


Figura 4 – Representação gráfica da transformada $\alpha\beta \rightarrow dq$

(Fonte: Do Autor)

O processo de transformação $\alpha\beta \rightarrow dq$ pode ser feito na forma matricial. Aqui será demonstrado apenas a obtenção das equações do fluxo do rotor no referencial dq , já que estas servirão, neste trabalho, como base para a análise dinâmica do motor e projeto do controlador PI. Será também desprezada a coordenada “0” do referencial $\alpha\beta 0$, por possuir representação nula no sistema de coordenadas (componente homopolar). A transformação matricial pode ser feita como segue:

$$\begin{bmatrix} i_{\alpha r} \\ i_{\beta r} \end{bmatrix} = \begin{bmatrix} \cos \theta(t) & \sin \theta(t) \\ -\sin \theta(t) & \cos \theta(t) \end{bmatrix} \begin{bmatrix} i_{d r} \\ i_{q r} \end{bmatrix} \quad (19)$$

Ou de forma mais prática, fazendo uso do operador de transformação $e^{-j\theta}$, como segue:

$$\bar{X}_{dq} = X_d + jX_q = e^{-j\theta} \bar{X}_{\alpha\beta} \quad (20)$$

Onde \bar{X}_{dq} e $\bar{X}_{\alpha\beta}$ são os vetores auxiliares generalizados que serão usados na transformação das equações do fluxo do rotor.

Dando sequência na demonstração, têm-se:

$$\frac{d[\bar{X}_{\alpha\beta}]}{dt} = \frac{d(e^{j\theta} \bar{X}_{dq})}{dt} = e^{j\theta} \frac{d[\bar{X}_{dq}]}{dt} + j \frac{d[\theta]}{dt} e^{j\theta} \bar{X}_{dq} \quad (21)$$

$$\frac{d[\bar{X}_{dq}]}{dt} = e^{-j\theta} \frac{d[\bar{X}_{\alpha\beta}]}{dt} - j \frac{d[\theta]}{dt} \bar{X}_{dq}$$

Aplicando 20 e 21 na equação 18, que por conveniência será escrita sem a componente homopolar, obtendo-se:

$$[u_{\alpha\beta 0}] = R[i_{\alpha\beta 0}] + \frac{d[\Psi_{\alpha\beta 0}]}{dt} \Rightarrow [u_{\alpha\beta}] = R[i_{\alpha\beta}] + \frac{d[\Psi_{\alpha\beta}]}{dt} \quad (18)$$

Efetando-se as substituições em 18:

$$[u_{dq}] e^{j\theta} = R[i_{dq}] e^{j\theta} + \frac{d[\Psi_{dq}]}{dt} e^{j\theta} \Rightarrow [u_{dq}] e^{j\theta} = R[i_{dq}] e^{j\theta} + \frac{d[\Psi_{dq}]}{dt} e^{j\theta} + j \frac{d[\theta]}{dt} [\Psi_{dq}] e^{j\theta}$$

e eliminando $e^{j\theta}$ por divisão, chega-se a equação 22:

$$[u_{dq}] = R[i_{dq}] + \frac{d[\Psi_{dq}]}{dt} + j \frac{d[\theta]}{dt} [\Psi_{dq}] \quad (22)$$

A equação 22 pode descrever o comportamento tanto da tensão do estator quanto da tensão do rotor motor, bastando somente inserir os respectivos índices na equação. É através dela que será obtida a função de transferência que determina o comportamento do fluxo do rotor do motor. É também, através do estudo desta função de transferência que se pode determinar o comportamento dinâmico da máquina e evidenciar suas principais características.

Como o objetivo deste estudo, se restringe em demonstrar um conjunto de equações básicas para a análise de estabilidade e do comportamento dinâmico motor, a equação 22 necessita, ainda, de algumas modificações.

Para as devidas modificações, a equação 22 será escrita com seus índices fazendo referência ao rotor do motor. Será considerado, também, um motor de indução do tipo gaiola de esquilo, como o rotor deste tipo de motor está em curto-circuito, as tensões nos enrolamentos tendem a ser zero. Na sequência têm-se a implementação das considerações citadas.

Referenciando a equação 22 ao rotor do motor e fazendo a tensão igual a zero, têm-se:

$$0 = R_r [i_{dqr}] + \frac{d[\Psi_{dqr}]}{dt} + j \frac{d[\theta]}{dt} [\Psi_{dqr}] \quad (23)$$

Escrevendo 23 na forma escalar:

$$0 = R_r i_{qr} + \frac{d\Psi_{qr}}{dt} + \frac{d\theta}{dt} \Psi_{dr} \quad (24)$$

$$0 = R_r i_{dr} + \frac{d\Psi_{dr}}{dt} - \frac{d\theta}{dt} \Psi_{qr} \quad (25)$$

Com o intuito de relacionar o fluxo rotórico com as grandezas elétricas do estator (grandezas elétricas de entrada), procede-se realizando a substituição de 26 e 27 nas equações 24 e 25 respectivamente. Onde:

$$i_{qr} = \frac{1}{L_r} \Psi_{qr} - \frac{L_m}{L_r} i_{qs} \quad (26) \quad i_{dr} = \frac{1}{L_r} \Psi_{dr} - \frac{L_m}{L_{dr}} i_{ds} \quad (27)$$

substituindo, obtêm-se:

$$0 = \frac{R_r}{L_r} \Psi_{qr} - \frac{R_r}{L_r} L_m i_{qs} + \frac{d\Psi_{qr}}{dt} + \frac{d\theta}{dt} \Psi_{dr} \quad (28)$$

$$0 = \frac{R_r}{L_r} \Psi_{dr} - \frac{R_r}{L_r} L_m i_{ds} + \frac{d\Psi_{dr}}{dt} + \frac{d\theta}{dt} \Psi_{qr} \quad (29)$$

Organizando os termos das equações 28 e 29, e fazendo $\frac{d\theta}{dt} = \omega_{sl}$, que representa o escorregamento do rotor do motor, têm-se as equações finais 30 e 31 que representam o comportamento do fluxo do rotor em seus respectivos referenciais.

$$\frac{d\Psi_{qr}}{dt} + \frac{R_r}{L_r} \Psi_{qr} - \frac{R_r}{L_r} L_m i_{qs} + \omega_{sl} \Psi_{dr} = 0 \quad (30)$$

$$\frac{d\Psi_{dr}}{dt} + \frac{R_r}{L_r} \Psi_{dr} - \frac{R_r}{L_r} L_m i_{ds} + \omega_{sl} \Psi_{qr} = 0 \quad (31)$$

Com base nestas equações será feito o estudo a respeito da estabilidade e do comportamento dinâmico do motor e, também, o projeto do controlador PI que servirá

como objeto de estudo para confrontar os resultados obtidos em simulação com a literatura consultada, resultando num embasamento teórico mais consistente para a realização deste trabalho.

3 Estudo e Implementação Utilizando Técnicas Convencionais de Controle para MIT e Análise da Viabilidade da Proposta

3.1 Introdução

Este capítulo tem como objetivo apresentar o estudo das técnicas de controle convencionais para MIT utilizando um controlador do tipo PI, e analisar a viabilidade da proposta de dissertação através da comparação de desempenho entre o controlador do tipo PI e de um controlador *fuzzy*.

Na primeira parte deste capítulo, é apresentada a estrutura do sistema de controle PI, dando ênfase ao funcionamento de cada parte que compõe o modelo desenvolvido. Em seguida, é apresentado o estudo referente a análise de estabilidade e ao desenvolvimento do sistema de controle do tipo PI aplicado aos motores de indução trifásicos, sendo este tipo de controle muito comum em acionamentos elétricos industriais. Concluindo esta primeira parte, está a apresentação dos resultados obtidos com o modelo desenvolvido e simulado, e também, os principais efeitos causados pela assintonia do controlador PI.

Na segunda parte, está apresentada uma análise de desempenho entre o controlador do tipo PI e o controlador *fuzzy* com o intuito de verificar a viabilidade da proposta deste trabalho.

Os resultados obtidos com o estudo e o desenvolvimento deste capítulo são de grande importância para o desenvolvimento da proposta. Primeiro porque resultou no modelo implementado no *MatLab/Simulink* que serviu para constatar, através de simulações computacionais, os problemas relacionados aos métodos de controle convencionais aplicados em acionamentos elétricos industriais, estando estes resultados alinhados com a literatura consultada. E também porque o modelo implementado serve como gerador de dados para o treinamento do sistema *neuro-fuzzy* a ser desenvolvido como proposta principal. Outro ponto de importância deste capítulo, é quanto a verificação da funcionalidade e do desempenho do sistema de controle baseado em *fuzzy* quando comparado com o controlador do tipo PI. Embora algumas considerações devam ser feitas quanto ao desenvolvimento do controlador *fuzzy* para o tipo de aplicação em questão, os resultados obtidos forneceram informações quanto a viabilidade da utilização do sistema de controle baseado em *neuro-fuzzy*, sendo esta a proposta principal para dissertação.

3.2 Modelo para Determinação dos Dados para Treinamento

Para o levantamento dos dados de treinamento do sistema *neuro-fuzzy*, foi desenvolvido um sistema de controle do tipo PI com base nas equações em regime permanente do motor de indução trifásico. Aspectos referentes ao projeto e desenvolvimento do sistema de controle serão discutidos a seguir.

3.2.1 Sistema de Controle PI

O controlador PI implementado para a obtenção dos dados de treinamento, trabalha de forma a compensar o aumento da queda de tensão presente na resistência estática do motor de indução a medida que a frequência imposta ao motor diminui. A não compensação implica na diminuição da corrente de magnetização do motor, que resulta, através do acoplamento magnético entre o estator e o rotor, no deslocamento do ponto de trabalho do escorregamento do motor, e conseqüentemente, na diminuição da eficiência energética do mesmo.

Outro ponto que prejudica a eficiência energética do motor de indução, e onde o controlador PI também atua, é a variação de carga resistente na ponta do eixo do motor. Segundo BOSE (2011), o motor de indução trifásico desenvolve o máximo de eficiência energética quando trabalha com frequência de escorregamento nominal, e atinge este ponto de trabalho quando está trabalhando à plena carga na ponta do eixo do motor. Com uma eventual diminuição de carga, o motor começa a operar com frequência de escorregamento menor, diminuindo assim sua eficiência energética, e neste instante, o controlador PI atua na correção da tensão imposta de forma a entregar ao motor de indução energia proporcional a energia requerida pela variação de carga na ponta do eixo. Ao ser concluído este ajuste, o motor de indução estará novamente em condição nominal de frequência de escorregamento e máxima eficiência energética.

Desta forma, levando-se em conta os dois últimos aspectos citados anteriormente a respeito da atuação do controlador PI, é possível levantar diversos pontos de trabalho do motor de indução trifásico, pontos estes onde o motor estará trabalhando em condições nominais e que servirão para o treinamento do sistema de controle *neuro-fuzzy* proposto neste trabalho.

Quanto ao comportamento em regime dinâmico, como o motor de indução se trata de um sistema não-linear, a sintonização dos parâmetros do controlador PI foram feitas para cada ponto de trabalho do sistema, levando-se em conta a variação da frequência imposta e a variação de carga na ponta do eixo do motor. As respostas transitórias não foram consideradas como conjunto de dados para treinamento do sistema *neuro-fuzzy*, tendo em vista que a qualidade da resposta transitória está ligada ao reconhecimento da carga conectada ao eixo do motor, e o sistema *neuro-fuzzy* consegue, devido às suas características, reconhecer e atuar imediatamente na correção da tensão imposta permitindo respostas transitórias mais rápidas, mesmo para diferentes pontos de trabalho (velocidade e carga).

Na figura 5, está exemplificado a diagramação do controlador PI. Ele faz a modulação do ciclo de trabalho do PWM trifásico através do erro de escorregamento do motor de indução. Através desta medição, como é proposto em PALMA (2008), é possível estimar o torque do motor e efetuar correções de forma que o motor trabalhe dentro da região de máximo rendimento.

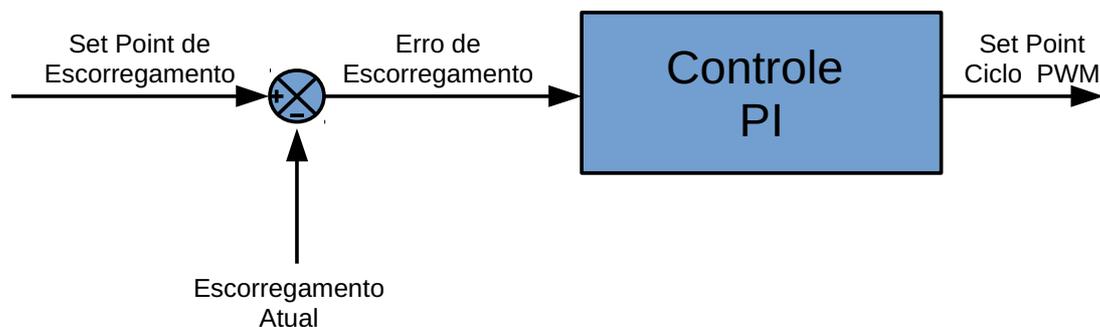


Figura 5 – Estrutura do bloco PI

(Fonte: Do Autor)

3.2.2 Estimação de Velocidade *Sensorless*

O processo de determinação da velocidade do eixo do motor utilizado neste trabalho é baseado no estimador de velocidade do tipo *sensorless*, através da monitoração das grandezas elétricas tensão e corrente é possível estimar a velocidade do motor. Para o desenvolvimento do estimador de velocidade *sensorless*, foram usadas as equações de regime permanente do motor, sendo necessária a correta parametrização do sistema de controle, com base nos parâmetros elétricos do motor de indução, para o correto funcionamento do estimador de velocidade.

Na figura 6 está exemplificado a diagramação do sistema de controle contendo o estimador de velocidade *sensorless*. Este estimador possui como variáveis de entrada o *setpoint* de velocidade (frequência imposta), tensão elétrica do estator e a corrente elétrica do estator, além dos parâmetros elétricos do motor de indução. O estimador de velocidade recebe todas estas informações e fornece a velocidade atual do eixo do motor, que servirá como parâmetro para a atuação do bloco PI de controle do ciclo de trabalho do PWM trifásico.

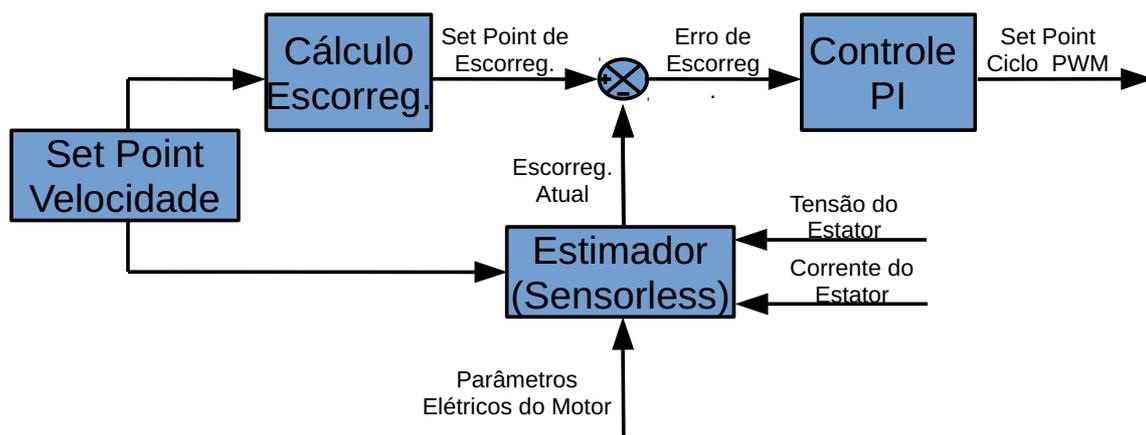


Figura 6 – Estrutura de controle com estimador *sensorless* - (Fonte: Do Autor)

3.2.3 Modulador PWM Trifásico

O modulador PWM trifásico tem como função impor ao estator do motor de indução a frequência estabelecida como referência de *setpoint* e, ainda, impor a tensão elétrica média ao estator de forma a suprir a demanda de carga solicitada ao eixo, mantendo assim o escorregamento dentro da faixa de máxima eficiência do motor.

A figura 7 exemplifica a estrutura do sistema de controle contendo o modulador PWM trifásico.

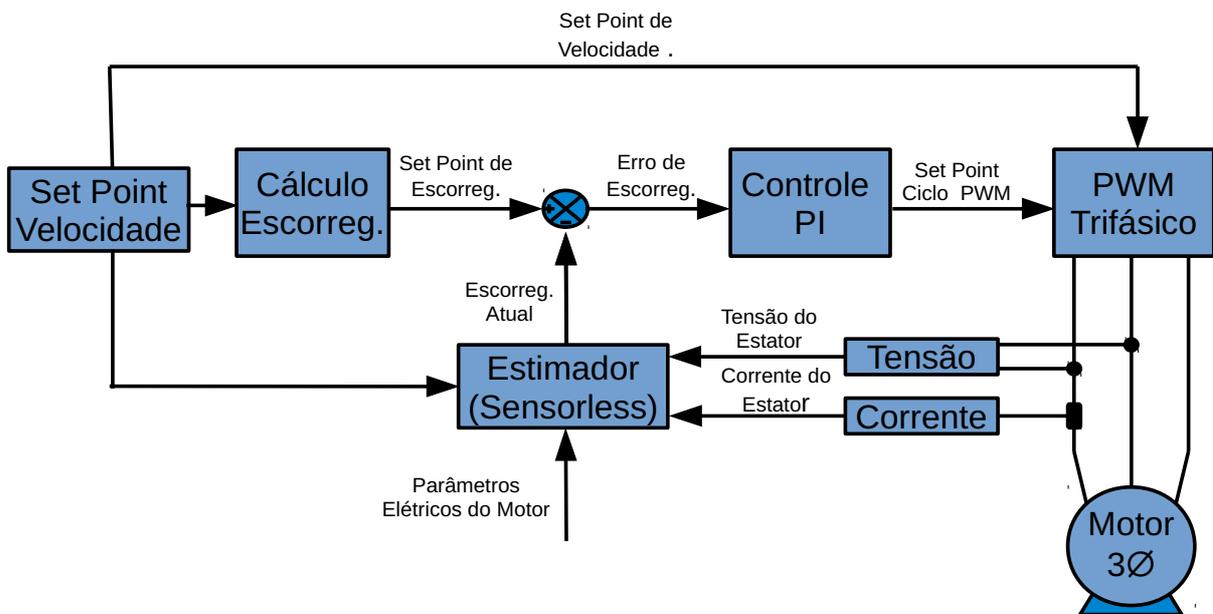


Figura 7 – Estrutura geral do sistema de controle PI

(Fonte: Do Autor)

Na figura 8 é possível visualizar a corrente de uma das fases do estator do motor de indução gerada através na modulação PWM. O formato não puramente senoidal da forma de onda da corrente, se dá pelo processo de chaveamento da unidade inversora transistorizada. Este formato irregular pode ser melhorado com o aumento da frequência de chaveamento dos transistores, no entanto, com um aumento significativo

das perdas por chaveamento na unidade inversora, causando um maior aquecimento e a diminuição da vida útil do componente.

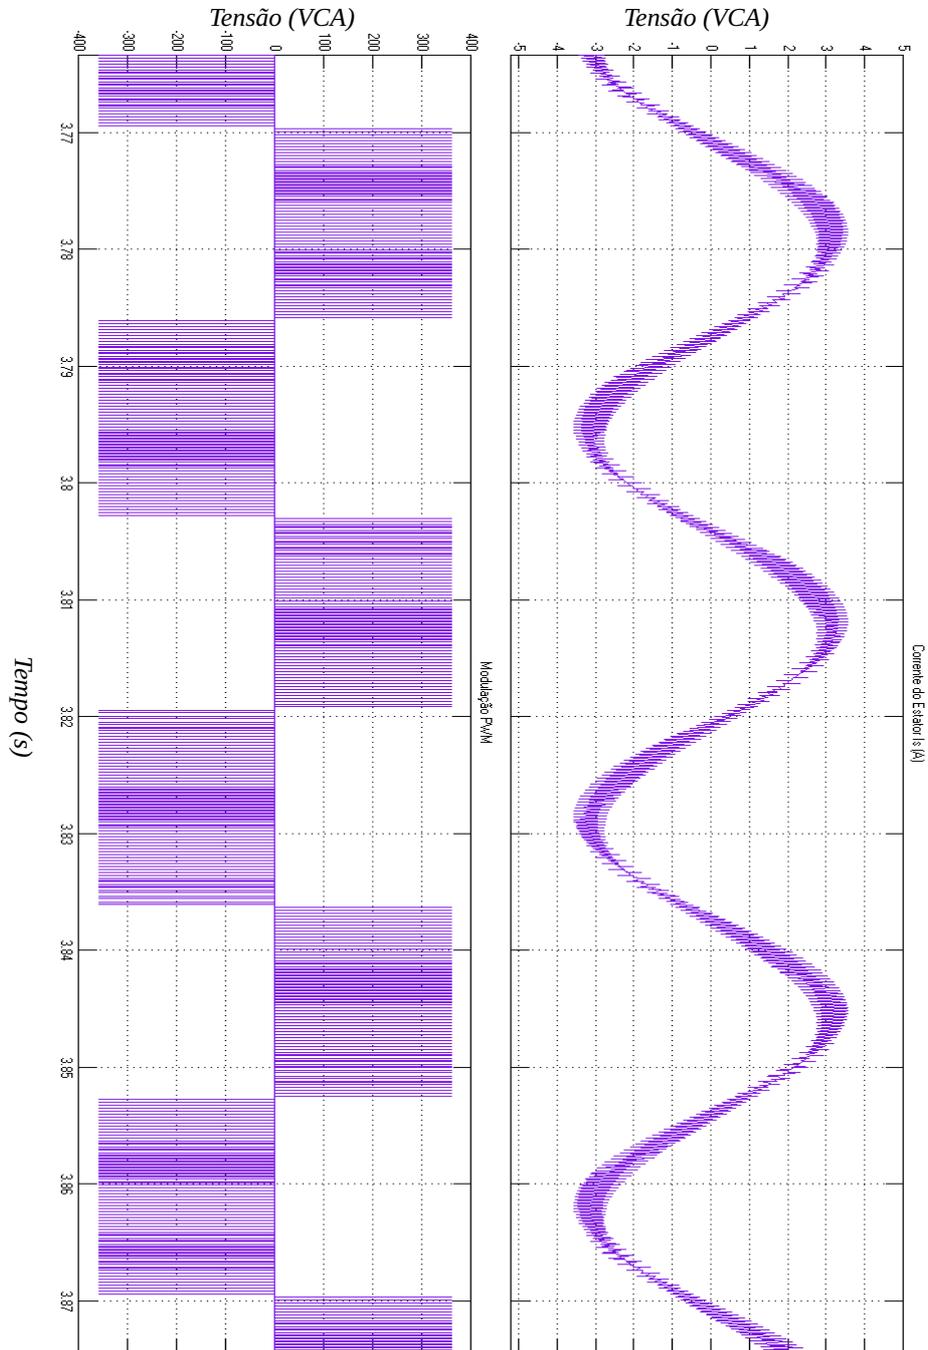


Figura 8 – Formas de onda, corrente do estator I_s (A), e modulação PWM

3.3 Análise e Modelagem do Sistema de Controle

O modelo para o levantamento dos dados de treinamento para o controlador *neuro-fuzzy*, faz uso das equações em regime permanente do motor de indução e de um controlador do tipo PI para o ajuste do torque eletromagnético requisitado ao motor pela carga conectada à ponta do eixo. Este sistema, é capaz de manter o escorregamento nominal do motor de indução para qualquer velocidade de operação e para qualquer carga solicitada ao eixo do motor, desde que, o controlador PI esteja sintonizado adequadamente.

Neste item serão abordados os aspectos relacionados ao projeto do controlador PI com base no modelo matemático do motor de indução, os efeitos de assintonia causados pelo comportamento não-linear do motor e serão analisados os dados obtidos em simulação no *MatLab/Simulink*.

3.3.1 Análise de Estabilidade do MIT

Para a análise de estabilidade do motor indução, se faz necessário a utilização das equações em regime dinâmico do motor. Estas equações são descritas nos eixos referências direto (d) e de quadratura (q), também chamado de referencial dq . Segundo BIM (2009), este tipo de referencial bifásico favorece a análise do comportamento do motor de indução por prover a redução do número de equações e, ainda, possibilitar o desacoplamento das variáveis elétricas do motor que influenciam diretamente em seu comportamento dinâmico. Isso auxilia na escolha da estratégia de controle e nas possíveis aproximações a serem consideradas durante a análise e desenvolvimento do sistema de controle. Também para esta análise, considera-se a estratégia de controle

baseada na variação simultânea da corrente e frequência imposta ao motor de indução para manter o escorregamento constante.

As equações 30 e 31, descrevem o comportamento do fluxo do rotor em seus respectivos referenciais:

$$\frac{d\Psi_{qr}}{dt} + \frac{R_r}{L_r}\Psi_{qr} - \frac{R_r}{L_r}L_m i_{qs} + \omega_{sl}\Psi_{dr} = 0 \quad (30)$$

$$\frac{d\Psi_{dr}}{dt} + \frac{R_r}{L_r}\Psi_{dr} - \frac{R_r}{L_r}L_m i_{ds} + \omega_{sl}\Psi_{qr} = 0 \quad (31)$$

Com base nestas equações é possível encontrar a função de transferência que relaciona o fluxo do rotor Ψ_r com o fluxo do estator Ψ_s . As raízes desta função de transferência determinam o comportamento dinâmico do fluxo do rotor Ψ_r e, conseqüentemente, como será o comportamento do torque gerado pelo motor de indução, bem como a variação de velocidade em função do comportamento do torque.

Para esta análise, considera-se o motor de indução estando com escorregamento ω_{sl} constante e sujeito a uma variação de carga na ponta do eixo do

motor, para tais circunstâncias, $i_{ds} = I_s$ e $i_{qs} = 0$, e fazendo $\frac{R_r}{L_r} = \frac{1}{\tau_r}$, resulta em:

$$\frac{d\Psi_{qr}}{dt} + \frac{1}{\tau_r}\Psi_{qr} + \omega_{sl}\Psi_{dr} = 0 \quad (32)$$

$$\frac{d\Psi_{dr}}{dt} + \frac{1}{\tau_r}\Psi_{dr} - \frac{1}{\tau_r}L_m I_s + \omega_{sl}\Psi_{qr} = 0 \quad (33)$$

A partir de 32 e 33, é possível obter a equação em modo escalar para o fluxo, equação 34:

$$\frac{d\Psi_r}{dt} + \frac{1}{\tau_r} \cdot \Psi_r - \frac{1}{\tau_r} \cdot L_m \cdot I_s \pm j\omega_{sl} \cdot \Psi_r = 0 \quad (34)$$

Sendo $L_m \cdot I_s = \Psi_m$, que é o fluxo de magnetização produzido no estator do motor de indução, e linearizando em torno de um ponto de trabalho $j\omega_{sl} = \Delta j\omega_{sl}$, têm-se a equação 35:

$$\frac{d\Psi_r}{dt} + \frac{1}{\tau_r} \Psi_r - \frac{1}{\tau_r} \Psi_m \pm \Delta j\omega_{sl} \Psi_r = 0 \quad (35)$$

Aplicando-se Laplace em 35, e resolvendo de forma que o fluxo do rotor Ψ_r seja a variável de saída e o fluxo do estator Ψ_m a variável de entrada, chega-se em 38 que é a função de transferência do sistema:

$$s\Psi_r(s) + \frac{1}{\tau_r} \Psi_r(s) - \frac{1}{\tau_r} \Psi_m(s) \pm \Delta j\omega_{sl} \Psi_r(s) = 0 \quad (36)$$

$$\Psi_r(s) \left(s + \frac{1}{\tau_r} \pm \Delta j\omega_{sl} \right) = \frac{1}{\tau_r} \Psi_m(s) \quad (37)$$

$$\frac{\Psi_r(s)}{\Psi_m(s)} = \frac{\frac{1}{\tau_r}}{\left(s + \frac{1}{\tau_r} \pm \Delta j\omega_{sl} \right)} \quad (38)$$

Onde as raízes da função de transferência são descritas em 39:

$$s = -\frac{1}{\tau_r} \pm \Delta j \omega_{sl} \quad (39)$$

As raízes situam-se com lugar geométrico demonstrado na figura 9.

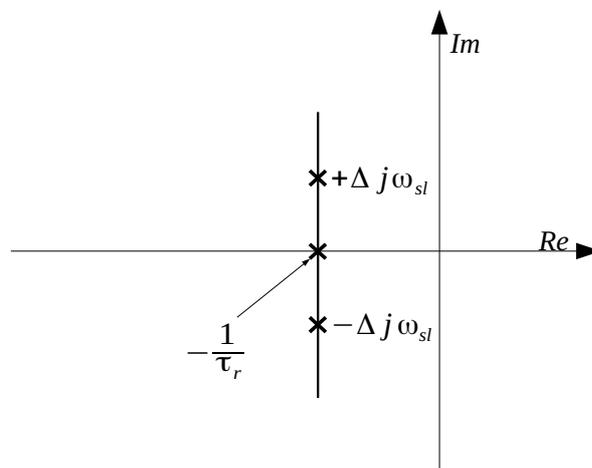


Figura 9 – Lugar geométrico das raízes da função de transferência do MIT

Com base na análise realizada, conclui-se que o motor de indução representa um sistema estável, apresentando uma resposta oscilatória em função da intensidade da variação de carga na ponta do eixo do motor. Esta oscilação está representada pela variação do escorregamento $\pm \Delta j \omega_{sl}$, que é a componente complexa na raiz da função de transferência.

Na figura 10 está a curva de resposta transitória de velocidade do motor de indução obtida a partir do modelo desenvolvido no *MatLab/Simulink*. Pode-se notar o tipo de resposta da curva de velocidade obtida. Esta curva demonstra o comportamento oscilatório da velocidade em função da variação de carga na ponta do eixo do motor de indução. No gráfico, até os primeiros 6 segundos, o motor está sujeito à carga constante. Dos 6 aos 8 segundos ocorre um aumento da carga que provoca o deslocamento do escorregamento e, conseqüentemente, a atuação do controlador. Dos 10 segundos em diante, ocorre uma nova variação de carga. Esta redução provoca um novo deslocamento do escorregamento e a atuação do controlador para manter o escorregamento dentro do nominal com velocidade de 825 rpm (reta vermelha no gráfico). Vale salientar que a qualidade da resposta está relacionada ao ajuste do controlador PI em função da variação de carga na ponta do eixo do motor e da velocidade requerida, já que estas duas grandezas influenciam na localização das raízes da função de transferência da malha de controle como será visto na sequência.

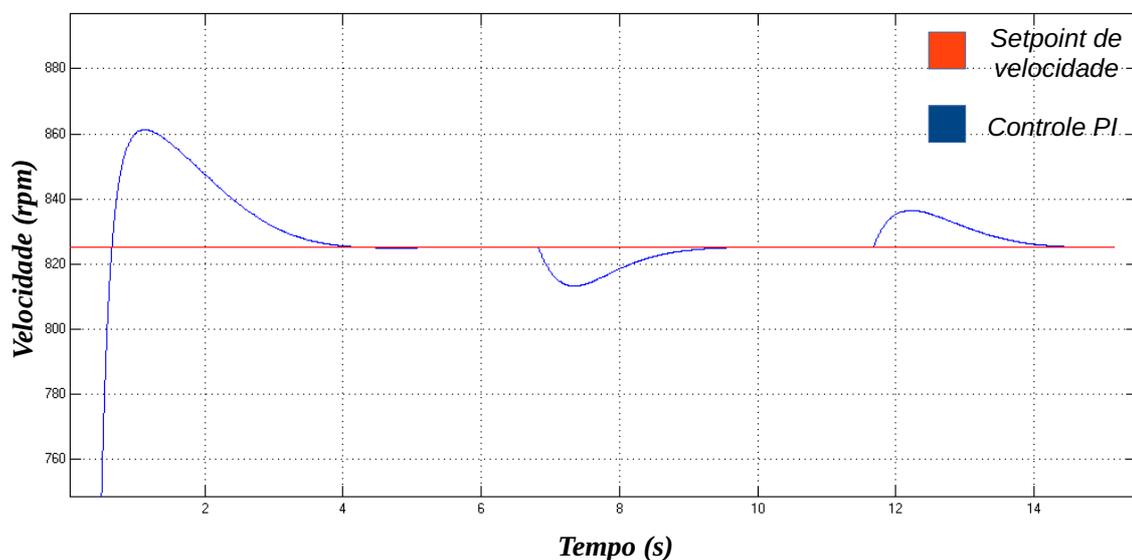


Figura 10 – Curva de resposta da velocidade do motor de indução

3.3.2 Projeto do Controlador PI de Velocidade

Nos acionamentos eletrônicos industriais, é comum o uso do controlador PI devido à sua simplicidade de sintonia e por propiciar erro de regime nulo e, ainda, atenuar o efeito da perturbação causada pela variação de carga na ponta do eixo do motor.

Em PALMA (2008), é proposto um método para o projeto do controlador de velocidade PI em que as raízes da função de transferência, equação 38, para efeito de simplificação, são alteradas de forma a desconsiderar a variação na parte complexa $\pm \Delta j \omega_{sl}$, que é a variação do escorregamento, e considerar a parte real como sendo $s = -\frac{1}{\tau_r}$, esta aproximação é válida desde que a variação do escorregamento causada pela carga seja pequena. Em seguida, o autor propõe o cancelamento do pólo mecânico da carga com o zero do controlador PI. Estas considerações levam a redução da ordem da função de transferência da malha de controle e, ainda, elimina o zero da função de transferência sem a necessidade da utilização de filtros na entrada do sistema de controle.

O controlador PI atua na determinação da tensão média imposta ao estator do motor de indução, controlando assim, o conjugado eletromagnético do motor de forma a manter o escorregamento dentro das condições nominais.

Na figura 11, está o diagrama de blocos do sistema de controle para o motor de indução, onde $\omega^*(s)$ é o setpoint de velocidade e $\omega(s)$ é a velocidade real do motor, τ_r e τ_m são as constantes de tempo do motor de indução e da carga ao eixo respectivamente, K a constante de torque do motor de indução e K_m a constante de torque resistente ao eixo da perturbação $T_{res}(s)$.

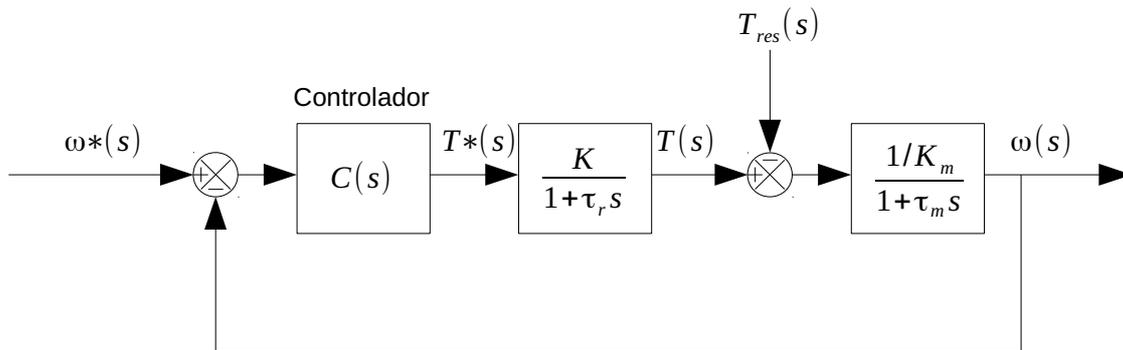


Figura 11 – Diagrama do sistema de controle para MIT

(Fonte: Do Autor)

Como já mencionado anteriormente, a solução consiste em fazer o cancelamento do pólo mecânico da carga resistente ao eixo com o zero do controlador PI. Sendo:

$$C(s) = \frac{K_c(1 + \tau_c s)}{s} = \left(\frac{K_c}{s} + K_c \tau_c\right) = \left(\frac{k_i}{s} + k_p\right) \quad \text{com } \tau_c = \tau_m \quad (40)$$

Resultando na função de transferência:

$$\frac{\omega(s)}{\omega^*(s)} = \frac{\frac{K_c \cdot K}{K_m \cdot \tau_r}}{s^2 + \frac{s}{\tau_r} + \frac{K_c \cdot K}{K_m \cdot \tau_r}} \quad (41)$$

Para ajustar o valor de K_c é conveniente adotar um coeficiente de amortecimento de $\zeta = 0.7$, e o valor de K_c fica:

$$K_c = \frac{K_m}{2 \cdot K \cdot \tau_r}$$

Para um tempo de subida de $t_{subida} = 4,7 \cdot \tau_r$.

O resultado desta solução pode ser vista graficamente na figura 12 com o cancelamento do pólo mecânico da carga com o zero do controlador.

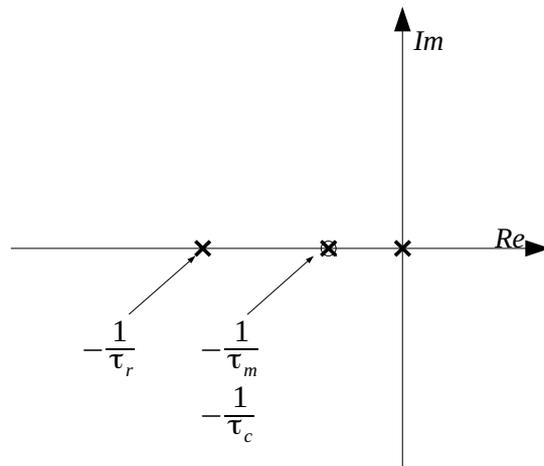


Figura 12 – Lugar geométrico das raízes da função de transferência da malha e controle indicando o cancelamento do pólo mecânico com o zero do controlador PI

Como pode-se observar na figura 13, o método de sintonização proposto em PALMA (2008) resultou numa resposta transitória subamortecida com um pequeno sobressinal como é visto em detalhe na figura 14.

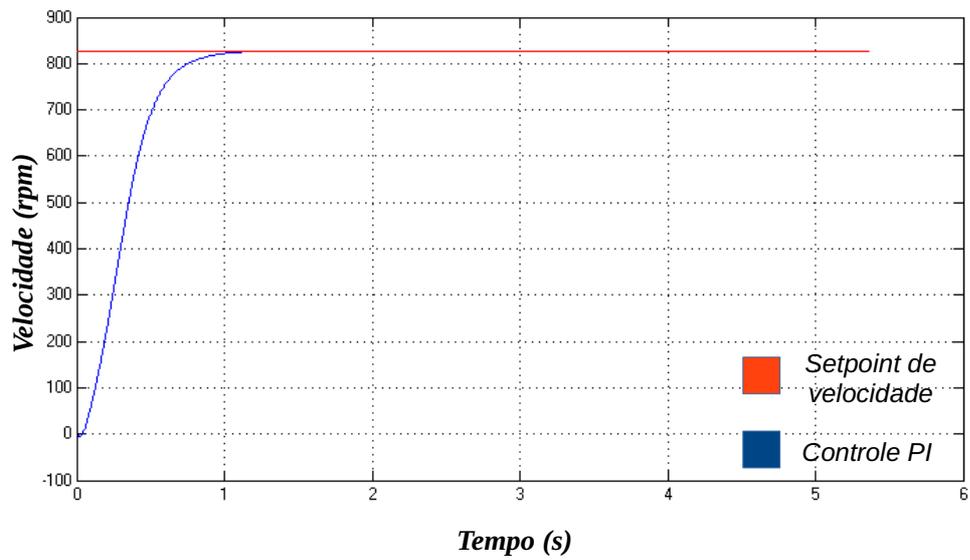


Figura 13 – Curva de resposta ao arranque utilizando o método de sintonização do controlador PI proposto em (PALMA, 2008)

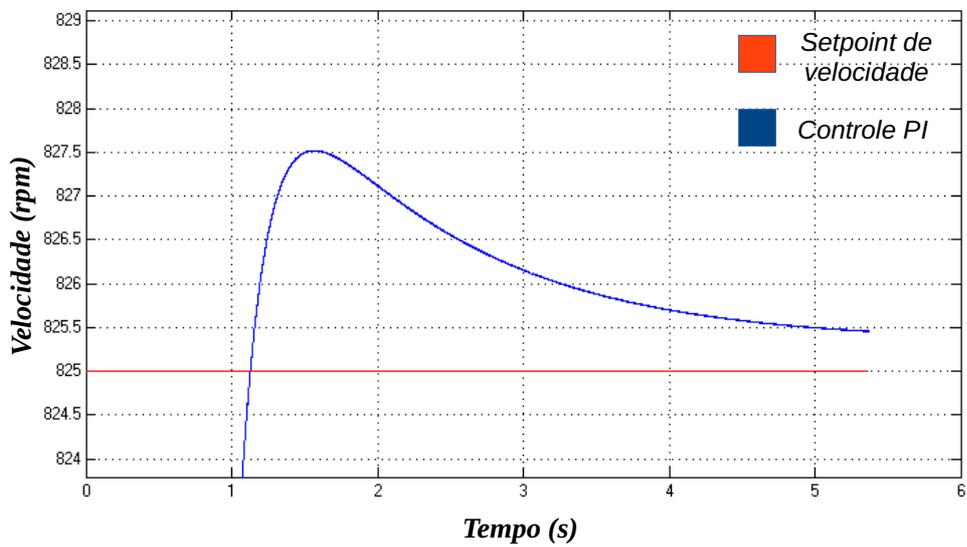


Figura 14 – Detalhe do sobressinal obtido com o método de sintonização do controlador PI proposto em (PALMA, 2008)

Com base nos resultados obtidos em simulação, o modelo projetado em ambiente computacional para levantamento dos dados do *ANFIS* é válido, já que o mesmo consegue determinar o torque eletromagnético gerado pelo motor de indução de forma que o mesmo desenvolva escorregamento nominal. Na figura 15 está o modelo construído no *MatLab/Simulink*.

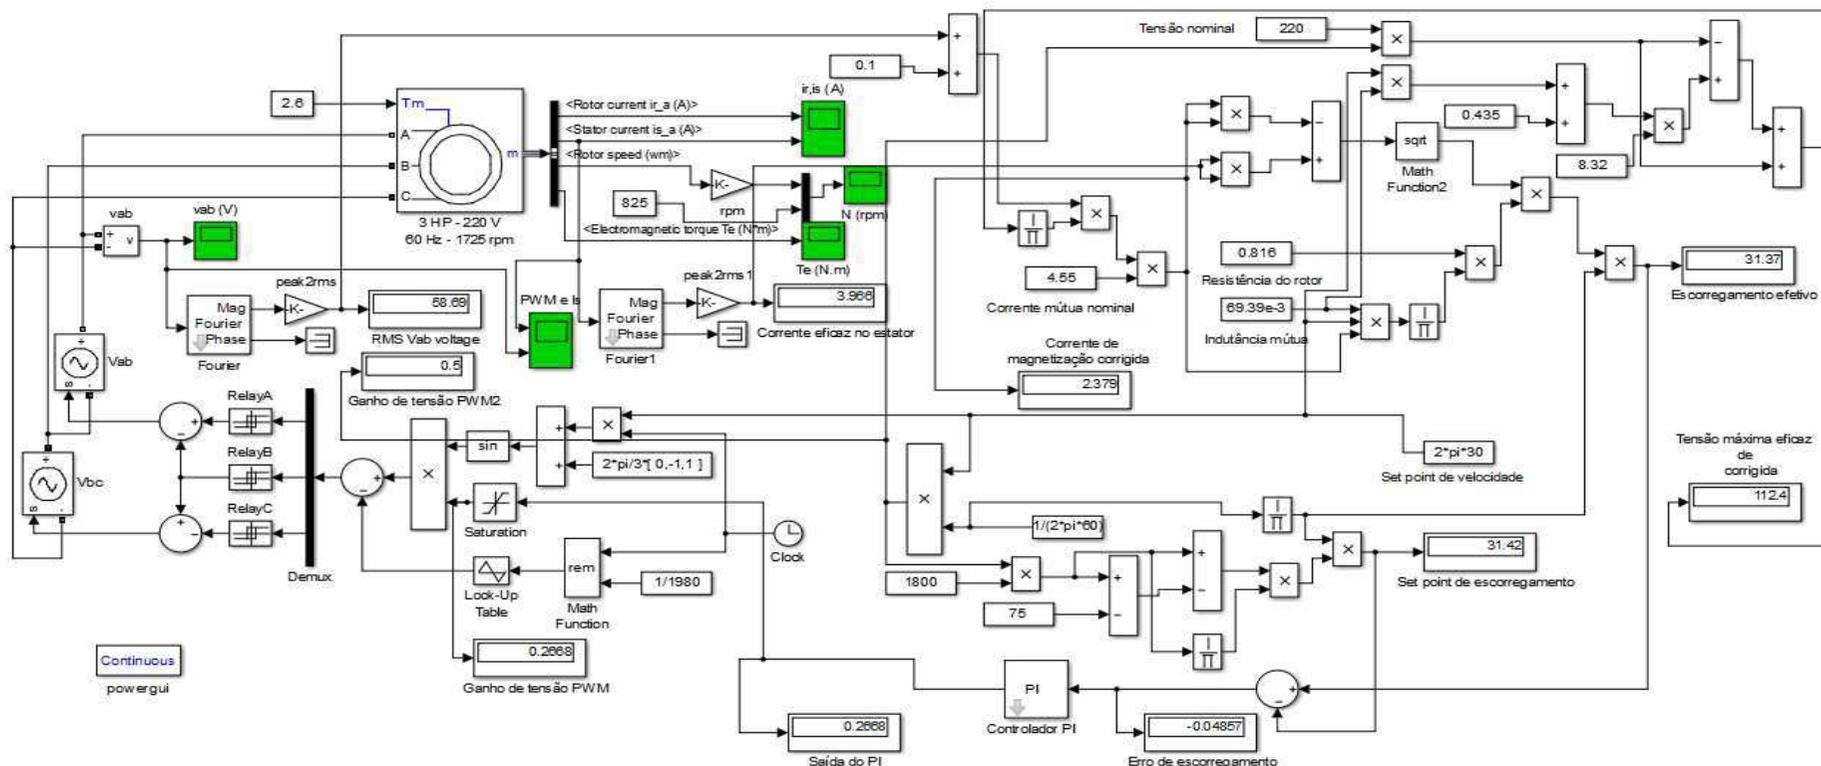


Figura 15 – Sistema de controle para MIT construído para levantamento dos dados de treinamento do ANFIS

3.4 Análise da Assintonia

Neste item serão analisados os efeitos causados pela assintonia no controlador PI apresentado no item 3.3. Serão analisados a qualidade do modelo de controle frente as variações de carga ao eixo do motor de indução e os efeitos da *variação do setpoint* de velocidade para uma ampla faixa de trabalho, condições estas muito comuns em ambiente industrial.

3.4.1 Sensibilidade à variação de Carga ao Eixo do Motor

O método de controle apresentado no item 3.3, é amplamente utilizado nos acionamentos industriais para motores de indução, mesmo apresentando problemas relacionados à degradação da qualidade do controle quando utilizados numa ampla faixa de variação de carga e velocidade. Quanto à variação de carga, o método de controle PI apresentado, começa a apresentar variação nos requisitos de controle estabelecidos inicialmente à medida que ocorre a variação de carga na ponta do eixo do motor. Esta variação de carga provoca a alteração das características do sistema mecânico e, conseqüentemente, o deslocamento do pólo mecânico da função de transferência da carga, que por sua vez, dessintoniza o controlador PI já que anteriormente o zero do controlador estava posicionado de forma a cancelar o pólo mecânico da carga.

Segundo PALMA (2008), o não cancelamento do pólo mecânico da carga, provoca a sobrelevação da curva de resposta ao degrau e, ainda, pode provocar, a rotação no sentido contrário do eixo do motor no momento da partida, caracterizando um sistema de fase não mínima como pode ser visto na figura 16.

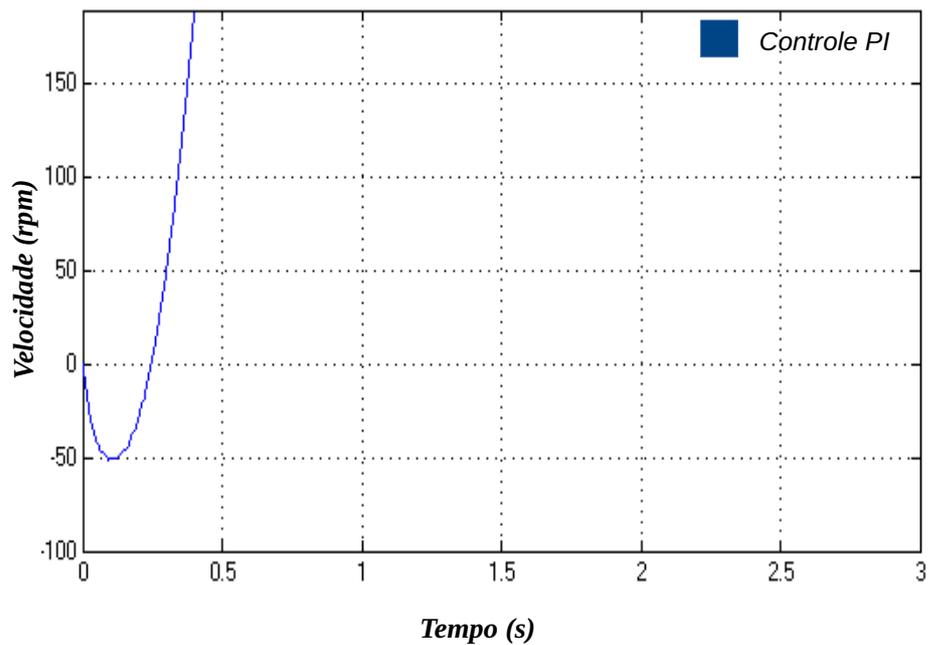


Figura 16 – Detalhe do momento da partida do motor com sistema de fase não mínima, rotação de 50 rpm no sentido contrário

3.4.2 Sensibilidade à variação de Velocidade

O método de controle apresentado no item 3.3, também apresenta problemas relacionados à degradação da qualidade do controle quando sujeito à variação do *setpoint* de velocidade. No processo de sintonização do controlador PI, o parâmetro K_c do controlador é determinado com base na imposição do coeficiente de amortecimento ζ e da frequência natural ω_n do denominador da função de transferência em malha fechada, equação 41, do sistema de controle, levando-se em conta o tempo de subida t_{subida} , a máxima sobrelevação M_p e o tempo de acomodação t_{acomod} para um determinado *setpoint* de velocidade. Quando o *setpoint* é alterado, os parâmetros de controle estabelecidos inicialmente não conferem mais a mesma qualidade da curva de resposta como pode ser observado na figura 17.

Como pode ser observado na figura 17, a variação do *setpoint* de velocidade altera significativamente a curva de resposta do motor. Na figura 17.B está a resposta do sistema de controle sintonizado para uma *setpoint* de velocidade de 30Hz. Na figura 17.C está a curva resposta do sistema de controle para um *setpoint* de velocidade de 45Hz. Pode-se observar que a curva apresenta uma resposta mais lenta, porém, mantendo a estabilidade da velocidade. Já na figura 17.A, para um *setpoint* de velocidade de 15Hz, o sistema de controle apresenta resposta transitória mais rápida, porém, com instabilidade de velocidade, que implica na necessidade de uma nova sintonização do controlador.

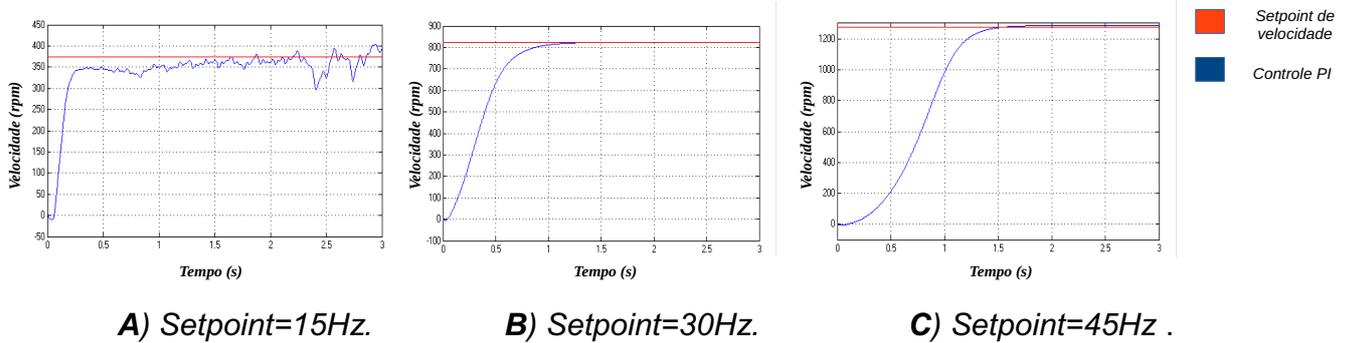


Figura 17 – Curvas de arranque do MIT:

- A)** Setpoint=15Hz, resposta apresentando instabilidade de velocidade
- B)** Setpoint=30Hz, resposta dentro das especificações estabelecidas na sintonização do controlador
- C)** Setpoint=45Hz, resposta mais lenta, fora das especificações estabelecidas na sintonização do controlador

Como foi verificado, o controlador PI mesmo sendo o mais empregado nos acionamentos industriais, é sensível à variação do *setpoint* de velocidade. Na prática do ambiente industrial, normalmente sintoniza-se o controlador PI para o pior caso, que é o menor *setpoint* de velocidade em que o sistema vai operar, levando-se em conta o tempo de subida t_{subida} para este *setpoint* e aplica-se o método de sintonização apresentado em no item 3.3. Como o tempo de subida t_{subida} foi estabelecido em função do pior caso, deve-se assumir uma curva de resposta mais lenta para *setpoints* de velocidade com maior valor. Isso, ao menos, garante a estabilidade da velocidade dentro de uma faixa estabelecida em projeto.

3.5 Sistemas *Fuzzy*

Estruturas de controle baseadas em lógica *fuzzy* possuem como principal característica a capacidade de se adaptarem as não-linearidades que o sistema a ser controlado possa apresentar, permitindo um desempenho superior quando comparado aos controladores do tipo PI (CAMPOS et al., 2004). Baseando-se nesta característica, foi desenvolvido neste item um controlador *fuzzy* para verificar a eficácia deste tipo de controle que, de acordo com os resultados obtidos, fornecerá subsídios para o desenvolvimento do controlador *neuro-fuzzy*.

3.5.1 Projeto do Controlador *Fuzzy*

O controlador *fuzzy* aqui projetado tem como finalidade estabelecer o correto *setpoint* para o ciclo de trabalho do modulador PWM trifásico, fazendo assim, a função que antes caberia ao controlador do tipo PI. De forma geral, o controlador *fuzzy* aqui proposto trabalha monitorando o erro de velocidade e a taxa de variação do erro de velocidade. Estas duas variáveis são processadas dentro do controlador *fuzzy* através das regras estabelecidas em projeto, o resultado deste processamento é um valor defuzzificado que representa o *setpoint* para o modulador PWM trifásico.

Na figura 18 está a exemplificação da estrutura de controle baseada em *fuzzy*. Para o cálculo da taxa de variação do erro, foi necessário a utilização de um filtro passa-baixa para aumentar a imunidade a ruído na entrada do bloco derivativo. Foi necessário também a utilização de dois blocos para ajuste de escala, um para cada entrada do controlador *fuzzy*.

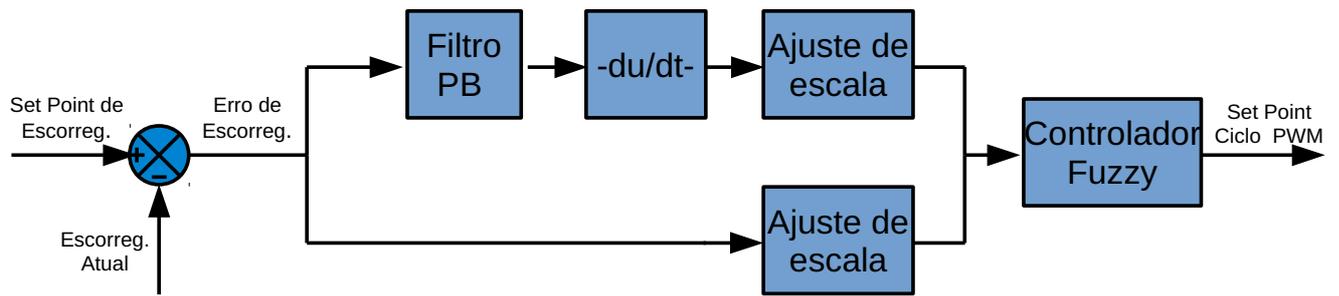


Figura 18 – Estrutura do sistema de controle baseado em fuzzy

(Fonte: Do Autor)

Em ARAÚJO (2010), foram desenvolvidos dois controladores *fuzzy*, um para a malha de controle de velocidade e o outro para a malha de controle de posição. A técnica de controle aplicada foi o controle vetorial, com realimentação de velocidade e posição feita por *encoder* e, fazendo uso da modulação *SVPWM* para a geração da tensão trifásica. Embora o sistema a ser controlado em ARAÚJO (2010) seja diferente do qual é proposto neste trabalho, os métodos aplicados serviram como base para o desenvolvimento do controlador *fuzzy* aqui proposto, já que muitos dos problemas relacionados ao controle de velocidade do motor indução estão presentes nas duas propostas.

O controlador *fuzzy* aqui proposto, utiliza o método Mamdani de inferência e o método de defuzzificação pela média dos máximos. As variáveis de entrada do controlador *fuzzy* são respectivamente, o erro de velocidade e a taxa de variação de erro. A figura 19 demonstra a implementação feita no *MatLab*.

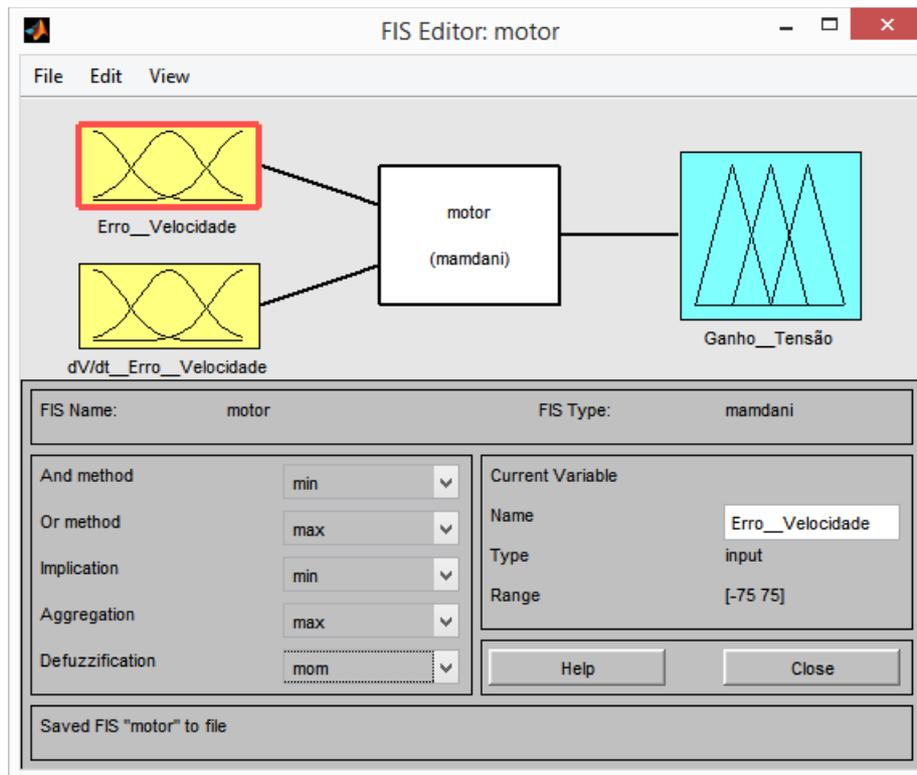


Figura 19 – Implementação feita no MatLab do controlador fuzzy

A variável “erro de velocidade” foi descrita com sete funções de pertinência triangulares, sendo as mesmas:

- NG:** Erro de Velocidade Negativo Grande.
- NM:** Erro de Velocidade Negativo Médio.
- NP:** Erro de Velocidade Negativo Pequeno.
- ZZ:** Erro de Velocidade Nulo.
- PP:** Erro de Velocidade Positivo Pequeno.
- PM:** Erro de Velocidade Positivo Médio.

PG: Erro de Velocidade Positivo Grande.

Todas as sete funções de pertinências estão descritas dentro de um intervalo que varia de +75 rpm até -75 rpm, este intervalo foi escolhido em função do escorregamento nominal do motor. A figura 20 demonstra como ficou implementada a variável de entrada “erro de velocidade” no *MatLab*.

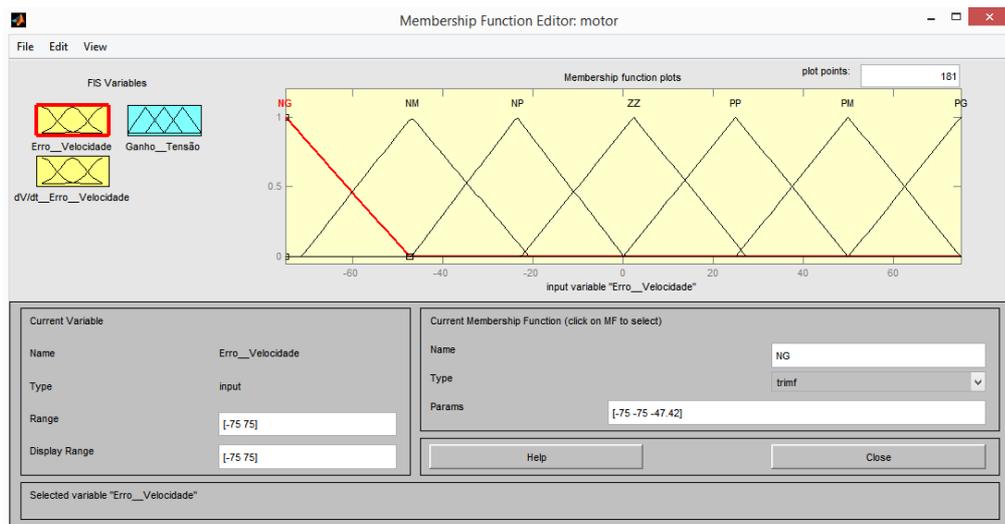


Figura 20 – Implementação feita no MatLab da variável de entrada “Erro de Velocidade”

A variável “variação do erro de velocidade” foi descrita com sete funções de pertinência triangulares, da mesma forma que a variável “erro de velocidade”, sendo as mesmas:

NG: Variação Erro de Velocidade Negativo Grande.

NM: Variação Erro de Velocidade Negativo Médio.

NP: Variação Erro de Velocidade Negativo Pequeno.

ZZ: Variação Erro de Velocidade Nulo.

PP: Variação Erro de Velocidade Positivo Pequeno.

PM: Variação Erro de Velocidade Positivo Médio.

PG: Variação Erro de Velocidade Positivo Grande.

Todas as sete funções de pertinências estão descritas dentro de um intervalo que varia de +1 até -1, de forma a indicar a tendência do erro de velocidade e o controlador poder agir para a correção do *setpoint* do ciclo de trabalho do modulador PWM trifásico. A figura 21 demonstra como ficou implementada a variável de entrada “variação do erro de velocidade” no *MatLab*.

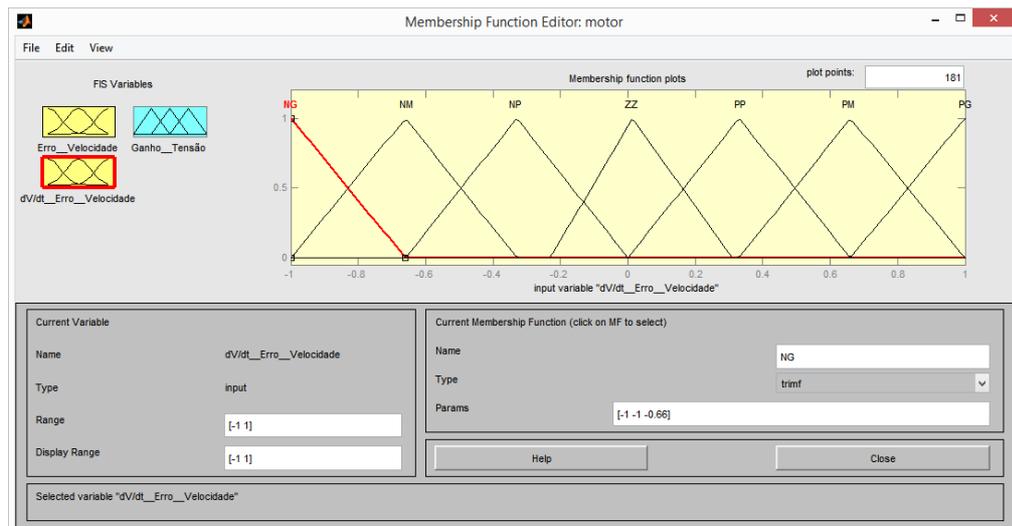


Figura 21 – Implementação feita no *MatLab* da variável de entrada “Variação do Erro de Velocidade”

Com base nas sete funções de pertinência de cada uma das duas entradas do controlador *fuzzy*, foram criadas quarenta e nove regras para o processo de

fuzzificação. Estas regras vão ativar suas respectivas funções de pertinência da variável de saída “ganho de tensão”, que após o processo de defuzzificação pelo método das médias dos máximos, vai resultar no *setpoint* para o modulador PWM trifásico. Na figura 22 estão apresentadas a composição das regras no editor *Fuzzy* do *MatLab*.

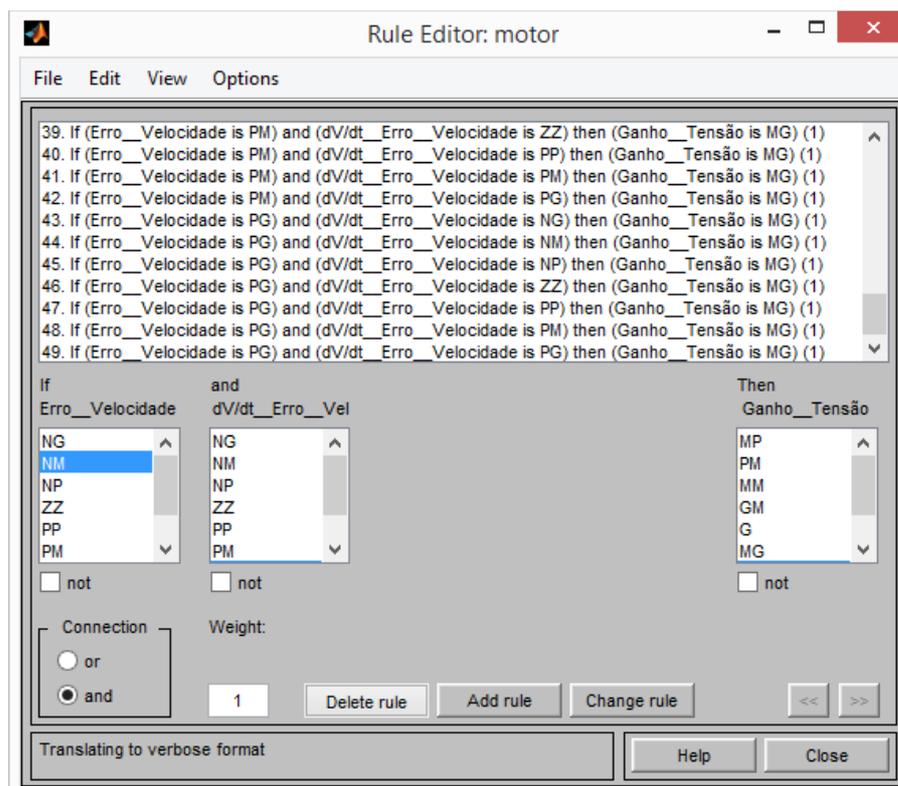


Figura 22 – Implementação das regras Fuzzy feita no MatLab

As sete funções de pertinência da variável de saída “ganho de tensão” ficaram:

MP: Ganho de Tensão Muito Pequeno.

P: Ganho de Tensão Pequeno.

PM: Ganho de Tensão Pequeno Médio.

MM: Ganho de Tensão Médio.

GM: Ganho de Tensão Grande Médio.

G: Ganho de Tensão Grande.

MG: Ganho de tensão Muito Grande.

A figura 23 mostra como ficou o ajuste das funções de pertinência da variável de saída “ganho de tensão”. O formato irregular da distribuição das funções de pertinência são devidas as não-linearidades que o motor de indução apresenta.

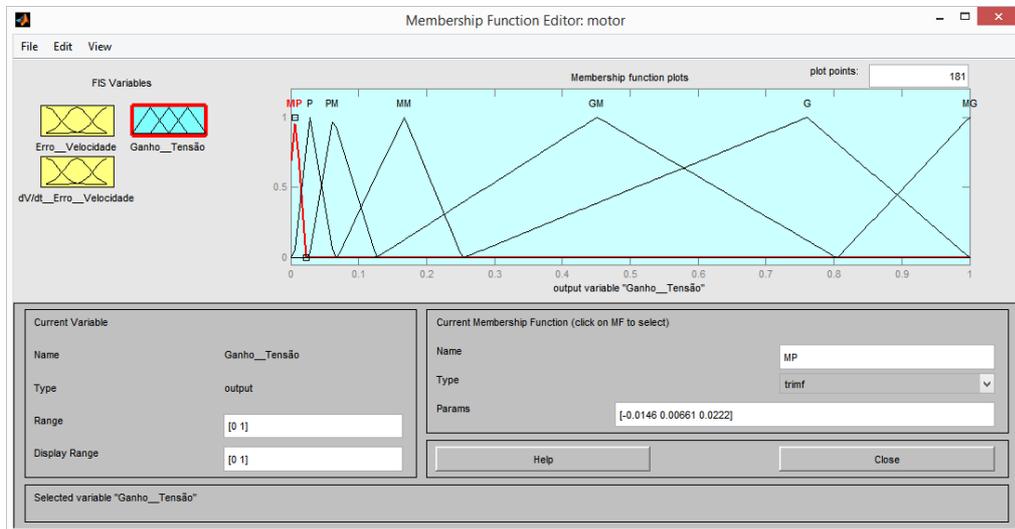


Figura 23 – Implementação feita no MatLab da variável de saída “Ganho de Tensão”

As funções de pertinência da variável de saída “ganho de tensão” estão distribuídas na faixa de 0 até 1, representando uma variação de 0 até 100% do ciclo de trabalho do PWM trifásico. Na figura 24 está a curva de superfície do controlador Fuzzy projetado.

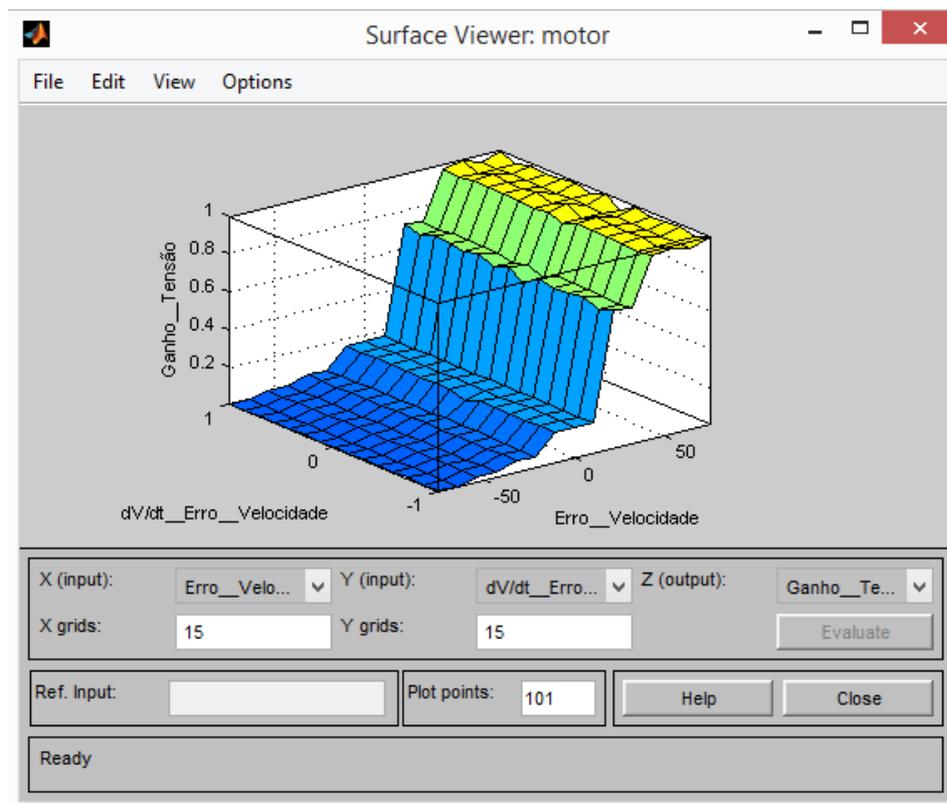


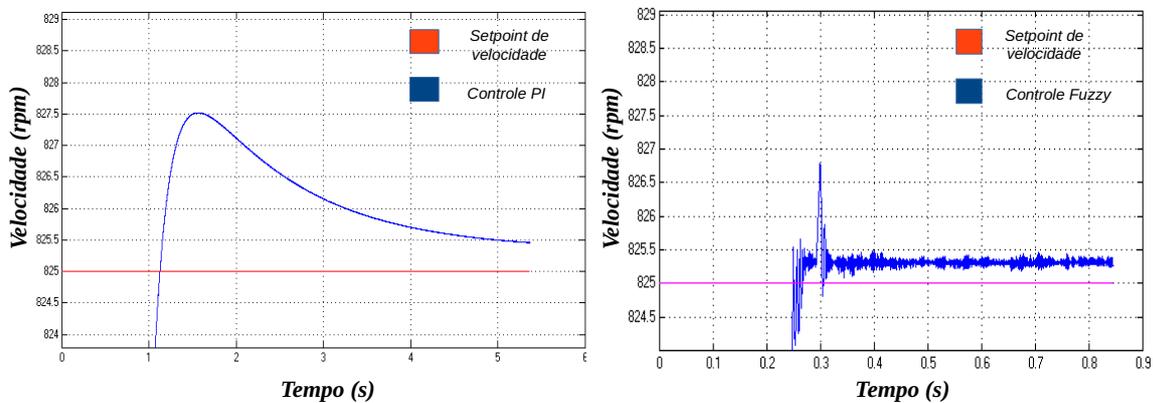
Figura 24 – Curva de superfície do controlador Fuzzy projetado

Como foi utilizado um controlador *fuzzy* do tipo Mamdani, o processo de sintonização se deu pelo método empírico, observando sempre o comportamento do motor de indução em função das condições de carga. Para um ajuste mais fino do controle, foi inserida uma variável de ajuste no sinal de entrada “erro de velocidade”, e outra no sinal de saída “ganho de tensão”. O controlador *fuzzy* foi inicialmente sintonizado para trabalhar com um setpoint de velocidade de 30Hz, sendo necessário a utilização de um bloco limitador na entrada do modulador PWM para evitar efeitos de saturação do entreferro do motor.

3.6 Análise da viabilidade da proposta

Neste item serão analisados os resultados obtidos com o controlador *fuzzy* e comparados aos resultados do controlador do tipo PI com o intuito de analisar a viabilidade da proposta.

Os mesmos testes de desempenho realizados no controlador do tipo PI foram realizados no controlador *fuzzy*. O primeiro diz respeito ao valor do sobressinal obtido após a sintonização ótima de cada controlador em questão. Como pode ser visto na figura 25, o controlador do tipo PI apresentou um sobressinal considerado aceitável e dentro das especificações do projeto, já o controlador *fuzzy* apresentou um sobressinal equiparável, em amplitude, ao do controlador do tipo PI. O que distingue as duas respostas é a forma com que ocorre a estabilização da velocidade. Enquanto o controlador do tipo PI apresenta uma curva de estabilização exponencial decrescente, o controlador *fuzzy* tem uma resposta de estabilização mais rápida e abrupta.



A) Controlador Tipo PI.

B) Controlador Fuzzy.

Figura 25 – Detalhe do sobressinal obtido com o controlador do tipo PI e o controlador fuzzy

Um outro método para comparação de desempenho entre os controladores é a análise de resposta ao arranque. Os dois tipos de controladores foram sujeitos as mesmas condições de carga e foram analisadas as curvas resultantes.

Como pode ser observado na figura 26, no controlador do tipo PI a estabilização de velocidade ocorre por volta de 1 segundo após a partida, enquanto o controlador fuzzy apresenta uma resposta de arranque mais rápida, com estabilização em torno de 0.35 segundos.

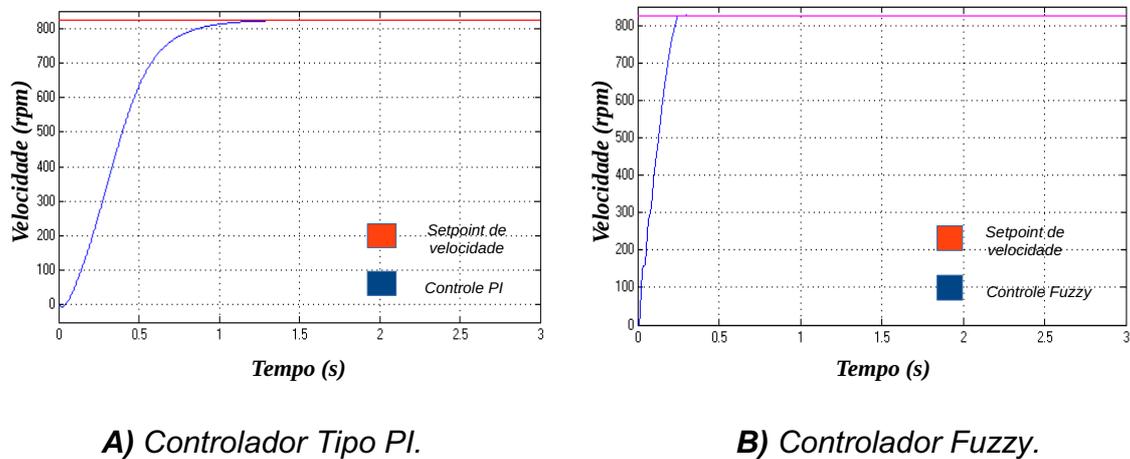
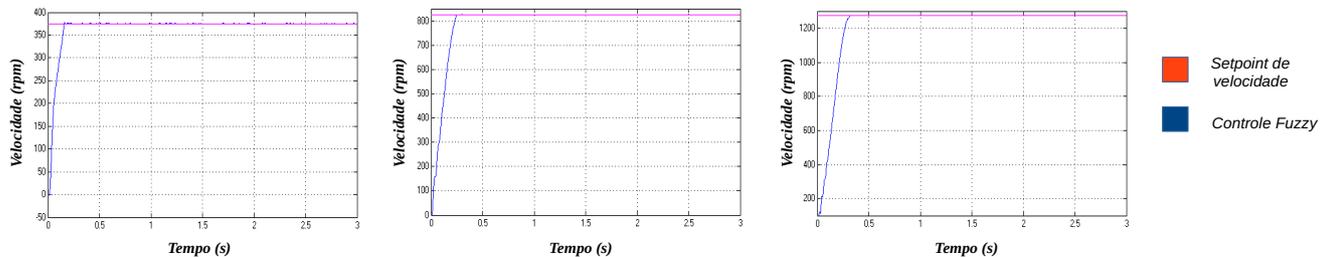


Figura 26 – Curvas de resposta ao arranque obtidas com o controlador do tipo PI e o controlador fuzzy

Será analisado a seguir o comportamento dos dois controladores frente a variação de velocidade. A figura 27 mostra o comportamento do controlador *fuzzy* frente a variação de velocidade para as frequências de 15Hz, 30Hz e 45Hz.

Como pode ser observado, o controlador *fuzzy* apresentou robustez frente a variação de velocidade mantendo praticamente o mesmo tempo de resposta ao arranque para as três situações de *setpoint*. Quando comparado com a figura 17, que

representa as curvas obtidas pelo controlador do tipo PI nas mesmas circunstâncias, fica evidente a superioridade do controlador *fuzzy*.



A) Setpoint=15Hz.

B) Setpoint=30Hz.

C) Setpoint=45Hz .

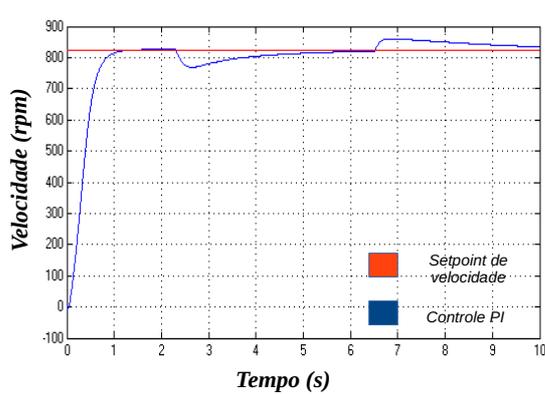
Figura 27 – Curvas de arranque do MIT com controle fuzzy:

A) Setpoint=15Hz, resposta apresentando estabilidade de velocidade

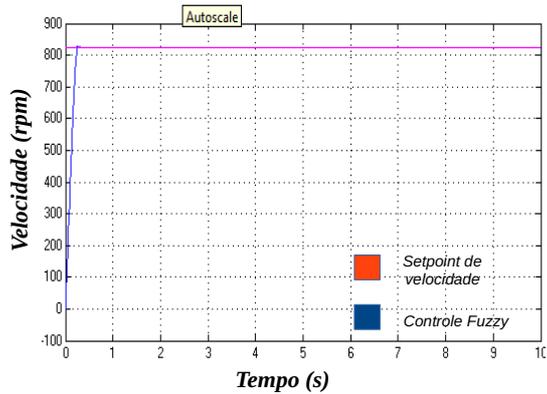
B) Setpoint=30Hz, resposta apresentando estabilidade de velocidade

C) Setpoint=45Hz, resposta apresentando estabilidade de velocidade

O último método para estabelecer um comparativo entre os dois tipos de controladores será a análise de desempenho frente a variação de carga ao eixo do motor de indução. Estando os dois controladores otimizados para um *setpoint* de velocidade de 30Hz, ambos são sujeitos a uma carga de 2,6Nm no momento do arranque. Após a estabilização da velocidade ocorre uma variação de carga ao eixo do motor para 6,6Nm. Quando ocorrer a estabilização de velocidade, a carga ao eixo varia novamente para 2,6Nm. O resultado obtido para os dois controladores é mostrado na figura 28.



A) Controlador Tipo PI



B) Controlador Fuzzy.

Figura 28 – Curvas de resposta a variação de carga ao eixo do motor obtidas com o controlador do tipo PI e o controlador fuzzy

Como pode ser verificado o controlador *fuzzy* manteve praticamente estável a velocidade do eixo do motor de indução mesmo estando sujeito a uma variação de carga de +/- 4Nm. Já o controlador do tipo PI apresentou uma resposta mais lenta para a mesma variação de carga. Vale realçar que em máquinas e equipamentos industriais reais variações de carga como as simuladas, podem acontecer com frequência, como por exemplo, em sistemas de transporte em geral e máquinas operatrizes.

3.6.1 Conclusão a respeito da Viabilidade da Proposta

O controlador *fuzzy* neste item, apresentou características de controle superiores ao controlador do tipo PI apresentado do item 3.3 em todos os requisitos testados. Embora o controlador *fuzzy* tenha demonstrado tal superioridade, comentários a respeito de seu funcionamento e sua implementação devem ser feitos.

O primeiro ponto é quanto à implementação e sintonização do controlador *fuzzy*, o método de sintonização aplicado foi empírico, o que dificulta em muito a sintonização levando a um tempo consideravelmente grande para ajustar o controlador, situação esta que já era esperada devido a utilização de um controlador *fuzzy* do tipo Mamdani. É importante colocar que para um ambiente industrial este tempo para sintonização é impraticável. Comissionamento e *start-up* de equipamentos com este tipo de controle *fuzzy* sem fazer uso de nenhum recurso computacional para sua sintonização, podem inviabilizar o emprego desta tecnologia, mesmo que após a exaustiva sintonização, os controladores *fuzzy* apresentem melhor desempenho.

O segundo ponto se refere ao comportamento da velocidade com este tipo de controle *fuzzy*. Após a estabilização da velocidade é possível notar, com a ampliação em detalhe da curva de velocidade, um sinal em forma de ruído proveniente da variação abrupta do *setpoint* do ganho de tensão do PWM trifásico gerado pelo controlador *fuzzy*. Esta variação abrupta tem origem na curva de superfície gerada pelo ajuste do controlador que não apresenta variações suaves em toda sua extensão de superfície.

Com base nos resultados obtidos até aqui com este estudo, a utilização dos controladores *fuzzy* se tornam viáveis para a implementação em controle de motores de indução quando associados a algum método de sintonização automática como é o caso da utilização das redes neurais sendo esta a proposta final deste trabalho.

4 Sistemas *Neuro-Fuzzy*

4.1 Introdução

Um sistema *neuro-fuzzy* pode ser definido como um sistema *fuzzy* que faz uso de um algoritmo baseado em redes neurais para determinação de seus parâmetros internos de controle através de uma base de dados para treinamento. Une a capacidade de lidar com sistemas não-lineares, próprias dos sistemas *fuzzy*, com a capacidade de auto-aprendizado das redes neurais (CAMPOS et al., 2004).

Os sistemas *fuzzy* visam um sistema computacional capaz de simular o pensamento humano. Estes sistemas possuem a capacidade de trabalhar com problemas complexos sem a necessidade de um modelo matemático, somente fazendo uso de termos linguísticos e um conjunto de base de regras que representam o conhecimento humano sobre determinado tipo de processo.

As principais características dos sistemas *fuzzy* são:

- possuem a capacidade de trabalhar com sistemas não-lineares;
- possibilidade de simular o conhecimento heurístico humano;
- não fazem uso de modelos matemáticos complexos;
- capacidade de lidar com informações imprecisas, da mesma forma que o ser humano.

A lógica *fuzzy* têm origem no trabalho publicado por Zadeh intitulado *Fuzzy Sets* (ZADEH, 1965). É apresentado neste trabalho, uma forma de representar o pensamento humano matematicamente utilizando conceitos abstratos, sem existir valores absolutos, onde os conjuntos de pertinência não são bem definidos e sim nebulosos. Também, neste trabalho, Zadeh apresenta o “*Princípio da*

Incompatibilidade”, postulando que, “conforme a complexidade de um sistema aumenta, a capacidade humana de tirar conclusões e tomar decisões que sejam simultaneamente precisas e significativas, tende a diminuir até o ponto onde a precisão e relevância passam a ser características excludentes”, (ZADEH, 1965). O que significa dizer que, a medida que nos aproximamos de um determinado fenômeno para descrevê-lo, mais imprecisas serão nossas conclusões a respeito deste fenômeno.

Outro trabalho de Zadeh, publicado em 1973 e intitulado *Outline of a New Approach to the Analysis of Complex Systems and Decision Processes* (ZADEH, 1973), propõe um método de computação baseado em termos linguísticos associado a matemática. Esta ideia surgiu do conceito de que o pensamento humano não é baseado em números, mas sim em classes de conjuntos ou subconjuntos nebulosos que possuem transição gradual entre si (ZADEH, 1973).

Em 1979, Procyk e Mamdani propuseram um controlador *fuzzy* que determinava seus parâmetros internos de sintonização de forma automática. O nome dado para este controlador *fuzzy* foi “*self-organizing process controller (SOC)*”, este controlador realizava medidas de desempenho do sistema de controle durante seu funcionamento e usava estes dados para ajustar seus parâmetros internos com base em critérios de desempenho pré determinados (PROCYK; MAMDANI, 1979).

O tipo de aplicação apresentada PROCYK e MAMDANI (1979) abriu caminho para a utilização de outros métodos automáticos de sintonização dos controladores *fuzzy*. Embora outros métodos de sintonização para controladores *fuzzy* tenham sido desenvolvidos, o método que mais se difundiu foi o baseado em redes neurais.

A principal vantagem da utilização das redes neurais é a de associar a capacidade de raciocínio *fuzzy* com a capacidade de aprendizagem das redes neurais. Esta união além de prover um sistema de controle robusto, permite a extração e análise dos parâmetros do sistema a ser controlado, o que em muitos casos seria inviável pelos métodos convencionais de análise devido à complexidade que tais sistemas podem apresentar (CAMPOS et al., 2004).

4.2 Conjuntos e Funções de Pertinência *fuzzy*

Observando a natureza, pode-se constatar que seus fenômenos acontecem de forma gradual, não variando suas características abruptamente. Analisar estes fenômenos através da lógica clássica pode ser inadequado, já que a lógica clássica trabalha com termos absolutos, como por exemplo, “sim” ou “não”, “falso” ou “verdadeiro”.

O raciocínio humano possui a capacidade de interpretar de forma mais adequada fenômenos que possuem transição gradual entre suas classes de conjuntos. Isso é possível já que o pensamento humano tem como base a utilização de termos linguísticos e subjetivos, que permitem interpretar a interação de classes de conjuntos completamente distintos, facilitando a compreensão de problemas reais que ocorrem na natureza.

Da mesma forma que no pensamento humano, a lógica *fuzzy* faz a associação gradual dos conjuntos e subconjuntos que compõe uma classe, permitindo que determinados elementos desta classe possam pertencer a mais de um conjunto ou subconjunto simultaneamente. Esta característica permite aos conjuntos *fuzzy* representar sistemas com base na linguagem natural humana, sem necessitar de dados de elevada precisão.

Um conjunto ou subconjunto *fuzzy* pode ser definido por uma função “ μ ” chamada de função de pertinência. Esta função associa a cada elemento que a compõe, um valor compreendido entre 0 e 1 definido como grau de pertinência. Um conjunto *fuzzy* pode ser escrito como segue:

$$\mu_A(x): x \Rightarrow [0,1]; x \in X \quad (42)$$

Sendo $\mu_A(x)$ a função de pertinência do conjunto *fuzzy* “A”, que retorna o grau de pertinência para cada termo x desta função, variando de 0 até 1, compreendido no universo de discurso X . As funções de pertinência podem ser representadas através de funções triangulares, trapezoidais, gaussianas e sigmóides. A figura 29 exemplifica a interação de dois conjuntos *fuzzy*, A_1 e A_2 , construídos a partir de funções triangulares.

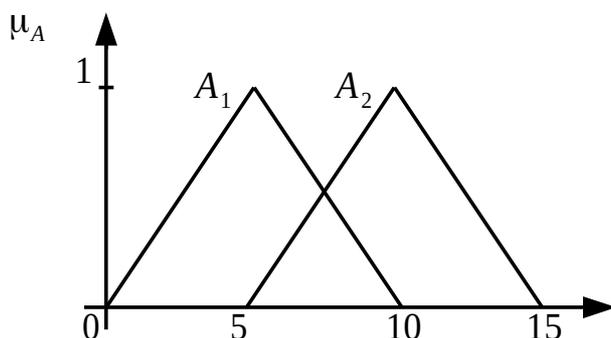


Figura 29 – Exemplo de funções de pertinência. Conjunto A_1 s e A_2

(Fonte: Do Autor)

Como pode ser visto na figura 29, os conjuntos *fuzzy* representados por A_1 e A_2 interagem entre si no intervalo [5,10]. Sendo assim, os termos compreendidos dentro deste intervalo não são definidos em termos absolutos como é o caso da lógica clássica, mas sim através do grau de pertinência que cada termo possui em relação aos conjuntos que pertencem, e o grau de pertinência varia gradualmente, de forma relativa, a medida que os termos se deslocam em direção a cada conjunto.

Pode-se dizer que a propriedade fundamental da lógica *fuzzy* é que cada função de pertinência compreende valores no intervalo [0,1]. Implicando que determinado elemento possa pertencer parcialmente a um conjunto, esse nível de veracidade é determinado através de um valor fracionário dentro do intervalo numérico representado pelo grau de pertinência (SIMÕES et al., 2007).

4.2.1 Inferência *fuzzy*

O processo de inferência *fuzzy* se dá pela utilização dos operadores *máx.* e *mín.* Estes operadores representam a implementação da função lógica “OU” para operador *máx.* e da função lógica “E” para o operador *mín.*

Segundo SIMÕES *et al* (2007), o operador *máx.* é mais utilizado na composição das saídas *fuzzy* de cada regra, enquanto que o operador *mín.*, tem sido mais usado na composição de vários conjuntos *fuzzy* de entrada de uma regra.

A aplicação dos operadores de inferência está sempre associada a uma base de regras *fuzzy* que exprimem um raciocínio *fuzzy*. Esta base de regras relaciona os conjuntos *fuzzy* usando o modo de implicação chamado de *modus ponens*, este modo de implicação trabalha na forma de **SE** ($X=A$) **ENTÃO** ($Y=B$), onde ($X=A$) é chamado de condição antecedente e ($Y=B$) é chamado de conseqüente lógico. Na figura 30, está um exemplo de como ocorre uma inferência *fuzzy*.

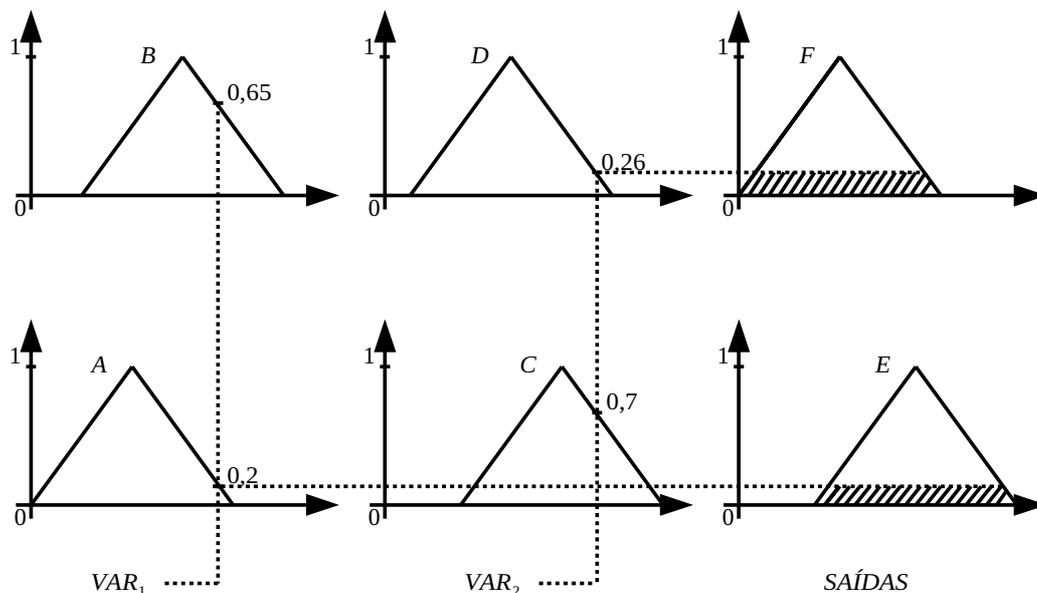


Figura 30 – Inferência fuzzy utilizando operado mín.

(Fonte: Do Autor)

Para a figura 30, pode-se aplicar o seguinte conjunto de regras:

REGRA 1 – **SE** $VAR_1=A$ **E** $VAR_2=C$ **ENTÃO** $SAÍDA=E$

REGRA 2 – **SE** $VAR_1=B$ **E** $VAR_2=D$ **ENTÃO** $SAÍDA=F$

Aplicando o operador de inferência *mín.* para os conjuntos de entrada, têm-se as respectivas saídas *fuzzy* para cada regra, sendo as mesmas representadas pelos conjuntos *E* e *F* na figura 30.

Neste ponto não se fará referência ao método utilizado para a associação das saídas *fuzzy* (defuzzificação), adiante quando for discutido a respeito do controlador *ANFIS*, serão feitas considerações a respeito desta etapa.

4.2.2 Estrutura do sistema *fuzzy*

Um sistema *fuzzy* é composto por blocos, que com base na resposta do sistema a ser controlado, determinam a ação de comando a ser tomada. Cada bloco possui uma função específica, como demonstrado na figura 31, e podem ser classificados como: codificação, base de conhecimento, decodificação e raciocínio *fuzzy*.

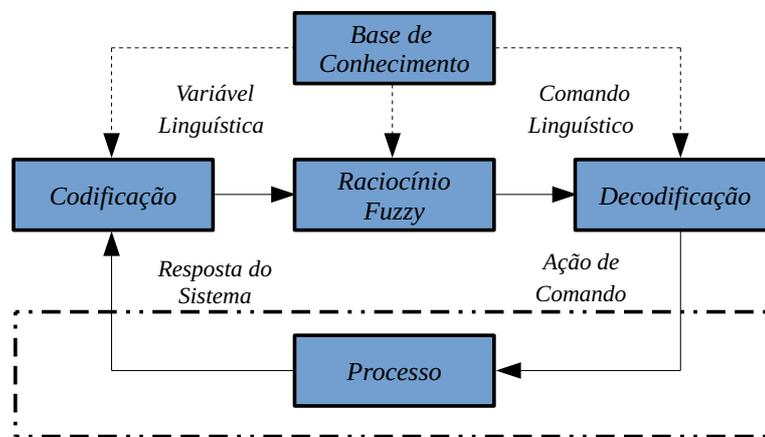


Figura 31 – Arquitetura geral de um sistema *fuzzy*

(Fonte: Do Autor)

- **Codificação:** este bloco é responsável pelo processo de fuzzyficação das variáveis provenientes da resposta do sistema. Ele executa uma varredura das variáveis do processo e faz um ajuste de escala para cada uma delas, de forma a normalizá-las dentro do universo de discurso de cada conjunto. Após esta etapa, determina o grau de pertinência para cada valor de entrada normalizado em função das variáveis linguísticas estabelecidas inicialmente em projeto.

- **Base de conhecimento:** etapa responsável pela base de regras do sistema *fuzzy*. Neste bloco estão contidos todos os parâmetros dos valores linguísticos, funções de pertinência e demais variáveis que, estão diretamente associadas a estratégia de controle adotada em função das características do processo a ser controlado.

- **Raciocínio *fuzzy*:** o processo de inferência *fuzzy* ocorre neste bloco. Os dados *fuzzy* provenientes da entrada do controlador, são inseridos na base de regras do sistema *fuzzy* originando um conjunto de dados que representa o grau de pertinência para cada variável *fuzzy* de entrada do controlador. Após esta etapa, ocorre a operação entre os conjuntos *fuzzy* de cada regra, esta operação é realizada através do operador de implicação *mín*.

- **Decodificação:** a etapa de decodificação é responsável por determinar a ação de controle efetiva do sistema de controle *fuzzy*, este processo é chamado de defuzzificação. A partir das variáveis linguísticas de cada regra, e do resultado obtido no processo de inferência, é calculado o valor de saída para o controlador. Esse valor de saída pode ser calculado a partir de diversos métodos, entretanto, se tratando de sistemas *fuzzy* não-paramétricos, na prática são mais comuns o método do centro de área (COA), e o método da média dos máximos (MOM), (NASCIMENTO et al., 2000).

4.3 Sistemas *neuro-fuzzy* adaptativos

Um sistema *fuzzy* adaptativo pode ser definido como um sistema *fuzzy* capaz de determinar seus parâmetros internos e sua base regras através de métodos computacionais específicos. Inserido neste contexto, está o *Adaptive Neuro-Fuzzy Inference System (ANFIS)*, que traduzindo significa sistema de inferência *neuro-fuzzy* adaptativo.

O *ANFIS* é composto por um controlador *fuzzy* do tipo paramétrico, e uma rede neural que faz uso de um algoritmo baseado em regressão linear para seu treinamento. Este algoritmo tem como função determinar, de forma otimizada, os parâmetros internos do controlador *fuzzy*. Isso é feito com o auxílio de uma base de dados que representa o comportamento do sistema ou processo que se deseja controlar. Desta forma, o *ANFIS* consegue mapear o comportamento de sistemas, sejam lineares ou não-lineares.

Devido a estas características, o *ANFIS* tem sido aplicado em diversas áreas da engenharia. Principalmente onde se faz necessário a estimação de parâmetros e o controle não-linear, como é o caso das aplicações em acionamentos elétricos para motores de indução (LIMA, 2010).

4.3.1 Controladores *fuzzy* paramétricos

O *ANFIS* faz uso de controladores *fuzzy* do tipo paramétrico para determinar os consequentes de cada regra, sendo este um método de inferência *fuzzy*. Basicamente existem dois métodos de inferência que podem ser utilizados em controle *fuzzy*, os baseados totalmente em termos linguísticos, como por exemplo o método Mamdani, onde os antecedentes e consequentes são determinados por conjuntos *fuzzy*, e o tipo

Takagi-Sugeno, onde os consequentes são constituídos por funções polinomiais lineares, sendo este tipo utilizado pelo *ANFIS*.

Os controladores *fuzzy* paramétricos fazendo uso de um conjunto de equações polinomiais lineares para determinar os consequentes de cada regra, necessitam que os coeficientes destas funções sejam ajustados em função do comportamento do sistema a ser controlado. Em 43 está o exemplo de uma regra com consequente em forma de função polinomial linear:

$$\mathbf{SE} \ X=A \ \mathbf{E} \ Y=B \ \mathbf{ENTÃO} \ Z=f(x,y) \quad (43)$$

onde Z é escrito como segue:

$$Z=a.x+b.y+c \quad (44)$$

sendo a , b e c os coeficientes de regressão da função polinomial de aproximação Z . Estes coeficientes são ajustados através de um algoritmo de regressão linear baseado em redes neurais, como por exemplo o *backpropagation*, que com o auxílio de uma base de dados que representa o comportamento do processo a ser controlado, consegue determinar estes coeficientes. O resultado deste processo é um conjunto de funções polinomiais, cada função representa um consequente para cada regra *fuzzy*, e com a associação de todas estas funções, é possível descrever a geometria da curva de superfície do sistema a ser controlado.

A figura 32 ilustra o resultado do processo de ajuste dos coeficientes, a curva em vermelho representa a geometria de superfície do sistema a ser controlado. Para cada conjunto *fuzzy* existe uma função polinomial que descreve parte da curva de superfície do sistema.

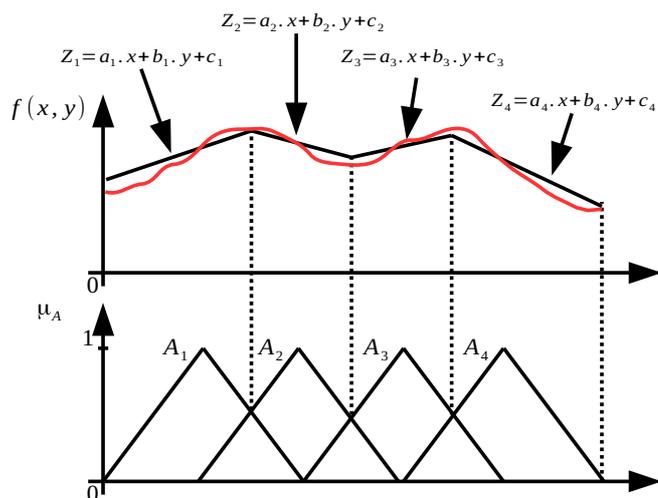


Figura 32 – Representação de uma função através de um modelo fuzzy paramétrico

(Fonte: Do Autor)

O processo de defuzzyficação de um controlador paramétrico Takagi-Sugeno se dá pela média ponderada de seus consequentes e seus respectivos valores de pertinência. A figura 33 exemplifica o processo de inferência que servirá como base para a defuzzyficação.

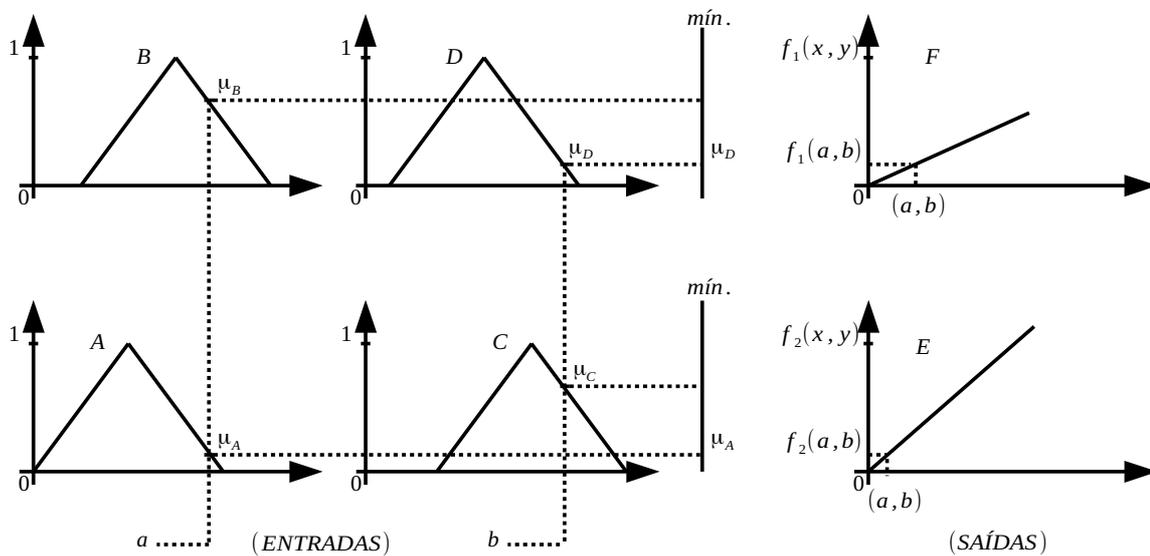


Figura 33 – Inferência fuzzy paramétrica

(Fonte: Do Autor)

O resultado da inferência *fuzzy* paramétrica, gera valores de pertinência e a ativação de suas respectivas funções polinomiais (consequentes), como pode ser visto na figura 33. A equação 45 é usada para determinar a saída defuzzyficada.

$$Saída_{fuzzy} = \frac{\mu_A \cdot f_2(a, b) + \mu_D \cdot f_1(a, b)}{f_1(a, b) + f_2(a, b)} \quad (45)$$

Com o auxílio da equação 45 é possível, então, executar a defuzzyficação do exemplo da figura 33 baseando-se nos valores obtidos do processo de inferência paramétrica.

Os controladores *fuzzy* paramétricos embora percam a formulação linguística de seus consequentes quando comparados com os baseados em regras, possuem a vantagem de prover uma maior interpretação matemática do processo a ser controlado. Outra vantagem está no uso de algoritmos de regressão linear utilizando redes neurais para o ajuste dos coeficientes do controlador, isso resultada numa curva de superfície otimizada e com transições suaves em toda sua extensão, ao contrário dos resultados obtidos com os controladores baseados em regras, (SIMÕES et al., 2007).

4.3.2 Estrutura do controlador *neuro-fuzzy*

Aqui será abordada de forma breve a composição estrutural de um controlador *neuro-fuzzy*. Um sistema de controle *neuro-fuzzy* é composto por três partes básicas: premissa, consequente e decodificação. Cada uma destas partes é composta por blocos ou camadas com funções específicas. A figura 34 exemplifica a composição de um controlador *neuro-fuzzy* de duas entradas.

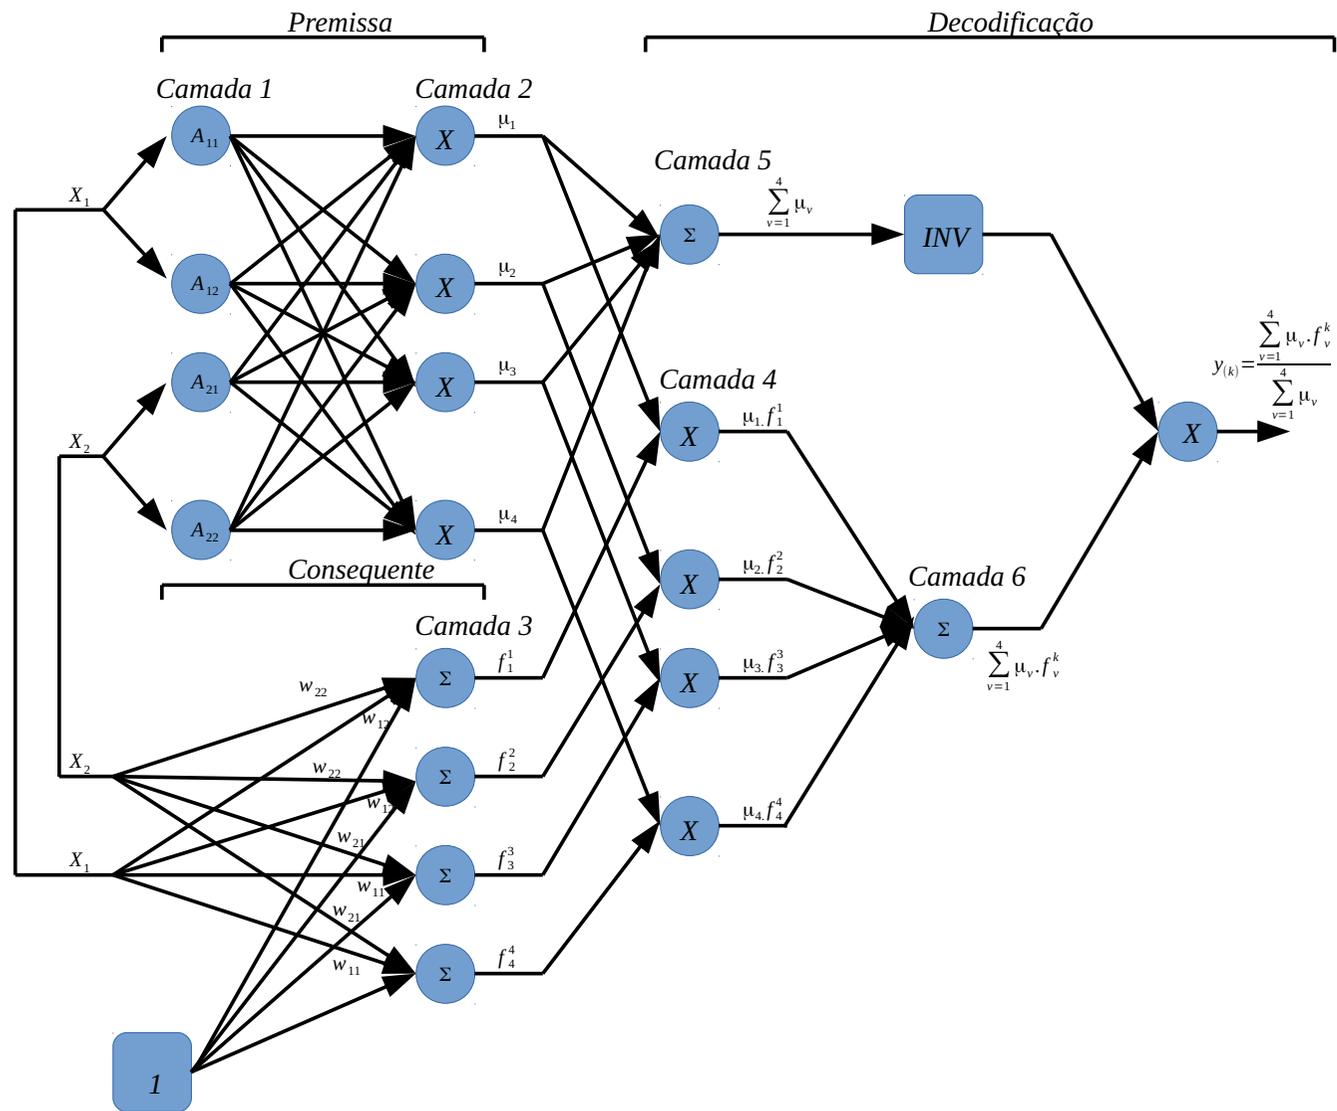


Figura 34 – Estrutura de controlador neuro-fuzzy de duas entradas
(Fonte: Do Autor)

A premissa é composta pelas seguintes camadas:

Camada 1: a camada 1 é composta pelas entradas do controlador, cada uma destas entradas é representada por uma variável linguística que é associada a sua respectiva função de pertinência. O resultado de cada uma destas associações, que equivale a saída da camada 1, compõe os antecedentes para o conjunto de regras *fuzzy* existente na camada 2. Por exemplo, a entrada X_1 na figura 34, associada ao nó A_{11} , poderia representar um termo linguístico “muito alto” ou “muito baixo” da variável de entrada X_1 .

Camada 2: na camada 2 estão todas as regras *fuzzy* do controlador, as entradas desta camada são os antecedentes gerados na camada 1. A saída desta camada é determinada através da ativação das regras sujeitas a suas respectivas entradas por meio dos operadores de inferência *min*. Por exemplo, para a seguinte regra **SE** $X_{11}(A_{11})$ **E** $X_{12}(A_{12})$, têm-se a função de pertinência μ_1 variando de 0 até 1.

A segunda parte do controlador *neuro-fuzzy* é composta pelo consequente, suas camadas são:

Camada 3: a camada 3 é composta pelo conjunto de funções polinomiais lineares, sendo seus coeficientes os pesos sinápticos de cada neurônio que a compõe. A saída de cada neurônio equivale ao consequente de cada regra *fuzzy* associada a camada 2. Para a figura 34, a função polinomial número um é formada como segue:

$$f_1^1 = 1 + W_{11}^1 \cdot X_{11} + W_{12}^1 \cdot X_{12} + W_{22}^1 \cdot X_{22} + W_{21}^1 \cdot X_{21} \quad (46)$$

A última parte do controlador *neuro-fuzzy* é a decodificação, e é composta pelas seguintes camadas:

Camada 4: a camada 4 executa o produto do resultado da camada 2 (regras ativadas) pelo resultado de saída da camada 3 (consequente). O resultado é a ponderação das regras pelas suas respectivas ativações.

Camada 5: a camada 5 é responsável por realizar o somatório das saídas da camada 2 (regras ativadas).

Camada 6: a camada 6 executa o somatório da camada 4 (ponderação das regras pelas respectivas ativações).

Camada 7: e por fim a camada 7. Esta camada representa a saída do sistema, ela executa a razão entre a camada 6 (somatório ponderado da camada 4) e a camada 5 (somatório das regras ativadas).

O resultado matemático do controlador pode ser observado na equação 47 que é a função de saída *neuro-fuzzy* $y_{(k)}$ na forma geral:

$$y_{(k)} = \frac{\sum_{v=1}^N \mu_v \cdot f_v^k}{\sum_{v=1}^N \mu_v} \quad (47)$$

onde k representa o número de regras *fuzzy* do controlador e v o número de funções polinomiais lineares.

Como pode ser observado na equação 47, a saída do controlador *neuro-fuzzy* é equivalente a saída de um controlador *fuzzy* Takagi-Sugeno. Sendo assim, os parâmetros do controlador *neuro-fuzzy* podem ser interpretados como parâmetros internos de um controlador *fuzzy* paramétrico (CAMPOS et al., 2004).

5 Metodologia Proposta para Implementação do Controle *Neuro-Fuzzy* para MIT

5.1 Introdução

Este capítulo tem como objetivo apresentar a metodologia adotada para o desenvolvimento e implementação do sistema de controle *neuro-fuzzy* aplicado ao controle de motores de indução trifásicos.

A proposta de dissertação consiste em implementar uma estrutura de controle capaz de garantir estabilidade de velocidade, rápida resposta transitória e o máximo de eficiência energética do motor de indução. Este sistema de controle deve ser capaz de trabalhar em frequências na faixa de 5Hz até 60Hz, considerando carga resistente ao eixo variando de 5% até 100% da potência nominal do motor de indução.

Através da fundamentação teórica dos Capítulos 2 e 3, desenvolveu-se um sistema de controle do tipo PI *sensorless* que permitiu o levantamento dos dados de treinamento para o sistema *neuro-fuzzy*. Estes dados representam pontos de estabilidade de velocidade com a máxima eficiência energética do motor de indução, compondo assim, as curvas V/f para cada ponto de trabalho do motor.

Fazendo-se uso de um controlador *neuro-fuzzy*, é possível reproduzir através de treinamento adequado, o conjunto de curvas V/f do motor de indução, tendo como base os dados levantados com a utilização do controlador PI e o modelo do motor em regime permanente. Com isso, espera-se que o sistema de controle proposto com o controlador *neuro-fuzzy*, reproduza de forma satisfatória os pontos de estabilidade de velocidade com o máximo de eficiência energética, da mesma forma que o controlador

PI alcançou, com a vantagem de prover resposta transitória mais rápida para qualquer ponto de operação de carga e velocidade.

O sistema de controle proposto foi desenvolvido no ambiente *MatLab/Simulink*, fazendo uso do *SimPowerSystem* para a implementação dos modelos que descrevem o motor de indução, e do *Adaptive Neuro-Fuzzy Inference Systems* (ANFIS) para a implementação do controlador *neuro-fuzzy*. Foi escolhida esta ferramenta devido ao fato da mesma conter os requisitos necessários para implementação de sistemas distintos, como os que estão presentes neste trabalho, garantindo a interação destes de forma plena e, ainda, fornecer um ambiente gráfico que facilita a geração de gráficos e tratamento dos dados.

5.1.1 Características do sistema de controle proposto

O sistema de controle proposto tem como base um controlador *neuro-fuzzy*. A função deste controlador é executar o controle de torque e velocidade do motor através da variação do ciclo de trabalho do modulador PWM trifásico.

A figura 35 exemplifica a configuração básica do controlador *neuro-fuzzy*. Este controlador é composto por duas entradas e uma saída. As entradas realizam a leitura do torque resistente ao eixo e do *setpoint* de velocidade imposta ao estator da máquina. Já a saída, é responsável em estabelecer o *setpoint* do ciclo de trabalho do modulador PWM trifásico.

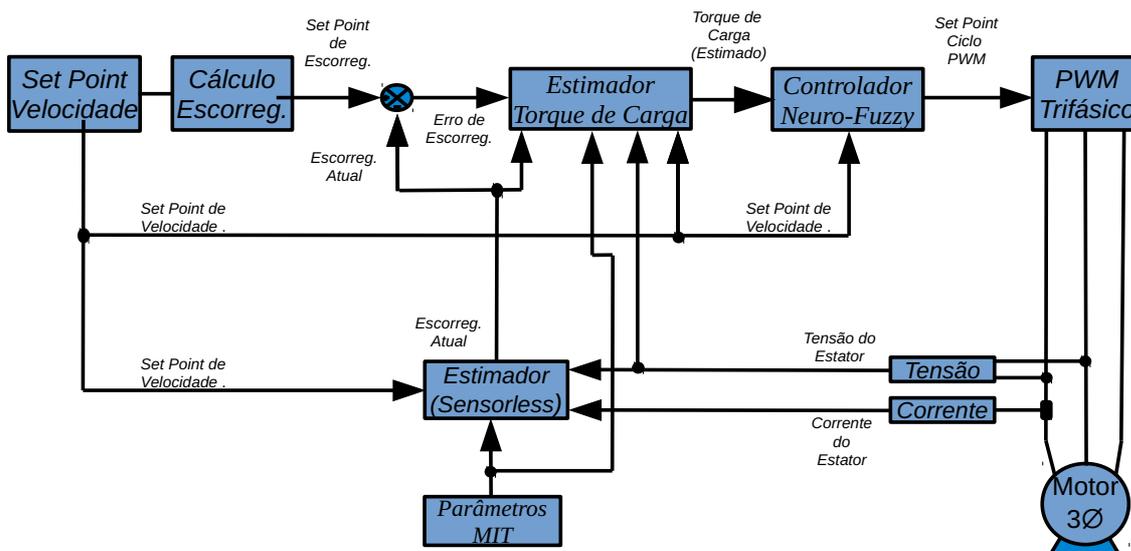


Figura 35 – Estrutura do controle neuro-fuzzy proposto

(Fonte: Do Autor)

O sistema ainda faz uso de um bloco estimador de carga. A função deste bloco é melhorar a resposta transitória de partida do motor. Isso se faz necessário já que o controlador *neuro-fuzzy* detecta o torque de carga no início da partida e impõe a energia proporcional a esta carga, o resultado é uma resposta transitória de partida mais lenta. Para contornar isso, o sistema de controle impõe o máximo de energia ao motor no momento da partida, esta condição prevalecerá até o momento em que a rotação do eixo alcance o *setpoint* de velocidade, neste instante o controlador *neuro-fuzzy* corrige imediatamente a tensão imposta ao motor garantindo a estabilidade da rotação.

5.2 Estratégia para levantamento dos dados de treinamento

Nesta secção será apresentada a estratégia para a obtenção dos dados de treinamento do controlador *neuro-fuzzy*.

O sistema de controle desenvolvido no Capítulo 3 tem como função estabelecer o correto conjugado eletromagnético do motor de indução, levando-se em conta a máxima eficiência energética do sistema. Para isso, o sistema de controle adota como critério a otimização do escorregamento do motor. Este método consiste em determinar a tensão imposta ao estator da máquina, tendo em vista a carga solicitada ao eixo e o escorregamento nominal do motor. A principal característica desta técnica é a geração de uma relação V/f dinâmica, esta relação vai representar pontos de estabilidade de rotação do eixo do motor com o máximo de eficiência energética do sistema.

Os pontos da relação V/f do modelo de controle desenvolvido no Capítulo 3, quando agrupados de forma organizada, geram uma curva de superfície otimizada do funcionamento do motor de indução. Este conjunto de dados, são a base para o treinamento do sistema *neuro-fuzzy* proposto. Com o devido treinamento do controlador *neuro-fuzzy*, este consegue através da supervisão contínua do torque resistente ao eixo do motor e da frequência imposta ao estator da máquina, determinar em sua saída o ciclo de PWM que será proporcional a geração do torque eletromagnético requerido pela carga. Como toda a informação do comportamento do motor está inserida no controlador *neuro-fuzzy*, todo o processo de controle ocorre com rapidez e precisão, garantindo que o comportamento dinâmico do sistema apresente características superiores ao do sistema de controle desenvolvido no Capítulo 3.

A tabela 1 mostra o agrupamento dos dados de treinamento para o controlador *neuro-fuzzy*.

Ordem	Frequência (Hz)	Torque (Nm)	Tensão (V)	Ordem	Frequência (Hz)	Torque (Nm)	Tensão (V)
1	60	10	219	61	30	10	108.9
2	60	9	208.6	62	30	9	103.5
3	60	8	197.8	63	30	8	97.87
4	60	7	186.4	64	30	7	91.88
5	60	6	174.2	65	30	6	85.47
6	60	5	161.1	66	30	5	78.54
7	60	4	146.8	67	30	4	70.94
8	60	3	131	68	30	3	62.41
9	60	2	112.9	69	30	2	52.53
10	60	1	91.4	70	30	1	40.29
11	55	10	200.3	71	25	10	90.47
12	55	9	190.8	72	25	9	86.39
13	55	8	180.8	73	25	8	81.87
14	55	7	170.3	74	25	7	76.59
15	55	6	159	75	25	6	71.47
16	55	5	146.9	76	25	5	65.46
17	55	4	133.7	77	25	4	58.99
18	55	3	119	78	25	3	51.8
19	55	2	102.3	79	25	2	43.36
20	55	1	82.19	80	25	1	32.56
21	50	10	181.7	81	20	10	73.49
22	50	9	173.1	82	20	9	69.57
23	50	8	163.9	83	20	8	65.72
24	50	7	154.3	84	20	7	61.61
25	50	6	144	85	20	6	57.21
26	50	5	132.9	86	20	5	52.45
27	50	4	121.1	87	20	4	47.21
28	50	3	107.3	88	20	3	41.31
29	50	2	92.07	89	20	2	34.42
30	50	1	72.77	90	20	1	25.74
31	45	10	163.3	91	15	10	55.61
32	45	9	155.5	92	15	9	52.81
33	45	8	147.2	93	15	8	49.85
34	45	7	138.5	94	15	7	46.71
35	45	6	129.1	95	15	6	43.34
36	45	5	119	96	15	5	39.68
37	45	4	108	97	15	4	35.65
38	45	3	95.74	98	15	3	31.1
39	45	2	81.64	99	15	2	25.77
40	45	1	64.53	100	15	1	19.0
41	40	10	144.9	101	10	10	38.15
42	40	9	137.9	102	10	9	36.21
43	40	8	130.7	103	10	8	34.16
44	40	7	122.9	104	10	7	31.98
45	40	6	114.5	105	10	6	29.65
46	40	5	105.5	106	10	5	27.11
47	40	4	95.63	107	10	4	24.31
48	40	3	84.54	108	10	3	21.14
49	40	2	71.79	109	10	2	17.41
50	40	1	56.23	110	10	1	12.63
51	35	10	126.9	111	5	10	20.89
52	35	9	120.73	112	5	9	19.82
53	35	8	114.18	113	5	8	18.69
54	35	7	107.1	114	5	7	17.48
55	35	6	99.7	115	5	6	16.19
56	35	5	91.83	116	5	5	14.78
57	35	4	83	117	5	4	13.23
58	35	3	73.15	118	5	3	11.46
59	35	2	61.82	119	5	2	9.37
60	35	1	47.89	120	5	1	6.67

Tabela 1 – Agrupamento dos dados de treinamento para o controlador Neuro-Fuzzy

Nesta tabela estão dispostos os dados da variação de tensão imposta ao motor de indução em função da variação do *setpoint* de velocidade (frequência imposta) e da carga imposta ao eixo do motor. Foram amostrados 120 pontos para a formação desta tabela. Para cada frequência estabelecida como referência, o motor foi sujeito a um incremento de carga de 1 Nm por ponto de amostra, esse incremento ocorreu numa faixa de 1Nm até 10Nm para cada frequência. Para o *setpoint* de velocidade (frequência imposta), o incremento foi de 5Hz para cada frequência de amostra numa faixa de 5Hz até 60Hz. O resultado deste processo se encontra na tabela 1. Cada ponto representa um ponto de estabilidade de rotação do eixo motor com o máximo de eficiência energética do sistema. Na figura 36, é possível verificar o formato da curva de superfície gerada em função dos pontos amostrados.

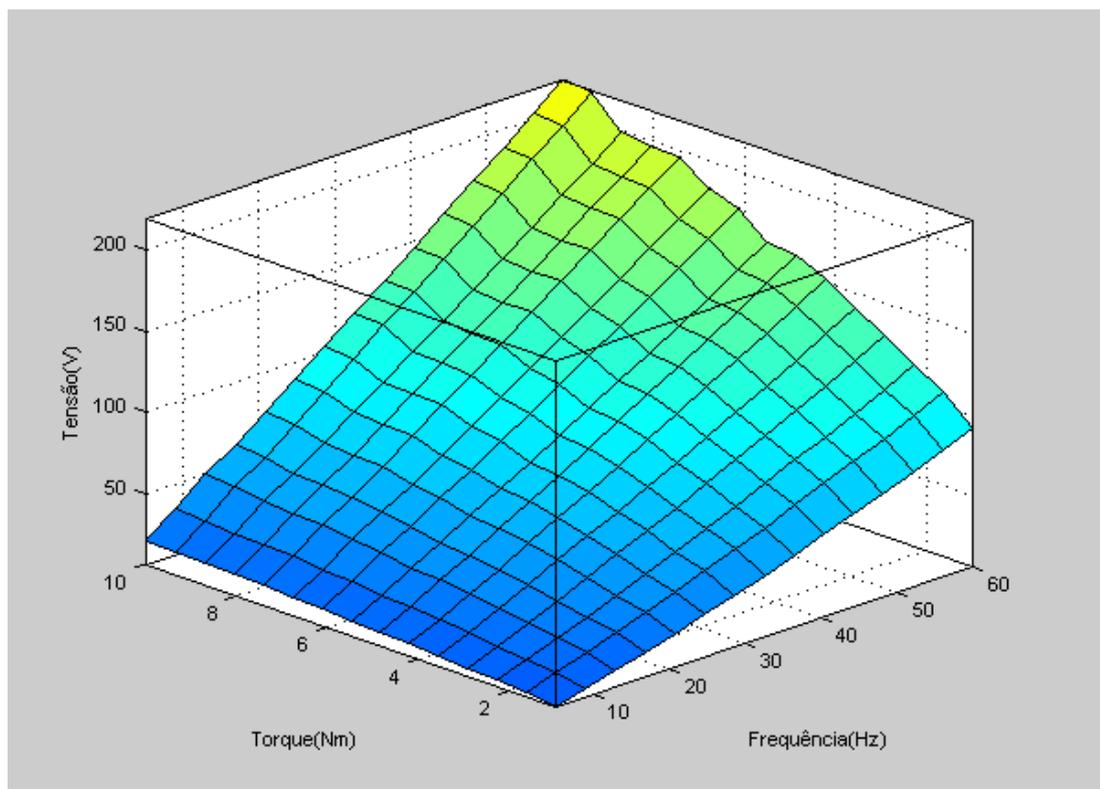


Figura 36 – Curva de superfície gerada a partir dos dados de treinamento da tabela 1

Como pode ser observado na figura 36, a superfície apresenta formato não-linear. Este formato justifica a variação de performance dos controladores convencionais do tipo PI para diferentes regiões de trabalho do motor de indução (GOEDEL et al, 2010).

5.3 Estrutura do controlador *neuro-fuzzy* para controle do MIT

Aqui serão apresentadas as características relacionadas à composição e ao treinamento do controlador *neuro-fuzzy*. Também serão tratadas as justificativas para a composição das funções de pertinência e o método de treinamento adotado.

• Funções de pertinência para as variáveis de entrada

O controlador proposto possui como variáveis de entrada a velocidade (frequência imposta) e a carga solicitada ao eixo do motor. Tendo em vista, desenvolver um sistema que obtivesse o máximo de desempenho com o mínimo de esforço computacional, foi adotado para as variáveis de entrada funções de pertinência triangulares. Esta escolha se deu através da comparação de performance entre a função do tipo triangular e a do tipo gaussiana. Embora a do tipo gaussiana tenda a apresentar melhores resultados, como demonstrado em GOEDEL (2003) e MINOTTI (2008), a performance apresentada pelo sistema de controle utilizando funções de pertinência gaussiana não foi significativamente superior ao ponto de determinar sua escolha.

O número de funções de pertinência adotado para cada uma das entradas foram 7. Cada função recebendo a designação como segue:

MP: Muito Pequeno;

P: Pequeno;

PP: Pouco Pequeno;

M: Médio;

PG: Pouco Grande;

G: Grande;

MG: Muito Grande.

A figura 37, ilustra as funções de pertinência da variável frequência após o treinamento. O universo de discurso para esta variável ficou entre 5Hz até 60Hz.

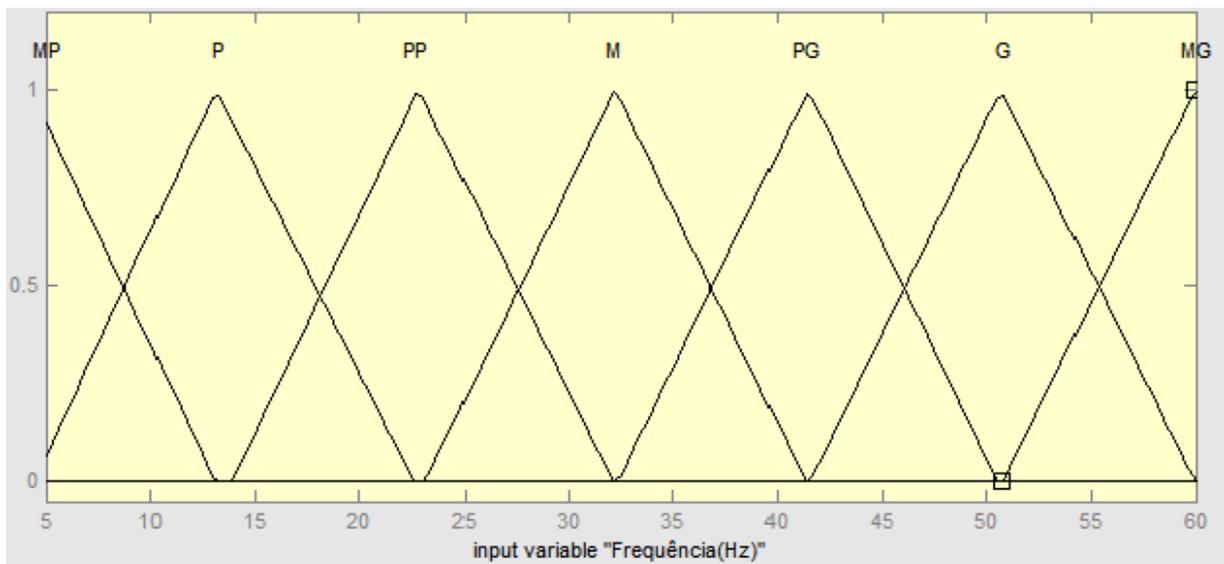


Figura 37 – Funções de pertinência para a variável “Frequência (Hz)”

A figura 38, ilustra as funções de pertinência da variável torque após o treinamento. O universo de discurso para esta variável ficou entre 1Nm até 10Nm.

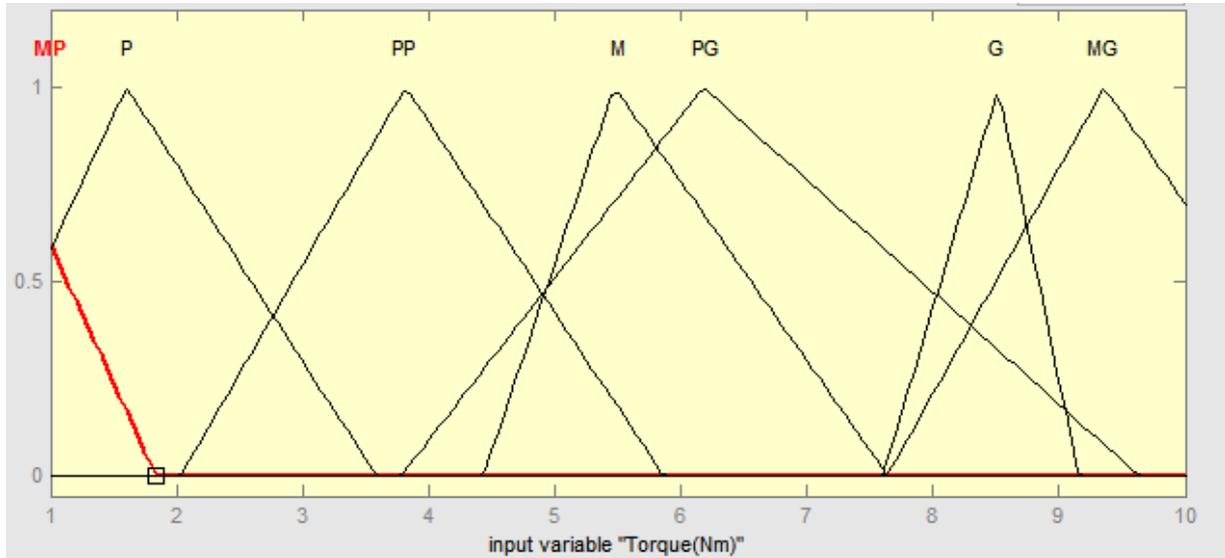


Figura 38 – Funções de pertinência para a variável “Torque (Nm)”

A adoção de 7 funções de pertinência para cada variável de entrada, resultou num total de 49 regras. O número de funções de pertinência foi escolhido através de simulações de várias configurações, objetivando um conjunto mínimo de regras que garantisse os requisitos de performance do sistema de controle.

• Funções de saída do controlador

No ANFIS é possível configurar dois tipos de funções de saída, a função linear e a função constante. Ambas foram testadas, a função constante apresentou elevado erro durante a fase de treinamento. Optou-se por adotar a função linear já que a mesma, além de apresentar um melhor desempenho em relação ao erro na fase de treinamento, apresenta um esforço computacional menor.

- **Algoritmo de treinamento**

O ANFIS dispõe de dois métodos para treinamento de redes neurais, o método híbrido e o *backpropagation*. Ambos os métodos foram testados apresentando resultados equivalentes no quesito erro de treinamento, no entanto, o método híbrido convergiu para o erro estipulado utilizando um número de épocas menor que o *backpropagation*. Desta forma, adotou-se pelo método híbrido para treinamento do controlador *neuro-fuzzy*.

5.3.1 Esquema geral de treinamento do controlador *Neuro-Fuzzy*

Para finalizar o capítulo, apresenta-se graficamente, na figura 39, uma esquematização geral da metodologia adotada para o desenvolvimento e validação do sistema de controle *neuro-fuzzy* aplicado ao MIT.

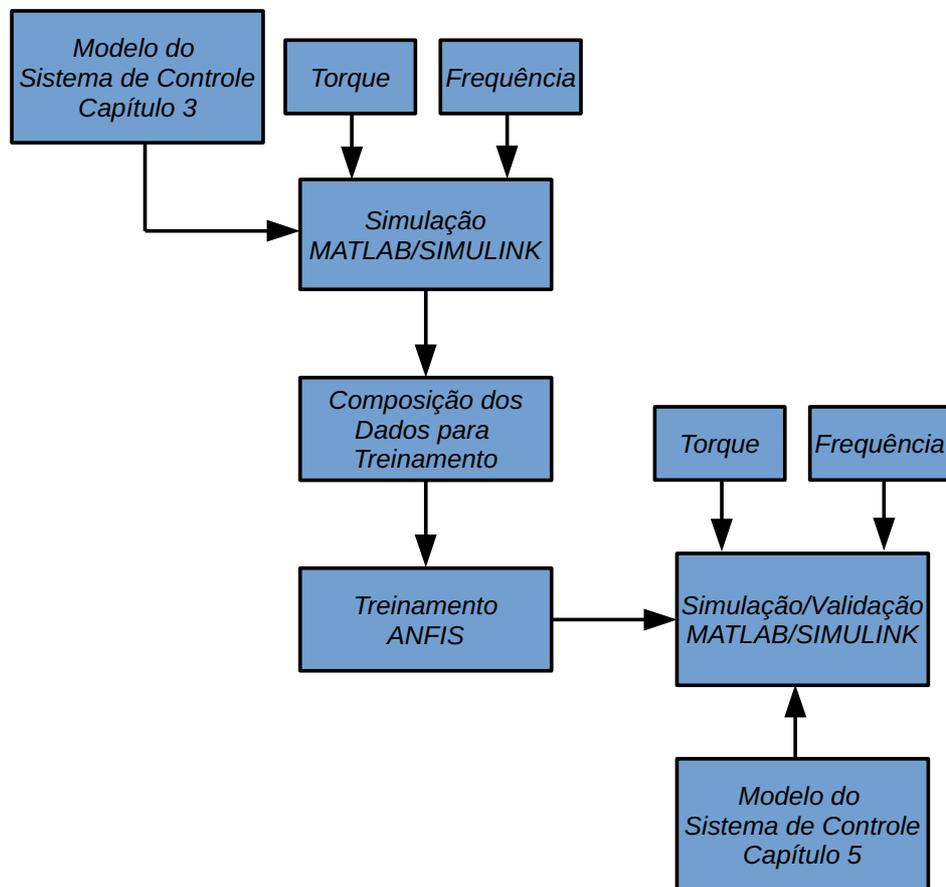


Figura 39 – Metodologia para desenvolvimento do sistema de controle neuro-fuzzy

(Fonte: Do Autor)

6 Simulação e Análise dos Resultados do Sistema de Controle *Neuro-Fuzzy* para MIT

6.1 Introdução

Neste capítulo serão apresentados e discutidos os resultados obtidos em simulação computacional, em ambiente *MatLab/Simulink*, do sistema de controle *neuro-fuzzy* aplicado ao controle de motores de indução.

Este capítulo está dividido em 3 partes, cada uma contendo um método de análise de desempenho do sistema. A ideia principal é analisar o desempenho do sistema de controle *neuro-fuzzy* quando comparado com o desempenho do sistema de controle convencional desenvolvido do Capítulo 3. Todas as análises partem deste princípio, com o intuito de verificar a viabilidade de emprego do sistema de controle proposto em ambiente industrial.

O primeiro método de análise de desempenho consiste na verificação da curva de resposta transitória de partida do motor. Os dois sistemas foram colocados nas mesmas condições de carga, estando o sistema de controle convencional (Tipo PI) ajustado de forma ótima para a carga. As curvas geradas por este método foram sobrepostas para melhor análise do transitório de partida e comparadas ao *setpoint* de velocidade estabelecido em simulação. O objetivo deste primeiro teste é verificar se o sistema *neuro-fuzzy* proposto apresenta superioridade frente ao sistema convencional, tendo em vista a estabilização de velocidade, sobre-sinal e o erro em regime permanente de carga.

O segundo método de análise de desempenho verifica o comportamento do sistema de controle proposto frente a variação de carga ao eixo do motor. Da mesma forma que o primeiro teste, tanto o sistema de controle do tipo PI, quanto o sistema de

controle *neuro-fuzzy* foram submetidos as mesmas condições de teste. No primeiro momento os sistemas foram expostos a degraus de carga crescentes e decrescentes e, no segundo momento, foram submetidos a uma rampa de carga crescente e decrescente. O objetivo com isso, é analisar se o sistema de controle *neuro-fuzzy* consegue corrigir o torque eletromagnético gerado pelo motor sem perder o *setpoint* de velocidade.

O terceiro método de análise consiste em variar a referência velocidade imposta ao sistema de controle *neuro-fuzzy*. Serão impostas variações de velocidade em degrau com carga ao eixo do motor constante. Com isso é possível analisar a capacidade que o sistema proposto tem de acompanhar as variações de referência de velocidade e manter o torque eletromagnético gerado pelo motor constante.

Com a aplicação destes métodos de análise, espera-se poder demonstrar a viabilidade de aplicação do sistema *neuro-fuzzy* no controle de motores de indução, e sua superioridade e robustez quando comparado com métodos convencionais de controle encontrados em acionamentos industriais atuais.

6.1.1 Análise de resposta transitória de partida do motor de indução

Neste item serão analisadas as curvas de resposta transitória de partida do motor de indução controlado por um sistema *neuro-fuzzy*. O método consiste em impor ao sistema de controle do tipo PI, e ao sistema de controle *neuro-fuzzy*, referências de velocidade e observar o comportamento transitório de partida dos dois sistemas.

Primeiro determinou-se os ganhos do controlador PI do sistema de controle convencional, de forma que o mesmo tivesse desempenho ótimo trabalhando a uma frequência imposta de 30Hz e torque resistente ao eixo do motor de 5Nm. Após isso, colocou-se ambos os sistemas de controle submetidos ao mesmo referencial de velocidade e carga ao eixo do motor e, em seguida, foram levantadas as curvas transitórias de partida para as frequências de 20Hz, 30Hz e 40Hz. Estas três frequências foram escolhidas para demonstrar a robustez da resposta transitória de partida do controlador *neuro-fuzzy* frente a imposição de referências de velocidade bem distintas como as usadas para esta simulação.

Para as simulações adotou-se as seguintes cores para distinguir os sinais nos gráficos: a cor azul representa os sinais provenientes do controlador do tipo PI, a cor vermelha os sinais provenientes do controlador *neuro-fuzzy* e a cor laranja representa a variável *setpoint*. A figura 40 ilustra o comportamento das curvas de resposta obtidas em simulação para uma frequência de 30Hz.

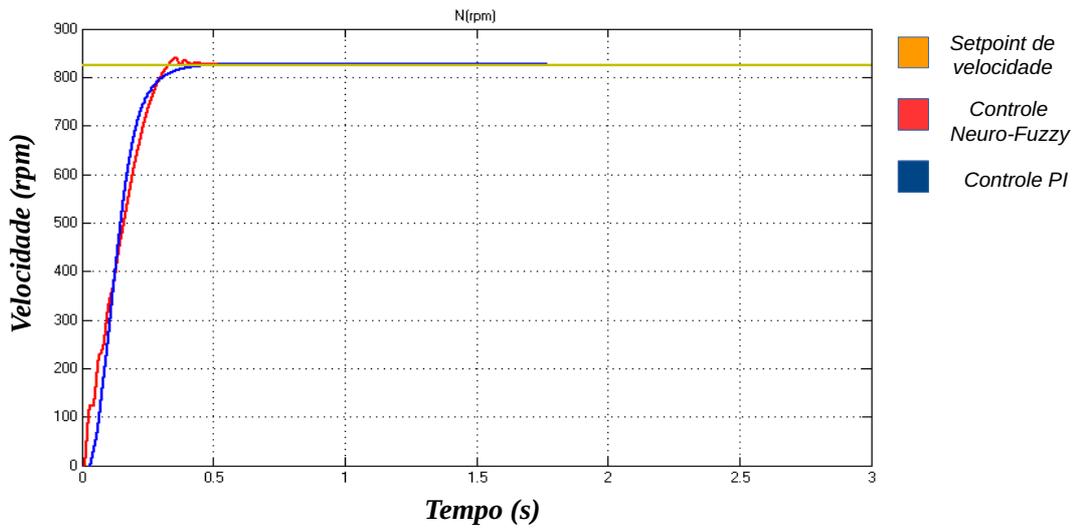


Figura 40 – Curvas de resposta transitória de partida à 30Hz

Na figura 40 está a representação gráfica das curvas de resposta transitória de partida dos dois controladores. Como pode-se notar os tempos de resposta são praticamente equivalentes. As diferenças aparecem quando são analisados o sobre-sinal e o tempo de estabilização como pode ser verificado em detalhe na figura 41.

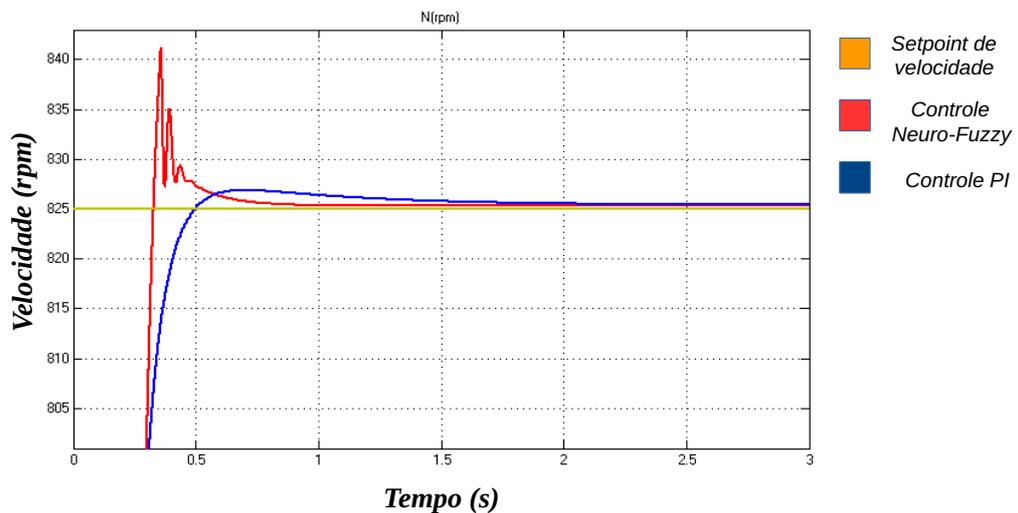


Figura 41 – Detalhe das curvas de resposta transitória de partida à 30Hz

A curva em vermelho representa a rotação do motor controlado pelo sistema *neuro-fuzzy*, pode-se notar que esta curva atinge o *setpoint* de 825 rpm antes que a curva em azul, que representa o controle do tipo PI. Embora a curva gerada pelo sistema *neuro-fuzzy* tenha apresentado um sobre-sinal maior que o controle do tipo PI, seu tempo de estabilização de rotação foi menor, girando em torno de 0,75 segundos, enquanto o controlador do tipo PI estabilizou por volta de 2 segundos.

Embora a curva gerada pelo sistema *neuro-fuzzy* tenha apresentado alguma superioridade quando analisada em detalhe, a forma geral das duas curvas podem ser consideradas equivalentes. Isso já era de se esperar, já que o controlador do tipo PI está sintonizado de forma ótima para as condições de frequência e carga, e os parâmetros para treinamento do controle *neuro-fuzzy* foram extraídos de forma que o mesmo fosse treinado com base nestas condições.

Neste ponto é válido um comentário quanto ao tempo de subida das curvas. Em acionamentos industriais, quando fazendo-se uso de controladores do tipo PI, o tempo de subida da velocidade em partida, ou tempo de aceleração do motor, pode ser alterado através da reparametrização do controlador PI e de um outro parâmetro, muito comum em acionamentos, que permite que a tensão imposta ao motor durante o instante de partida seja ligeiramente maior, com isso o conjugado eletromagnético que o motor desenvolve força uma aceleração de partida de ordem superior, porém, podendo comprometer o tempo de estabilização da curva e o sobre-sinal apresentado (Franchi, 2008).

No sistema de controle *neuro-fuzzy* proposto, foi inserido uma malha retroalimentada que impõe ao sistema de controle a tensão que se deseja no motor no instante de partida. Esta malha assume o controle do modulador PWM até o momento em que o motor atinge o *setpoint* de velocidade e, neste instante, o controlador *neuro-fuzzy* assume o controle do sistema, corrigindo instantaneamente o torque eletromagnético gerado e mantendo a velocidade do motor no *setpoint* estabelecido. É importante ressaltar que em tais condições, o sistema de controle *neuro-fuzzy* fica submetido a condições extremas de funcionamento e, ainda, consegue desenvolver

uma curva com características de desempenho superiores, quando comparada ao funcionamento do sistema sem a imposição desta tensão extra.

Nesta primeira simulação (figura 40) a tensão imposta ao motor pelo controle *neuro-fuzzy* foi a mesma que o controle do tipo PI impôs. A ideia foi colocar os dois sistemas em condições de igualdade num primeiro instante e, posteriormente, poder demonstrar a capacidade que o sistema de controle *neuro-fuzzy* possui de corrigir condições extremas de trabalho mantendo o desempenho do sistema. A figura 42 mostra como ficou a curva de resposta do sistema de controle *neuro-fuzzy*, a tensão imposta no momento de partida foi 21% maior que a da simulação da figura 40.

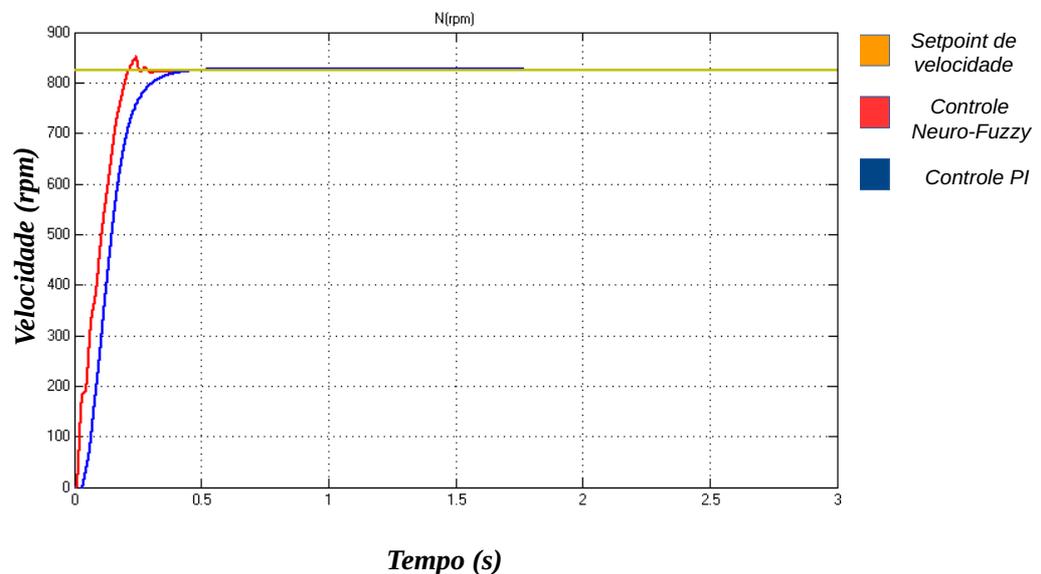


Figura 42 – Curvas de resposta transitória de partida com imposição de tensão extra na partida pelo sistema de controle neuro-fuzzy

Como pode ser observado na figura 42, através da imposição da tensão extra pelo sistema de controle *neuro-fuzzy*, foi possível desenvolver uma curva de resposta com tempo de subida em torno de 0,25 segundos e um tempo de acomodação por volta de 0,5 segundos. Na figura 43 pode ser visualizado o sobre-sinal gerado com utilização deste método.

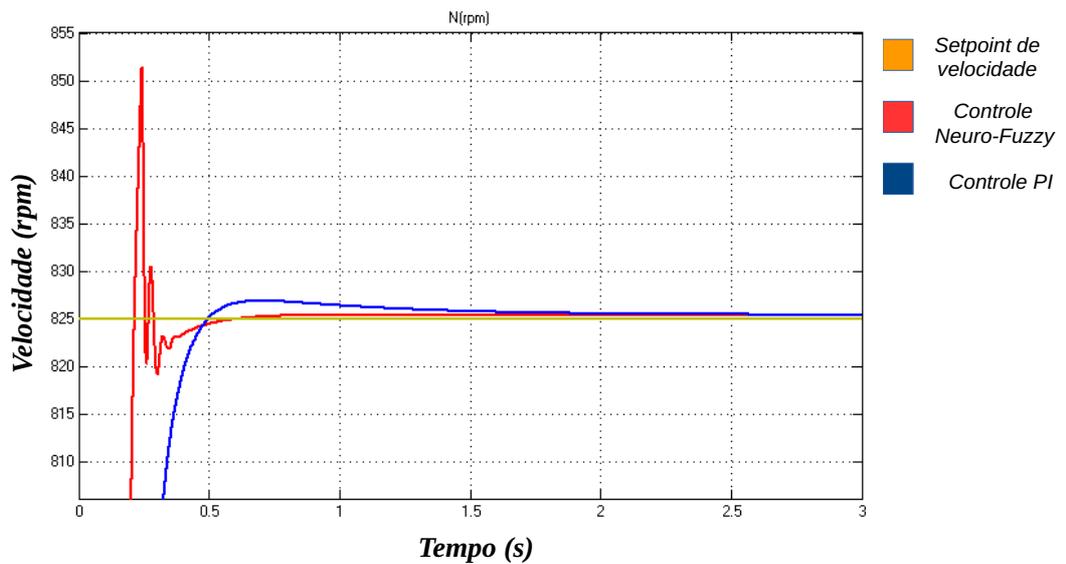


Figura 43 – Detalhe da resposta transitória de partida com imposição de tensão extra na partida pelo sistema de controle neuro-fuzzy

O sobre-sinal ficou em torno de 3% em relação ao *setpoint* de velocidade, no entanto, a curva convergiu para o *setpoint* rapidamente, levando aproximadamente 0,25 segundos.

Uma das principais características do sistema de controle *neuro-fuzzy* é sua capacidade de mapear e controlar sistemas que representam funções não-lineares. Tendo em vista esta característica, e a aplicação em acionamentos para motores de indução, os controladores *neuro-fuzzy* apresentam melhores resultados quando comparados com as técnicas de controle tradicionais baseadas em modelos dinâmicos linearizados do motor de indução (LIMA, 2010).

Para atestar o desempenho do sistema de controle proposto, frente ao comportamento não-linear do motor indução em função da frequência imposta, foram realizadas duas simulações onde o controlador *neuro-fuzzy* fica sujeito a duas frequências distintas, uma de 20Hz e outra de 40Hz. Um comparativo de desempenho com o sistema de controle do tipo PI foi traçado estando o mesmo sujeito as mesmas

condições de frequência imposta, no entanto, manteve-se os parâmetros do controlador do tipo PI ajustados para a frequência imposta de 30Hz. Desta forma, o objetivo é demonstrar a capacidade do sistema *neuro-fuzzy* proposto de trabalhar em pontos distintos de frequência, sem a necessidade de reparametrização do sistema de controle. A figura 44 mostra a simulação descrita para a frequência de 20Hz.

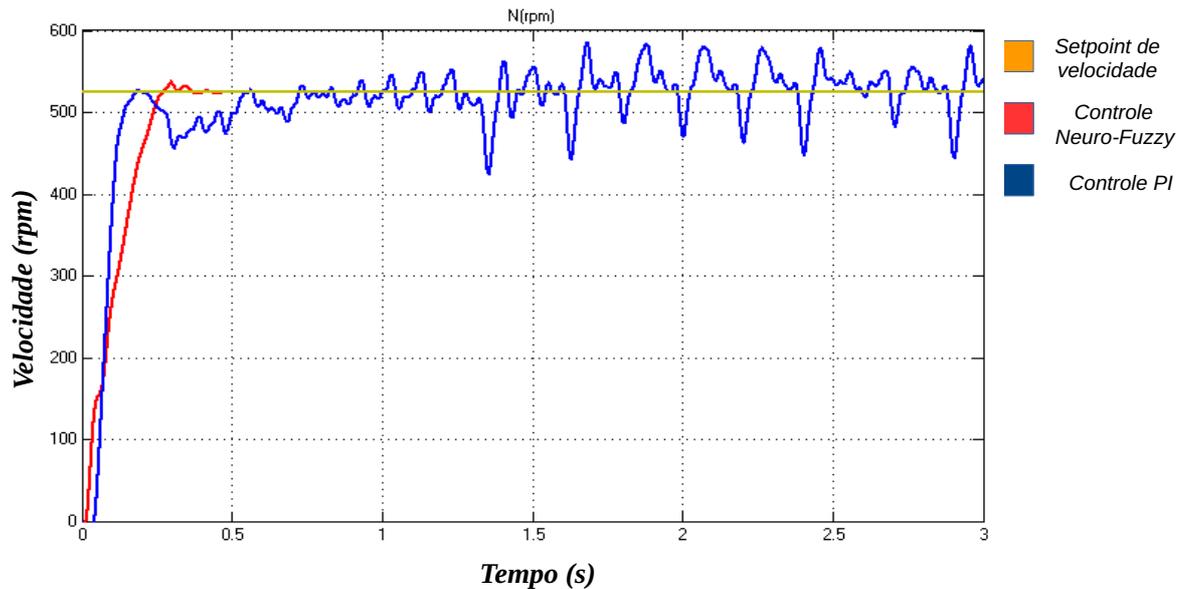


Figura 44 – Curvas de resposta transitória de partida à 20Hz

Na figura 44, é possível verificar o superior desempenho do sistema de controle *neuro-fuzzy* proposto (curva em vermelho), frente a variação de referência da velocidade para um *setpoint* de 525 rpm, enquanto o controlador do tipo PI (curva em azul) apresentou um comportamento oscilatório em todo período de simulação. A figura 45 detalha o comportamento dos tempos de acomodação dos sinais e o sobre-sinal obtido nesta simulação.

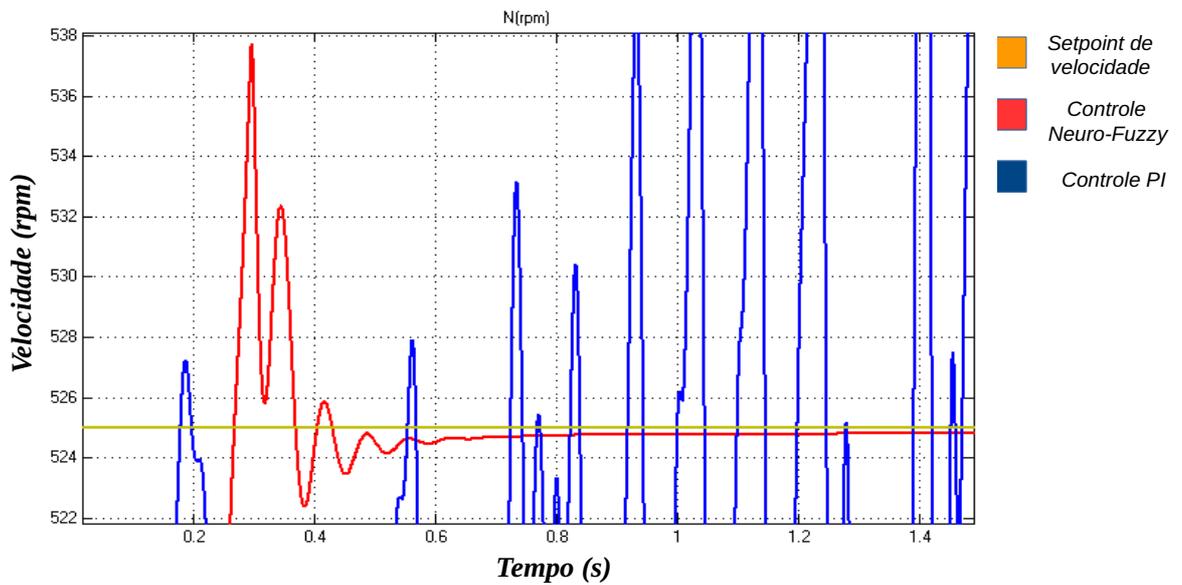


Figura 45 – Detalhe das curvas de resposta transitória de partida à 20Hz

Pode-se notar na figura 45, a rápida resposta que o controle *neuro-fuzzy* obteve na simulação, atingindo o setpoint de velocidade em torno de 0,25 segundos com um sobre-sinal de 2,5% e, tempo de acomodação da curva próxima de 0,65 segundos com um erro em regime próximo de -0,1%.

Será analisado a seguir, o comportamento do sistema *neuro-fuzzy* para uma frequência imposta de 40Hz. O *setpoint* de velocidade proporcional a esta frequência é de 1125 rpm. A figura 46 demonstra o resultado desta simulação.

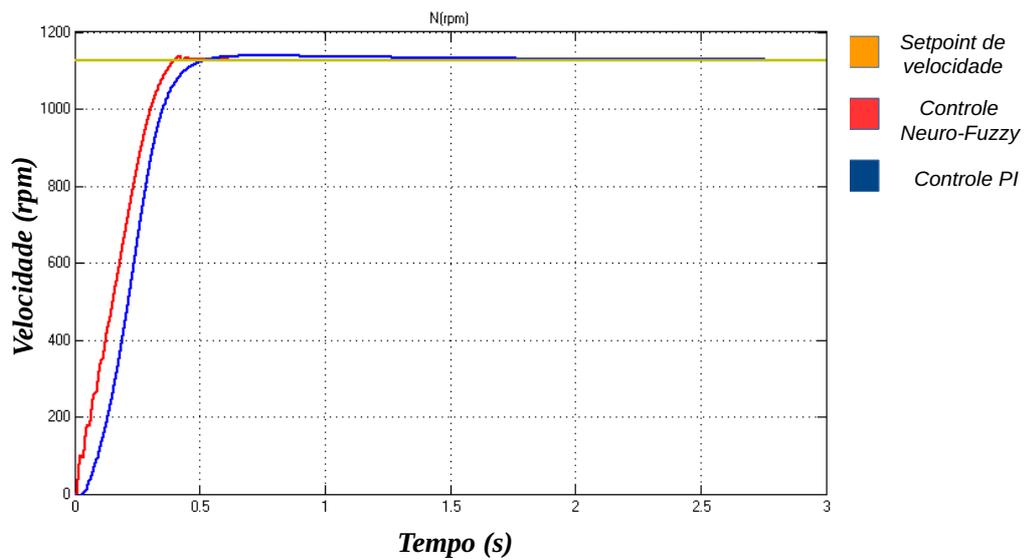


Figura 46 – Curvas de resposta transitória de partida à 40Hz

Observando-se a figura 46, pode-se notar que o controlador *neuro-fuzzy* apresentou uma resposta transitória mais rápida que a do controlador do tipo PI, atingindo o *setpoint* de velocidade em aproximadamente 0,4 segundos. A figura 47 mostra em detalhe o comportamento das curvas.

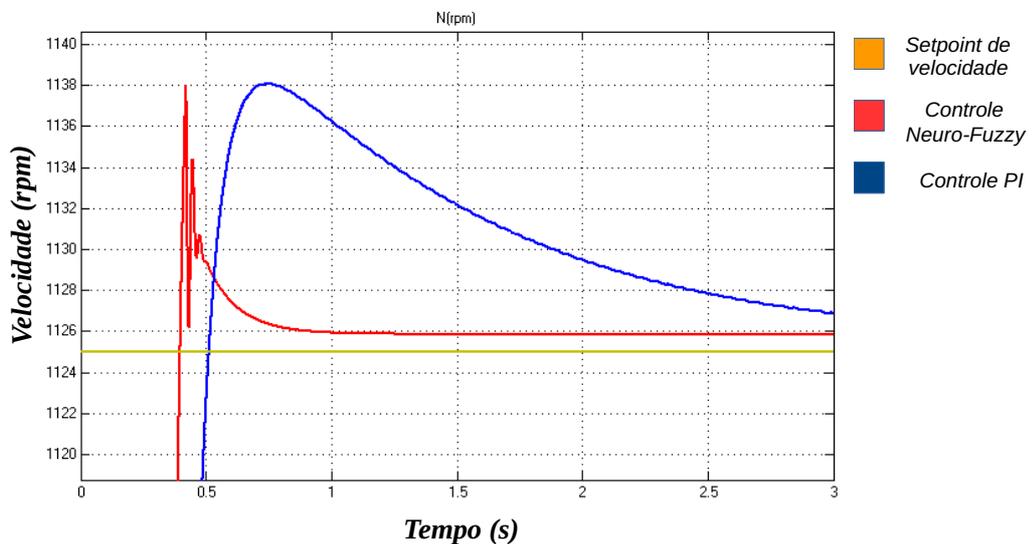


Figura 47 – Detalhe das curvas de resposta transitória de partida à 40Hz

Como pode ser percebido na figura 46, o principal atributo do controlador *neuro-fuzzy*, quando comparado com o do tipo PI, é seu comportamento mais rápido, tanto em resposta transitória de partida quanto em relação aos tempos de acomodação do sinal. Embora o sobre-sinal gerado pelo controle *neuro-fuzzy*, tenha sido equiparável ao do tipo PI para estas circunstâncias, o tempo de acomodação da curva ficou em aproximadamente 1 segundo e com um erro de regime em 0,1%, comportamento superior ao apresentado pelo controle do tipo PI.

6.2 Análise de resposta transitória de carga ao eixo do motor de indução

Neste item serão analisadas as curvas de resposta transitória de carga ao eixo do motor de indução, controlado por um sistema *neuro-fuzzy*. O método consiste em impor ao sistema, variações de carga crescentes e decrescentes e analisar o comportamento das curvas geradas. Um paralelo entre o desempenho do controlador *neuro-fuzzy* proposto e o do tipo PI é traçado, de forma a verificar as potencialidades do sistema de controle proposto frente as técnicas de controle tradicionais aplicadas aos motores de indução.

Para verificação do desempenho, foram utilizadas variações de carga no formato degrau e rampa. Estes formatos foram escolhidos por representarem tipos de cargas facilmente encontradas no ambiente industrial (MINOTTI, 2008).

6.2.1 Análise de resposta transitória de carga em degrau ao eixo do motor de indução

A primeira simulação consiste na aplicação de cargas no formato degrau aos dois sistemas analisados. Serão analisados como critério de desempenho, o tempo de resposta de estabilização da velocidade frente a variação de carga e o erro de velocidade em regime. A figura 48 apresenta os resultados desta simulação.

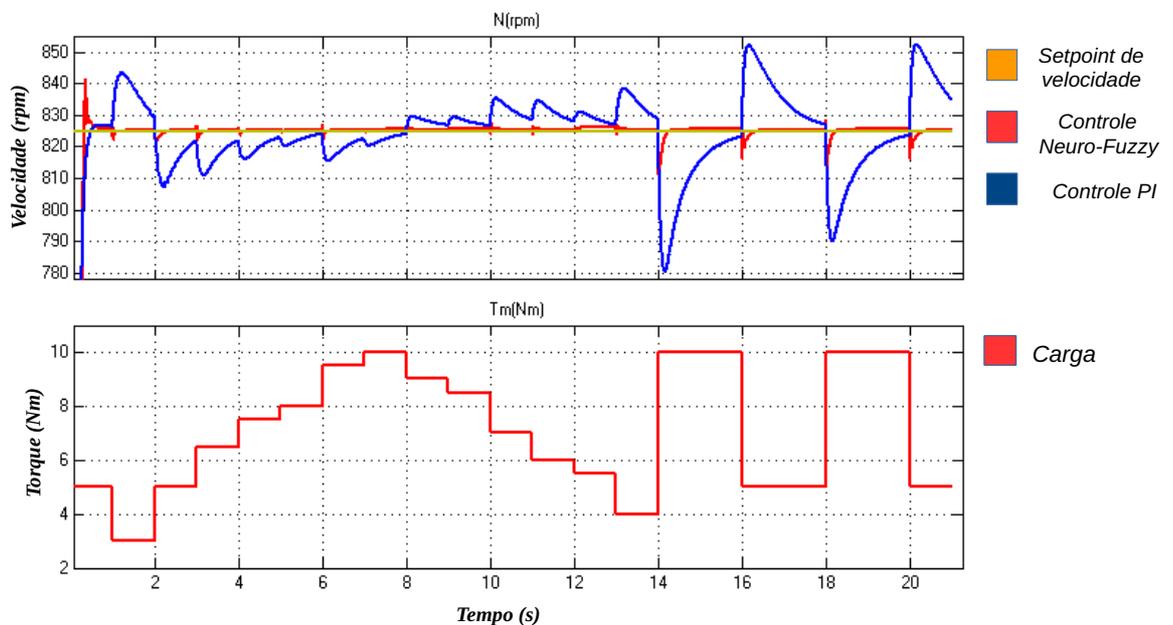


Figura 48 – Curvas de resposta transitória ao degrau de carga

Os dois controladores foram submetidos as mesmas condições de variação de carga e *setpoint* de velocidade, o controlador do tipo PI foi otimizado para uma frequência de 30Hz e carga constante de 5Nm. De 0 até 14 segundos, foram aplicados degraus de amplitude variando entre $\pm 2\text{Nm}$ e $\pm 0,5\text{Nm}$ em intervalos variando de 1 a 2 segundos. Como pode ser observado na figura 48, o controlador *neuro-fuzzy* proposto

(curva em vermelho) apresentou resposta transitória mais rápida quando comparado com o do tipo PI (curva em azul), e também, o sobre-sinal que o mesmo desenvolveu apresentou menor amplitude. O sobre-sinal máximo desenvolvido pelo sistema *neuro-fuzzy* nestas circunstâncias ficou em ± 3 rpm, representando aproximadamente $\pm 3,6\%$ em relação ao *setpoint* de 825 rpm. Já o tempo máximo para a estabilização da velocidade após os transitórios de carga ficou em 0,5 segundos para um erro máximo em regime em torno de 0,12% para um *setpoint* de velocidade de 825 rpm. As figuras 49 e 50 a seguir, evidenciam em detalhe o comportamento dos sistemas para o período de simulação de 0 até 14 segundos.

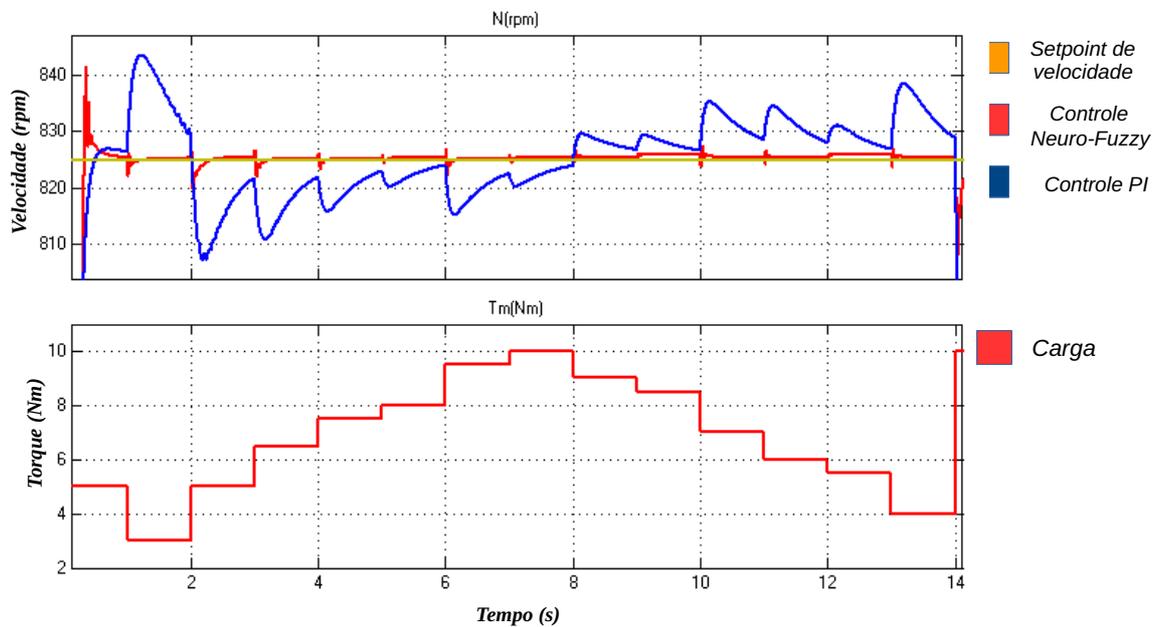


Figura 49 – Detalhe das curvas de resposta transitória ao degrau de carga

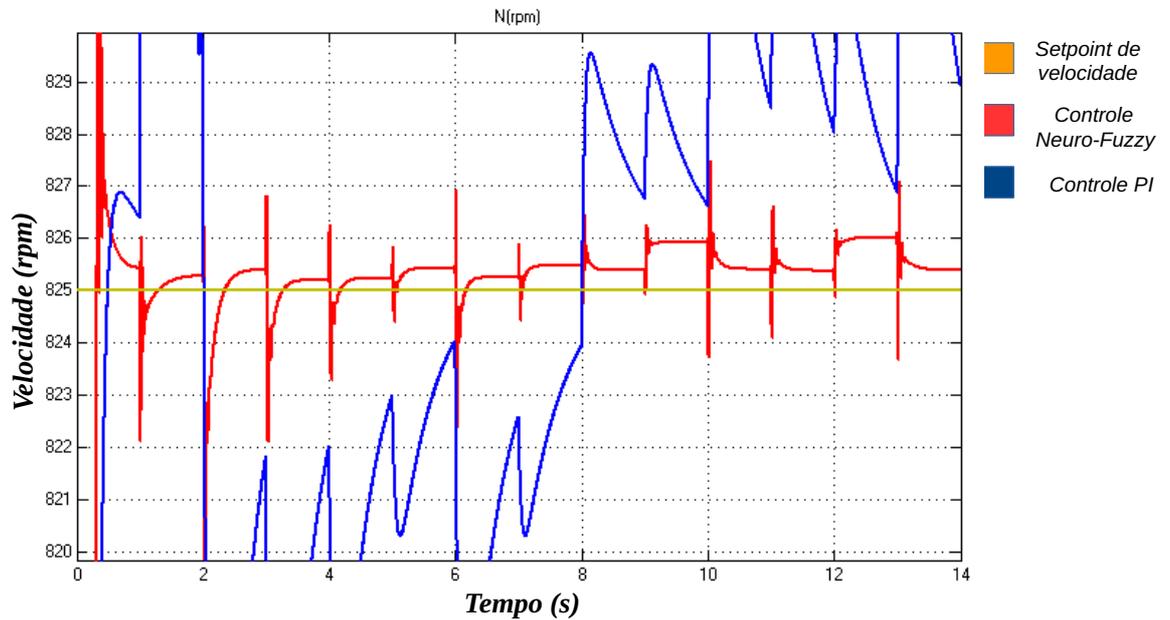


Figura 50 – Detalhe do erro em regime do sistema de controle neuro-fuzzy

Para o período de 14 segundos em diante, os sistemas foram submetidos a variações de cargas mais bruscas, variando em torno de $\pm 50\%$. Nestas circunstâncias, o controlador *neuro-fuzzy* também obteve melhor desempenho, com sobre-sinal máximo em torno de $\pm 1,2\%$, e tempo máximo de estabilização de velocidade em torno de 0,5 segundos para um erro de regime não ultrapassando os 0,12% do primeiro período de simulação. A figura 51 mostra em detalhe o período de simulação a partir dos 14 segundos em diante.

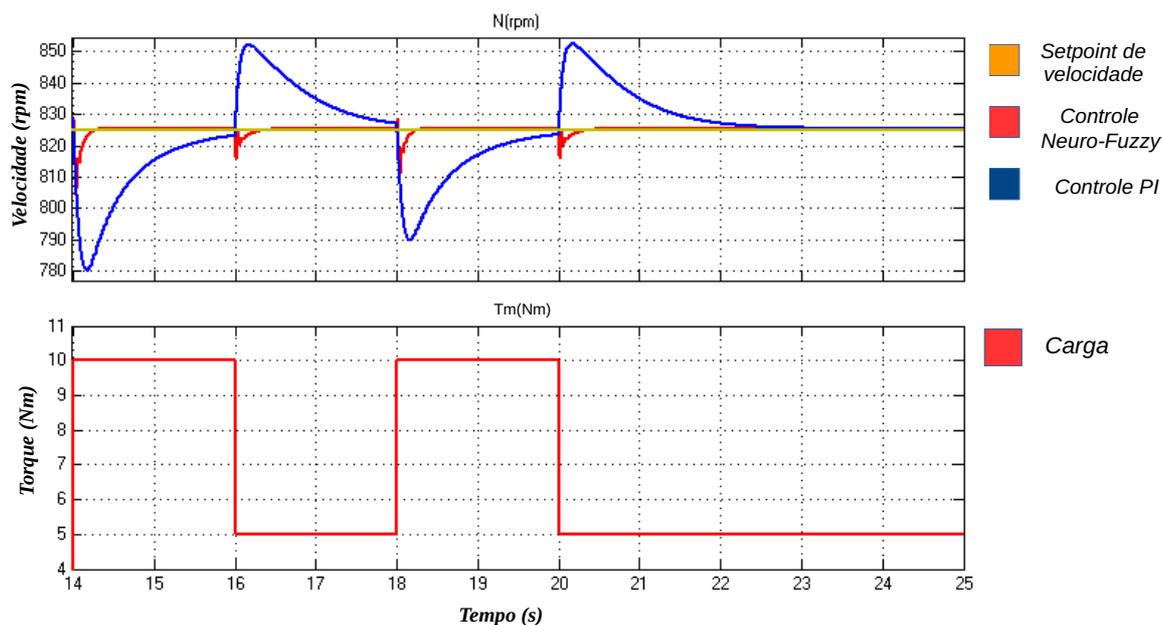


Figura 51 – Detalhe das curvas de resposta transitória ao degrau com variação de carga em $\pm 50\%$

6.2.2 Análise de resposta transitória de carga em rampa ao eixo do motor de indução

A segunda simulação consiste na aplicação de cargas no formato rampa aos dois sistemas analisados. Será analisado como critério de desempenho, o erro de velocidade em regime frente as variações crescentes e decrescentes da carga. A figura 52 apresenta a forma geral das curvas obtidas em simulação.

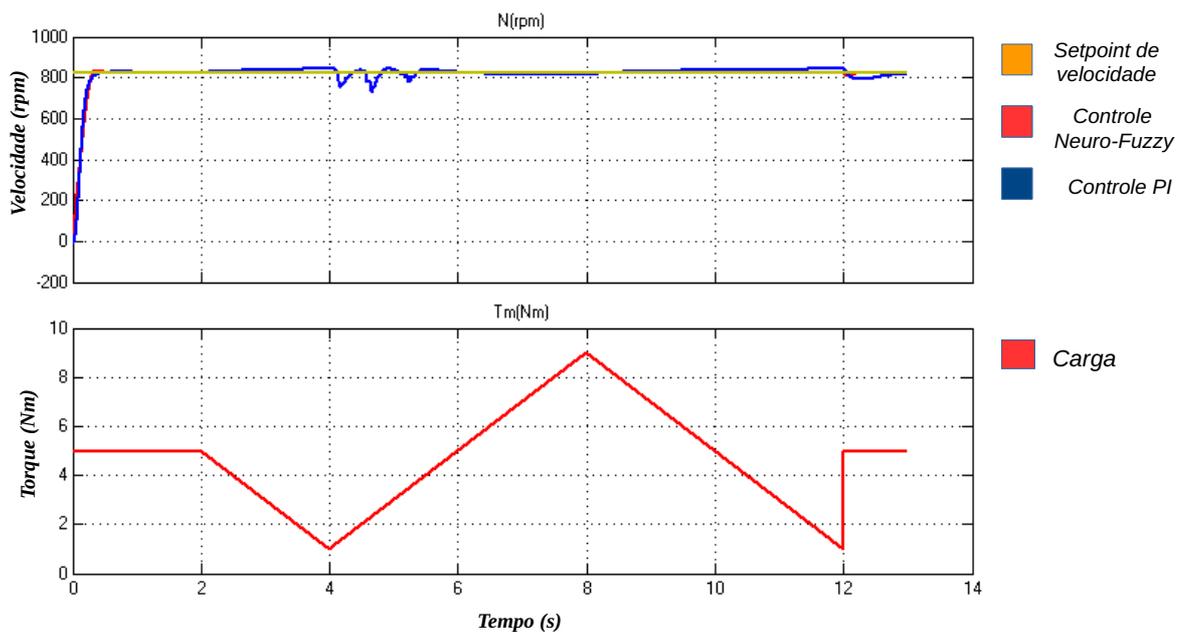


Figura 52 – Curvas de resposta transitória de carga em rampa crescente e decrescente

Após a estabilização de velocidade dos dois sistemas, ambos foram submetidos a rampas crescentes e decrescentes com taxa de variação de 2Nm/s, com um período de simulação partindo de 2 até 12 segundos. A figura 52 dá uma visão geral do comportamento dos dois sistemas. Pode-se notar que o controlador *neuro-fuzzy* proposto (curva em vermelho) manteve a rotação do motor próxima ao *setpoint* de velocidade estabelecido na simulação, ao contrário do controlador do tipo PI que apresentou desvios de rotação superiores e, também, apresentou instabilidade de rotação no intervalo de 4 a 6 segundos, durante a rampa de carga crescente. Na figura 53 é possível verificar em detalhe o comportamento da curva de velocidade imposta ao motor de indução submetido ao controlador *neuro-fuzzy*.

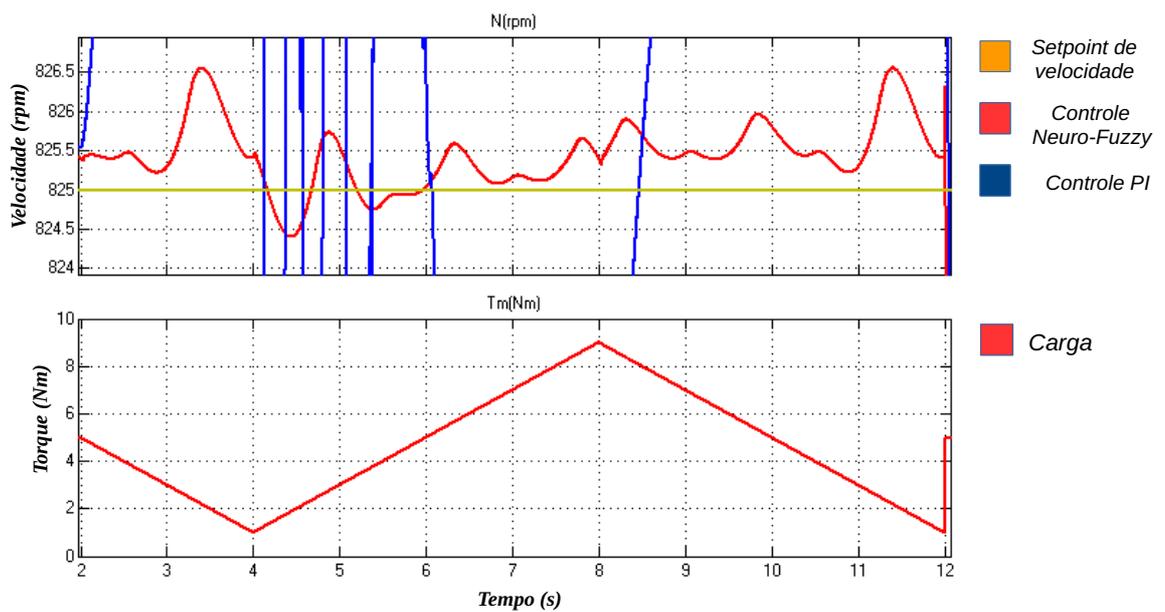


Figura 53 – Detalhe da curva de resposta transitória de carga em rampa do controlador neuro-fuzzy

Na figura 53 pode-se notar, na curva em vermelho, o comportamento da rotação do motor controlado pelo sistema *neuro-fuzzy*. O sistema proposto apresentou estabilidade de velocidade para todo o período de simulação e, também, manteve os desvios de velocidade próximos ao *setpoint* velocidade. As taxas máximas da variação do erro de velocidade ficaram, para uma rampa com taxa de variação de $\pm 2\text{Nm/s}$, em torno de $\pm 0,2\%$ em relação ao *setpoint* de 825 rpm.

6.3 Análise de resposta transitória de velocidade

Esta terceira parte da análise, consiste em verificar o comportamento do sistema *neuro-fuzzy* proposto frente a variações de velocidade no formato degrau. Com isso, pode-se verificar a qualidade da resposta gerada, adotando como critério de desempenho o tempo de acomodação da curva e o erro de velocidade. A figura 54 mostra o resultado da simulação.

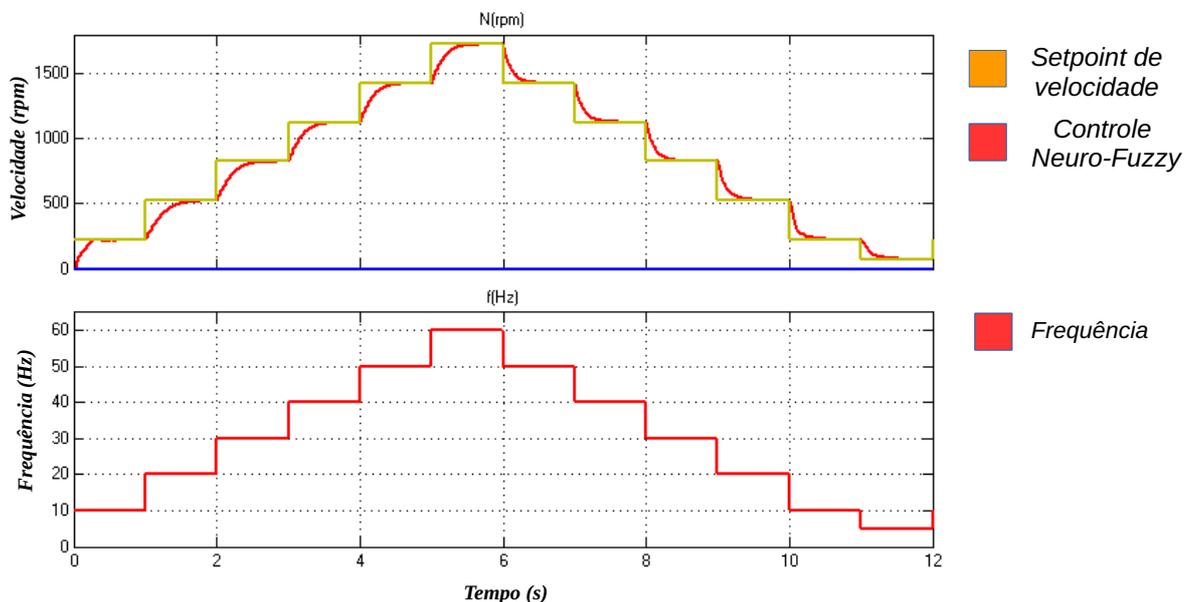


Figura 54 – Curva de resposta transitória de velocidade em degrau crescente e decrescente

Para a simulação, foram impostas ao sistema de controle proposto, frequências no formato degrau na faixa de 5 até 60 Hz, com taxa de variação entre ± 10 Hz e $- 5$ Hz e, também, carga constante ao eixo do motor de 5Nm. O tempo de acomodação máximo da curva de velocidade, entre os transitórios e velocidade, não ultrapassou 0,75 segundos, o melhor tempo de acomodação ficou na marca de 0,5 segundos. Já o erro de velocidade, não ultrapassou a faixa de $\pm 0,2\%$ obtidos nas simulações anteriores.

7 Conclusões Gerais e Trabalhos Futuros

7.1 Conclusão

Este trabalho apresentou o estudo e a implementação de um sistema de controle *neuro-fuzzy* aplicado ao controle de motores de indução trifásicos, através do ajuste dinâmico da relação V/f imposta ao motor e, conseqüentemente, a otimização do escorregamento relativo desenvolvido pela máquina.

Através dos resultados obtidos em simulação, pôde-se verificar o melhor desempenho do sistema de controle *neuro-fuzzy* proposto, quando comparado ao controlador convencional do tipo PI. Os resultados apresentados pelo sistema proposto foram superiores tanto em regime permanente quanto em regime de transitórios de carga e velocidade. Com base nestes resultados, pode-se concluir a viabilidade do sistema no controle de motores de indução trifásicos. Embora o sistema *neuro-fuzzy*, tenha sido inserido na estratégia de controle que consistiu na otimização do escorregamento do motor através do controle dinâmico da relação V/f imposta, os resultados obtidos em simulação sugerem que o controlador *neuro-fuzzy* pode ser utilizado em outras estratégias mais sofisticadas de controle para motores, como por exemplo o controle vetorial e o controle direto de torque, já que os mesmos também apresentam problemas relacionados a degradação dos requisitos de controle por usarem modelos linearizados em sua estrutura.

A utilização de uma rede neural para a sintonização do controlador *fuzzy* mostrou-se adequada, já que sua utilização diminuiu significativamente o tempo de ajuste do sistema de controle. Isso pôde ser verificado já que durante o desenvolvimento deste trabalho, foi realizado um estudo de viabilidade dos controladores *fuzzy* em sistemas de controle para motores de indução, onde chegou-se

a conclusão de que o tempo necessário para sintonização do sistema de controle poderia inviabilizar sua utilização, mesmo que ao final da sintonização, o sistema *fuzzy* apresentasse desempenho satisfatório.

É importante ressaltar, a capacidade de respostas mais rápidas que o controle *neuro-fuzzy* atribuiu ao sistema de controle. A técnica de otimização de escorregamento tem como uma de suas características respostas transitórias mais lentas, já que o ajuste da relação *V/f* imposta ao motor é determinada pelo controlador PI. Como o controle *neuro-fuzzy* possui internamente todo o comportamento dinâmico do motor, a relação *V/f* é determinada imediatamente após a detecção da variação de carga ou velocidade, independente da região de trabalho em que o motor se encontra, o que garante respostas mais rápidas e precisas.

Sendo assim, com este trabalho, fica demonstrada a viabilidade do emprego dos controladores baseados em sistemas *neuro-fuzzy* no controle de motores de indução trifásicos.

7.2 Trabalhos futuros

Os trabalhos futuros sugeridos estão a seguir:

- Implementação computacional do sistema *neuro-fuzzy* em outras estratégias de controle para motores de indução.
- Desenvolvimento de algoritmo para a implementação de sistemas *neuro-fuzzy* sem o auxílio do ANFIS.
- Desenvolvimento de um protótipo microcontrolado para verificação em laboratório do algoritmo de controle *neuro-fuzzy* desenvolvido em simulador.
- Implementação de uma bancada experimental para análise do desempenho de estratégias de controle aplicados em acionamentos elétricos.
- Testes práticos em ambiente industrial do protótipo desenvolvido.

Referências Bibliográficas

ARAÚJO. JOSÉ MÁRIO. **Acionamento Elétrico de Alto Desempenho**. Editora Edgar Blucher, 1º edição, 2010. ISBN 978-85-8039-003-2

AZCUE PUMA, J. L. **Controle Direto de Torque do Motor de Indução Trifásico Usando Controlador Fuzzy do Tipo PI Autoajustável**. Dissertação (Mestrado) – Faculdade de Engenharia Elétrica e Computação, Universidade Estadual de Campinas, 2010.

BARBI, I (1985). **Teoria Fundamental do Motor de Indução**. Editora UFSC, 1985.

BIM. EDSON. **Máquinas Elétricas e Acionamentos**. Editora Elsevier, 1º edição, 2009. ISBN 978-85-352-3029-1

BOSE BIMAL K. **Modern Power Electronics and AC Drives**. Editora Prentice Hall, 4º edição, 2011. ISBN 0-13-016743-6

BOSE BIMAL K. **Neural Network Applications in Power Electronics and Motor Drives — An Introduction and Perspective**. IEEE TRANSACTIONS ON INDUSTRIAL ELECTRONICS, VOL. 54, NO. 1, FEBRUARY 2007, pp. 14 – 33.

CAMPOS, MÁRIO MASSA; SAITO, KAKU. **Sistemas Inteligentes em Controle e Automação de Processos**. Editora Ciência Moderna, 1º edição, 2004. ISBN 85-7393-308-9

FRANCHI, CLAITON MORO. **Acionamentos Elétricos**, Editora Érica, 4º edição, 2007. ISBN 978-85-365-0149-9

GODETEL, A. **Estimativa de Conjugado de Carga Aplicado em Eixos de Motores de Indução Trifásico Através de Redes Neurais Artificiais**. Dissertação (Mestrado) – Faculdade de Engenharia de Bauru, Universidade Estadual Paulista, 2003.

GODETEL, A. **Estimador Neural de Velocidade Para Motores de Indução Trifásico**. Tese (Doutorado) - Escola de Engenharia de São Carlos, Universidade de São Paulo, 2007.

GRABOWSKI, PAWEL Z. **A Simple Direct Torque Neuro-Fuzzy Control of PWM-Inverter-Fed Induction Motor Drive**. IEEE TRANSACTIONS ON INDUSTRIAL ELECTRONICS, VOL. 47, NO. 4, AUGUST 2000, pp. 863 – 870.

LIMA, F. **Estimador Neuro-Fuzzy de Velocidade Aplicado ao Controle Vetorial sem Sensores de Motores de Indução Trifásico**. Tese (Doutorado) – Escola Politécnica, Universidade de São Paulo, 2010.

LINDEN FILHO, HAECKEL VAN DER. **Utilização de Filtro Neural Adaptativo para Eliminar Níveis CC na Estimação do Conjugado Eletromagnético em Motores de Indução Trifásico**. Dissertação (Mestrado) – Faculdade de Engenharia Mecânica, Universidade Federal da Paraíba, 2012.

MAMEDE FILHO, JOÃO. **Instalações Elétricas Industriais**. Editora LTC, 8º edição, 2012. ISBN 978-85-216-1742-6

MINOTTI, C. **Estimador Fuzzy de Velocidade Para Motores de Indução Trifásico Usando Abordagem Sensorless**. Dissertação (Mestrado) - Escola de Engenharia de São Carlos, Universidade de São Paulo, 2008.

NASCIMENTO JÚNIOR, CAIRO LÚCIO e YONEYAMA, TAKASHI. **Inteligência Artificial em Controle e Automação**, Editora Edgar Blucher, 5º edição, 2000. ISBN 978-85-212-0310-0

OH SEOK, WON. **Self Tuning Neural Network Controller for Induction Motor Drive**. IECON 02 – Industrial Electronics Society, IEEE 2002 28th Annual Conference, VOL. 1, NOVEMBER 2002, pp. 152 – 156.

PALMA, P. JOÃO C. **Accionamentos Electromecânicos de Velocidade Variável**. Editora Fundação Calouste Gulbenkian, 2º edição, 2008. ISBN 978-972-31-0839-2

PROCYK, T. e MAMDANI, E.H, (1979). **A linguistic Self-Organizing Process Controller**, *Automatica*, V. 15, pp. 15-30.

SILVA, S. F. **Identificação de Torque de Carga em Motores de Indução Usando Abordagem Baseada em Sistemas Fuzzy**. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, 2007.

SIMÕES, MARCELO GODOY e SHAW, IAN S. **Controle e modelagem Fuzzy**, Editora Edgar Blucher, 2º edição, 2007. ISBN 978-85-212-0416-9

SIMONE, GÍLIO ALUÍSIO. **Máquinas de Indução Trifásicas**. Editora Érica, 2º edição, 2010. ISBN 978-85-7194-708-5

ZADEH, L.A (1965). **Fuzzy sets**. *Information and Control*, V. 8, pp. 29-44.

ZADEH, L.A (1973). **Outline of a New Approach to the Analysis of Complex Systems and Decision Processes**. *IEEE Transactions on Systems, Man and Cybernetics*, V. 3. pp. 28-44.

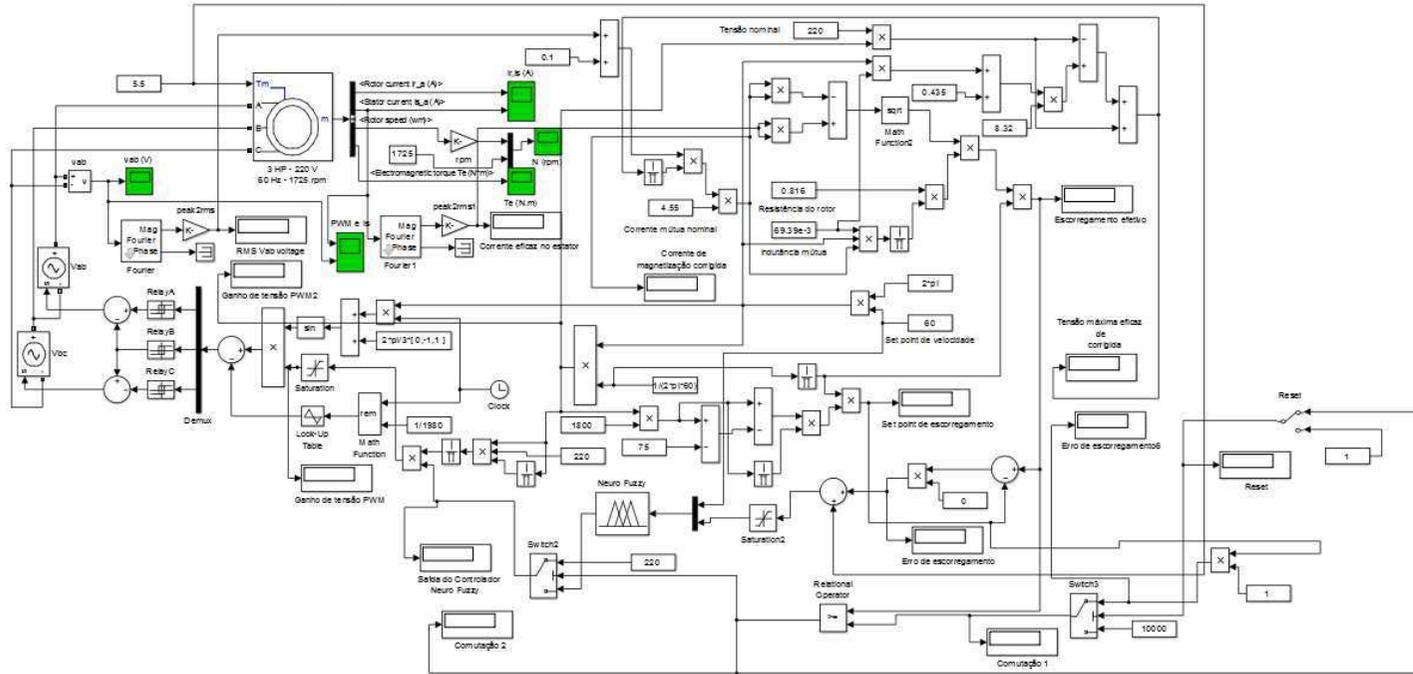


Figura 56 – Implementação feita no MatLab/Simulink do controlador neuro-fuzzy.