



UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**METODOLOGIA BASEADA EM SISTEMA *FUZZY* INTERVALAR
DO TIPO-2 PARA DETECÇÃO E IDENTIFICAÇÃO DE FALTAS
INCIPIENTES EM MOTORES DE INDUÇÃO.**

ERICK MELO ROCHA

DM – 05/2013

UFPA / ITEC / PPGEE

Belém – Pará – Brasil

2013

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

ERICK MELO ROCHA

**METODOLOGIA BASEADA EM SISTEMA *FUZZY* INTERVALAR DO
TIPO-2 PARA DETECÇÃO E IDENTIFICAÇÃO DE FALTAS
INCIPIENTES EM MOTORES DE INDUÇÃO.**

DM – 05/2013

UFPA / ITEC / PPGEE

Belém – Pará – Brasil

2013

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

ERICK MELO ROCHA

**METODOLOGIA BASEADA EM SISTEMA *FUZZY* INTERVALAR DO
TIPO-2 PARA DETECÇÃO E IDENTIFICAÇÃO DE FALTAS
INCIPIENTES EM MOTORES DE INDUÇÃO.**

Dissertação de Mestrado submetida à Banca Examinadora do Programa de Pós-Graduação em Engenharia Elétrica (PPGEE) da Universidade Federal do Pará (UFPA), como requisito final de avaliação para a obtenção do Título de Mestre em Engenharia Elétrica.

Área de Concentração: Sistemas de Energia

Orientador: Prof. Dr. Walter Barra Junior.

UFPA / ITEC / PPGEE

Belém – Pará – Brasil

2013

Dados Internacionais de Catalogação-na-Publicação (CIP)
Sistema de Bibliotecas da UFPA

Rocha, Erick Melo, 1987-

Metodologia baseada em sistema fuzzy
intervalar do tipo-2 para detecção e
identificação de faltas incipientes em motores
de indução. / Erick Melo Rocha. - 2013.

Orientador: Walter Barra Junior.
Dissertação (Mestrado) - Universidade Federal
do Pará, Instituto de Tecnologia, Programa de
Pós-Graduação em Engenharia Elétrica, Belém,
2013.

1. Lógica fuzzy. 2. Algoritmos genéticos. 3.
Motores elétricos - métodos de simulação. I.
Título.

CDD 22. ed. 511.313

UNIVERSIDADE FEDERAL DO PARÁ
 INSTITUTO DE TECNOLOGIA
 PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

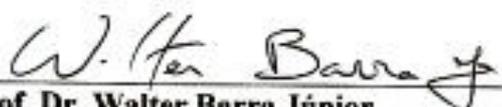
**“METODOLOGIA BASEADA EM SISTEMA FUZZY INTERVALAR DO TIPO-2 PARA
 DETECÇÃO E IDENTIFICAÇÃO DE FALTAS INCIPIENTES EM MOTORES DE
 INDUÇÃO”**

AUTOR: ERICK MELO ROCHA

DISSERTAÇÃO DE MESTRADO SUBMETIDA À BANCA EXAMINADORA APROVADA PELO
 COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, SENDO
 JULGADA ADEQUADA PARA A OBTENÇÃO DO GRAU DE MESTRE EM ENGENHARIA
 ELÉTRICA NA ÁREA DE SISTEMAS DE ENERGIA ELÉTRICA.

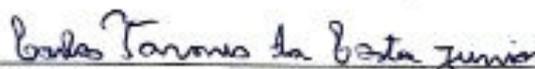
APROVADA EM: 27 / 02 / 2013

BANCA EXAMINADORA:



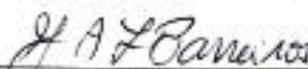
Prof. Dr. Walter Barra Júnior

(Orientador – PPGEE/UFPA)



Prof. Dr. Carlos Tavares da Costa Júnior

(Membro – PPGEE/UFPA)



Prof. Dr. José Augusto Lima Barreiros

(Membro – PPGEE/UFPA)



Prof. Dr. André Maurício Damasceno Ferreira

(Membro Externo – IFPA/UFPA)

VISTO:



Prof. Dr. Evaldo Gonçalves Pelaes

(Coordenador do PPGEE/ITEC/UFPA)

Dedico esse trabalho à minha família, em especial aos meus pais, Getúlio Cândido Rocha e Carmita Corrêa Melo pela dedicação e pelo apoio aos meus estudos, e por sempre se fazerem presentes em todos os momentos difíceis da minha vida, e a Deus por ter me dado a vida.

AGRADECIMENTOS

Primeiramente agradeço a Deus, que colocou pessoas maravilhosas em minha vida, e me mostrou nesses últimos meses um Amor que até então eu desconhecia, obrigado por me permitir viver, eu te amo eternamente meu Deus.

A minha família pelo amor incondicional em todos os momentos da minha vida, principalmente ao meu pai, Getúlio Cândido Rocha, e à minha mãe, Carmita Corrêa Melo, pela educação exemplar que me deram e pelo incentivo aos estudos; sem vocês eu não seria nada, e aos meus irmãos Ingrid Melo Rocha, Denis Melo Rocha, e à tia Josefa Corrêa Melo que me acompanham no desenvolvimento acadêmico, torcendo por mim em todos os momentos, obrigado!

Ao prof. Dr. Walter Barra Júnior por sua orientação, e por sempre estar disponível a tirar dúvidas e a fazer sugestões, também agradeço pelas responsabilidades creditadas nos últimos anos e que me permitiram amadurecer profissionalmente. Obrigado professor Barra!

A todos os professores do PPGEE que contribuíram com minha pós-graduação, em especial a José Augusto Lima Barreiros, Carlos Tavares da Costa Júnior e Jorge Roberto Brito de Souza, meu muito obrigado.

Ao meu amigo de trabalho Geraldo Neves de Albuquerque Maranhão, que nesses dois anos de pesquisas contribuiu significativamente com a evolução dos nossos trabalhos, sempre apresentando novas sugestões de estudos, também agradeço pela parceria; valeu Geraldo!

A todos os demais colegas e amigos de laboratório, Marcus, Conceição, Lusiane, Jackeline, Anderson, Cleyson e Florindo, obrigado por todos os momentos agradáveis que tornaram o ambiente de trabalho mais prazeroso.

Agradeço a minha namorada Juliana Chagas por entender minhas privações e por tornar menos exaustivo o desenvolvimento desse trabalho, me proporcionando momentos de felicidade e descontração. Agradeço também a minha sogra, Andreza Chagas, pela amizade e pelas palavras de carinho, muito obrigado mesmo.

Aos meus amigos da Igreja, Leonam e Ingrid, agradeço pelos conselhos e por sempre me levarem a palavra de Deus.

Agradeço também o apoio do Projeto PREDFALT, entre a UFPA e a Companhia Vale que me proporcionou amadurecimento profissional, agradeço também o apoio financeiro em viagens para apresentação de artigos em congressos.

A CAPES pela provisão da bolsa de mestrado.

A todos, meus sinceros agradecimentos.

*“Prepara-se o cavalo para a batalha, mas é do
Senhor que vem a vitória.”*

(Provérbios 21:31)

SUMÁRIO

RESUMO.....	XV
ABSTRACT	XVI
1 INTRODUÇÃO	1
1.1 Objetivos.....	3
1.2 Estrutura do Trabalho	3
2 MÉTODO DE DETECÇÃO DE FALTAS BASEADO EM MODELO DO PROCESSO.....	5
2.1 Introdução	5
2.2 Modelagem da falta aplicada na planta.....	5
2.3 Classificação das faltas	6
2.3.1 Classificação quanto ao tipo de falta	6
2.3.2 Classificação quanto à localização da falta	7
2.3.3 Quanto à atuação da falta no sistema.....	7
2.4 Etapas do processo de detecção e diagnóstico de faltas	8
2.5 Modelo do processo	9
2.6 Métodos de detecção de faltas	10
2.7 Introdução às técnicas convencionais de estimação	12
2.8 Representação linear em tempo discreto com ruído	13
2.9 Estimador dos mínimos quadrados recursivo	14
2.10 Conclusão.....	17
3 CONJUNTO FUZZY INTERVALAR DO TIPO-2.....	18
3.1 Introdução	18
3.2 Definições do SIF tipo-2.....	20
3.3 Definições para o universo discreto.....	23
3.4 Mancha de incerteza e Conjunto <i>fuzzy</i> intervalar do tipo-2.....	23
3.5 Incertezas nas funções de pertinência de conjuntos <i>fuzzy</i> do tipo-2.....	24
3.5.1 FOU no valor modal da função de pertinência primária gaussiana.....	24
3.5.2 FOU na dispersão da função de pertinência primária gaussiana.....	25
3.5.3 FOU na base da função de pertinência primária triangular	26
3.6 Estrutura de um sistema de inferência <i>fuzzy</i> do tipo-2 Mamdani	28

3.7	Sistemas de inferência <i>fuzzy</i> intervalares do tipo-2	32
3.8	Conclusão.....	34
4	ALGORITMOS GENÉTICOS.....	35
4.1	Introdução aos algoritmos de otimização	35
4.2	Algoritmos genéticos: princípios e aplicações.....	36
4.2.1	Problema a ser otimizado	36
4.2.2	Representação das soluções de problema.....	36
4.2.3	Decodificação do cromossomo.....	37
4.3	Funcionamento dos algoritmos genéticos.....	37
4.3.1	Inicialização.....	38
4.3.2	Avaliação de aptidão (<i>fitness</i>)	38
4.3.3	Seleção de reprodutores.....	39
4.3.4	Operadores genéticos.....	40
4.3.5	Atualização	43
4.3.6	Finalização.....	43
4.4	Desenvolvimento do algoritmo genético	43
4.5	Conclusão.....	44
5	ESTUDO DE CASO APLICADO À DETECÇÃO E AO DIAGNÓSTICO DE FALTAS INCIPIENTES EM ENROLAMENTO DE ESTATOR DE MOTOR TRIFÁSICO DE INDUÇÃO	45
5.1	Considerações iniciais.....	45
5.2	Identificação do sistema para a condição livre de faltas.....	45
5.3	Identificação do sistema para condição com falta incipiente	50
5.4	Identificação da falta incipiente utilizando-se sistemas de inferência <i>fuzzy</i> intervalar do tipo-2.....	57
5.5	Uso de algoritmos genéticos para minimização do erro de identificação.....	61
6	CONCLUSÃO	65
	REFERÊNCIAS BIBLIOGRÁFICAS	68
	APÊNDICES	71

LISTA DE FIGURAS

Figura 2. 1: Tipos de faltas em função do tempo: (a) abrupta; (b) incipiente; (c) intermitente. 6

Figura 2. 2: Classificação da falta quanto a sua localização na planta..... 7

Figura 2. 3: Tipos de Faltas: (a) falta aditiva para um sinal de saída; (b) falta multiplicativa... 8

Figura 2. 4: Etapas do processo de detecção e isolamento de faltas 8

Figura 2. 5: Método de detecção de falta baseado em modelo do processo..... 10

Figura 2. 6: Diagrama em blocos para representação do método de detecção e classificação de faltas. 11

Figura 2. 7: Procedimento para identificação de processos..... 12

Figura 2. 8: Representação esquemática do modelo ARX. 14

Figura 2. 9: Procedimento iterativo na estimação de parâmetros..... 15

Figura 3. 1: Função de pertinência *fuzzy* tipo-1 e *fuzzy* tipo-1 manchada. 20

Figura 3. 2: Conjunto *fuzzy* tipo-2 representado tridimensionalmente..... 22

Figura 3. 3: FOU em função de pertinência primária com incerteza no valor modal 25

Figura 3. 4: FOU em função de pertinência primária com incerteza na dispersão..... 25

Figura 3. 5: FOU em funções de pertinência primárias triangulares..... 26

Figura 3. 6: Estrutura de um sistema *fuzzy* do tipo-2. 29

Figura 4. 1: (a) Cromossomo binário, (b) Cromossomo real, e (c) Cromossomo de símbolos.
..... 37

Figura 4. 2: Etapas do funcionamento dos AG's..... 38

Figura 4. 3: *Crossover* em um ponto 41

Figura 4. 4: *Crossover* em dois pontos 41

Figura 4. 5: *Crossover* uniforme 42

Figura 4. 6: Mutação simples 42

Figura 5. 1: Modelo de simulação do motor de indução em Matlab/Simulink 46

Figura 5. 2: Tensão e corrente eficazes no estator, sem a falta. 47

Figura 5. 3: Saída real e saída estimada sem a falta. 49

Figura 5. 4: Parâmetros estimados a_1 e b_1 50

Figura 5. 5: Bloco Qaxis (eixo de referência q) detalhado com a falta 53

Figura 5. 6: Bloco Daxis (eixo de referência q) detalhado com a falta 53

Figura 5. 7: Bloco falta 53

Figura 5. 8: Evolução do curto-circuito e redução do valor da reatância de magnetização	54
Figura 5. 9: Tensão e corrente eficazes no estator com a falta	54
Figura 5. 10: Saída real e saída estimada com a falta.....	55
Figura 5. 11: Comportamento do parâmetro a	56
Figura 5. 12: Comportamento do parâmetro b	56
Figura 5. 13: Função de pertinência gaussiana dos parâmetros a e b	58
Figura 5. 14: Função de pertinência triangular dos parâmetros a e b	59
Figura 5. 15: Falta identificada para as variações do método proposto	60
Figura 5. 16: Erro de identificação para as variações do método proposto.....	60
Figura 5. 17: Erro de identificação para as variações do método proposto.....	62
Figura 5. 18: Erro Médio Quadrático para as variações do método proposto.....	62

LISTA DE TABELAS

Tabela 4. 1: Sistema natural x Algoritmos genéticos	36
Tabela 4. 2: Tipos de representação dos cromossomos.....	37
Tabela 5. 1: Parâmetros do MIT de 20HP	47
Tabela 5. 2: Valor médio dos parâmetros com a intensidade da falta.....	57
Tabela 5. 3: Falta Identificada utilizando-se SIF TIPO-2 + AG	63

LISTA DE ABREVIATURAS

AG	<u>A</u> lgoritmos genéticos
ARX	<u>A</u> uto <u>r</u> egressivo com entradas <u>e</u> xógenas
Daxis	<i>D</i> irect <i>a</i> xis
FDI	<i>F</i> ault <i>d</i> etection and <i>i</i> solation
FOU	<i>F</i> ootprint of <i>u</i> ncertainly
MQR	<u>M</u> ínimos quadrados <u>r</u> ecursivos
MSE	<u>M</u> ean <u>s</u> quare <u>e</u> rror
MIT	<u>M</u> otor de <u>i</u> ndução <u>t</u> rifásico
Qaxis	<i>Q</i> uadrature <i>a</i> xis
RT	<u>R</u> edutor de <u>t</u> ipo
SIF	<u>S</u> istema de <u>i</u> nterferência <u>f</u> uzzy
SFG	<u>S</u> istema <u>f</u> uzzy genético
SBPA	<u>S</u> equência <u>b</u> inária <u>p</u> seudo <u>a</u> leatória

RESUMO

Desde a incorporação da automação no processo produtivo, a busca por sistemas mais eficientes, objetivando aumento da produtividade e da qualidade dos produtos e dos serviços, direcionou os estudos para o desenvolvimento de estratégias que permitissem o monitoramento de sistemas com o intuito principal de torná-los mais autônomos e robustos. Por esse motivo, as pesquisas envolvendo o diagnóstico de faltas em sistemas industriais tornaram-se mais intensivas, visto a necessidade da incorporação de técnicas para monitoramento detalhado de sistemas. Tais técnicas permitem a verificação de perturbações, faltas ou mesmo falhas. Em vista disso, esse trabalho investiga técnicas de detecção e diagnóstico de faltas e sua aplicação em motores de indução trifásicos, delimitando seu estudo em duas situações: sistema livre de faltas, e sobre atuação da falta incipiente do tipo curto-circuito parcial nas espiras do enrolamento do estator. Para a detecção de faltas, utilizou-se análise paramétrica dos parâmetros de um modelo de tempo discreto, de primeira ordem, na estrutura autoregressivo com entradas exógenas (ARX). Os parâmetros do modelo ARX, que trazem informação sobre a dinâmica dominante do sistema, são obtidos recursivamente pela técnica dos mínimos quadrados recursivos (MQR). Para avaliação da falta, foi desenvolvido um sistema de inferência fuzzy (SIF) intervalar do tipo-2, cuja mancha de incerteza ou *footprint of uncertainty* (FOU), característica de sistema fuzzy tipo-2, é ideal como forma de representar ruídos inerentes a sistemas reais e erros numéricos provenientes do processo de estimação paramétrica. Os parâmetros do modelo ARX são as entradas para o SIF. Algoritmos genéticos (AG's) foram utilizados para otimização dos SIF intervalares do tipo-2, objetivando reduzir o erro de diagnóstico da falta identificada na saída desses sistemas. Os resultados obtidos em testes de simulação computacional demonstram a efetividade da metodologia proposta.

Palavras-chave: Diagnóstico de Faltas, Identificação Paramétrica, Sistema Fuzzy Intervalar do Tipo-2, Algoritmos Genéticos.

ABSTRACT

Since the incorporation of automation in the production processes, aiming at order to improve productivity and quality of products and services, researches on more efficient methodologies for fault diagnosis became more intensive. Such techniques allow the early detection of faults, before then lead to failures. This work investigates techniques for detection and diagnosis of faults and its application to induction motors, limiting their study to two situations, namely: system free of faults and system under incipient partial short-circuit in the coils the stator winding. For fault detection, parametric analysis of first order ARX (autoregressive with exogenous input) were applied. The parameters of identified ARX modes, which bring information about the dynamics of the dominant system, are recursively obtained by the technique of recursive least squares (RLS). In order to evaluate the capability for early fault detection, a type-2 interval fuzzy system was developed. This kind of fuzzy system has capability to capture a larger set of uncertainties than conventional (type-1) fuzzy systems. The footprint of uncertainty (FOU), characteristic of type-2 fuzzy system, is a way to accounts for uncertainties coming from noise and numerical errors from the process of parameter estimation. The ARX model parameters are the inputs to the supervisor system. Genetic algorithms (GA's) were used for optimization of SIF interval type-2, aiming at to reduce the diagnostic error. The results obtained in tests of computer simulation show the effectiveness of the proposed methodology.

Keywords: Fault Diagnosis, Parametric Identification System, Interval Type-2 Fuzzy, Genetic Algorithms.

1 INTRODUÇÃO

Com a automação incorporada aos meios de produção, o desenvolvimento de estratégias que visam monitorar os processos, mostrando o comportamento ou estado atual do sistema, e indicando os estados indesejados ou não permitidos, são o foco de estudos na área de manutenção com o objetivo de evitar danos e/ou acidentes. Os desvios do comportamento normal, resultado de falhas ou erros, podem ser atribuídos a inúmeras causas, podendo resultar em curtos ou longos períodos de mau funcionamento, paradas não programadas, ou falhas permanentes, se ações preditivas que detectem e isolem as faltas do sistema não forem tomadas (ISERMANN, 2006).

Nesse sentido, métodos de monitoramento de sistemas para diagnóstico de faltas incipientes são alvos de pesquisas para o desenvolvimento de ferramentas que possam ser incorporadas à manutenção dos meios de produção. Com o desenvolvimento e a sofisticação das ferramentas de manutenção, métodos para detecção, identificação e diagnóstico de faltas estão se tornando cada vez mais utilizados, diminuindo o número de alarmes falsos e aumentando a segurança operacional dos sistemas. O emprego dessas técnicas também contribui significativamente com a redução de paradas não programadas, redução dos custos de manutenção e redução de falhas permanentes e inesperadas em máquinas e sistemas. Isso permite o uso otimizado da disponibilidade de pessoal para manutenção no momento da falta, além de contribuir para prolongar a vida útil dos equipamentos.

A técnica para detecção de faltas desenvolvida nesse trabalho será aplicada em motores elétricos de indução, o qual é de grande aplicação industrial devido à sua robustez, versatilidade e baixo custo de fabricação. Embora essas máquinas rotativas apresentem boa construção e robustez, a possibilidade de faltas é inerente, e ocorre devido a fatores tais como: exposição à intemperes ambientais, condições hostis de funcionamento, estresse de funcionamento ou mesmo defeitos provenientes da própria fabricação. Desse modo, são inúmeras as possibilidades de faltas, sendo de natureza elétrica ou mecânica, podendo ser desde a quebra ou rachaduras nas barras do rotor até faltas oriundas do curto-circuito dos enrolamentos estatóricos. Tais faltas podem provocar desequilíbrio das tensões e correntes, decréscimo do valor médio do torque e da potência útil, com o consequente aumento das perdas e redução da eficiência do motor.

Nesse trabalho, o alvo de estudo serão as faltas incipientes. Em particular faltas do tipo curto-circuito parcial nas espiras do enrolamento do estator. Um sinal tipo rampa é utilizado para modelar e simular a falta cujo efeito principal é o de uma redução aparente no número de

espiras do estator. As informações da falta serão obtidas a partir da avaliação de valores de parâmetros de um modelo identificado com o de estimadores paramétricos. Essa é uma opção de grande aplicabilidade, pois os valores dos parâmetros do modelo estimado são ricos em informações das características dinâmicas da planta. Para obtenção de um modelo matemático do processo, modelo autoregressivo com entradas exógenas (ARX), serão coletados sinais de tensão e de corrente (entrada e saída) tanto para o sistema operando livre de faltas, quanto para o sistema sujeito a uma falta incipiente, tipo curto-circuito parcial nas espiras no enrolamento do estator. Os parâmetros da função de transferência discreta do modelo ARX serão estimados recursivamente pelo método dos mínimos quadrados recursivos (MQR) e representarão, de forma condensada, o comportamento da dinâmica dominante do sistema.

Por meio de uma análise comparativa será possível verificar possíveis desvios do comportamento normal do sistema apenas observando o comportamento dos parâmetros para os casos com faltas. Desse modo, espera-se que a variação dos parâmetros seja consistente com a severidade da falta permitindo assim a detecção confiável da mesma. Para identificação do percentual de espiras avariadas, os parâmetros da função de transferência discreta do modelo ARX serão entradas de um sistema avaliador *fuzzy* intervalar do tipo-2, com incertezas nos valores de suporte da função de pertinência.

A complexidade computacional para o desenvolvimento de um algoritmo com base em sistemas *fuzzy* do tipo-2 é maior quando comparado com sistemas *fuzzy* do tipo-1, isso porque existe uma dimensão a mais em sua função de pertinência. Essa dimensão extra é chamada de função de pertinência secundária. Assim para cada função de pertinência primária (função de pertinência do conjunto *fuzzy* tipo do-1), haverá um grau secundário (peso) a ser computado. Por esse motivo conjuntos *fuzzy* do tipo-2 permitem modelar vários tipos de incertezas, as quais não poderiam ser modeladas apropriadamente se fossem apenas conjuntos *fuzzy* do tipo-1. Com o objetivo de simplificar a programação, mas sem eliminar as incertezas do conjunto primário, são utilizados conjuntos *fuzzy* intervalares do tipo-2. Em tais conjuntos *fuzzy* intervalares, as funções de pertinência secundárias distribuem uniformemente suas incertezas sobre a mancha de incerteza ou *footprint of uncertainty* (FOU) do conjunto *fuzzy* primário.

A utilização de sistemas de inferência *fuzzy* (SIF) intervalares do tipo-2 para diagnóstico de faltas é justificada por considerar incertezas em suas funções de pertinência, a FOU. Desse modo, incertezas provenientes da estimação paramétrica ganham representatividade em conjuntos *fuzzy* do tipo-2, enquanto que em sistemas *fuzzy* do tipo-1 as funções de pertinência se baseiam em parâmetros que desconsideram incertezas presentes nos

próprios parâmetros, como os desvios padrões dos parâmetros estimados, comuns ao processo de identificação de sistemas.

Com o objetivo de reduzir ainda mais o erro de diagnóstico de faltas, outra ferramenta será introduzida nesse trabalho, são os algoritmos genéticos (AG's). Em muitos artigos da área são propostas diversas metodologias de otimização de SIF do tipo-2 utilizando AG's, a mais comum é a utilização de AG para otimização da FOU, mas outras otimizações possíveis são a da base de regras, a da função de pertinência secundária, a do defuzzificador, e a do redutor de tipo, sendo este último caso, uma proposta deste trabalho não encontrada em nenhum artigo ou fonte de pesquisa envolvendo otimização de SIF do tipo-2.

Algoritmos genéticos são amplamente utilizados na otimização de sistemas por não ser unicamente uma técnica baseada na varredura de valores, mas por se basear na convergência das respostas buscando uma função objetivo. A função objetivo a ser minimizada é o erro médio quadrático (MSE), que corresponde ao erro cometido na tentativa de identificar/diagnosticar a falta.

1.1 Objetivos

Este trabalho propõe o desenvolvimento de um sistema de detecção e diagnóstico de faltas incipientes, baseado em análise dos parâmetros do modelo matemático do sistema e da utilização de SIF do tipo-2 para identificação da intensidade da avaria atuante no processo. Com o objetivo de reduzir ainda mais o erro de diagnóstico, é proposto uma metodologia de otimização aplicada na “mancha de incerteza” (FOU) e no redutor de tipo (RT) do SIF do tipo-2, utilizando-se algoritmos genéticos (AG's). Desse modo pretende-se aumentar a precisão da identificação da falta, principal objetivo do trabalho, uma vez que o diagnóstico de faltas incipientes permite o monitoramento e o planejamento para manutenção de máquinas e equipamentos.

1.2 Estrutura do Trabalho

O trabalho é organizado da seguinte forma:

No Capítulo 2, será abordada a metodologia para detecção de faltas baseada no modelo do processo. Sendo assim, um estudo envolvendo a modelagem da falta aplicada na planta, e as etapas do processo de detecção de faltas serão apresentadas. Para a modelagem do

sistema, o método utilizado é o baseado no modelo do processo, técnica não invasiva, e, para a representação matemática desse modelo, optou-se por uma estrutura ARX (auto-regressivo com entradas exógenas), cujos parâmetros serão estimados recursivamente, utilizando-se mínimos quadrados recursivos (MQR).

No Capítulo 3, será introduzido o conceito de conjuntos *fuzzy* do tipo-2, apresentando suas principais diferenças em relação aos conjuntos *fuzzy* do tipo-1. Também será apresentado o conceito de região de incerteza, ou mancha de incertezas (*footprint of uncertainty* – FOU) em funções de pertinência gaussianas e triangulares, e o estudo da estrutura de SIF do tipo-2 composta por: base de regras, bloco de inferência, fuzzificador, redutor de tipo, e defuzzificador. Conjuntos *fuzzy* intervalar do tipo-2, caso particular de SIF do tipo-2, serão apresentados como uma alternativa à complexidade dos conjuntos *fuzzy* tipo-2 para programação. Sua principal característica é a distribuição uniforme da função de pertinência secundária sobre a FOU de função de pertinência primária.

No Capítulo 4, se fará uma breve abordagem sobre algoritmos genéticos (AG's), seus principais fundamentos, e sua estrutura dividida em: inicialização, avaliação ou *fitness*, seleção, cruzamento ou *crossover*, mutação, atualização e finalização. Será abordado também o conceito de Sistemas *Fuzzy* Genéticos (SFG's), propondo uma metodologia para otimização da FOU e do RT.

No Capítulo 5, serão apresentados e analisados os resultados de estudos de simulação de um motor elétrico de indução sujeito a falta, no qual será aplicado um sinal de teste do tipo sequência binária pseudoaleatória (SBPA) modulando a amplitude da tensão de entrada, para ser feita a identificação do modelo do sistema. Serão analisadas grandezas elétricas, tensão e corrente eficaz no estator, para as condições com falta e sem a falta incipiente, essas grandezas elétricas serão entradas de um algoritmo baseado em MQR que irá estimar recursivamente os parâmetros do modelo ARX. Esses parâmetros trazem informações da dinâmica do sistema e da intensidade da falta. Esses mesmo parâmetros serão entradas de um SIF intervalar do tipo-2, e a intensidade da falta será identificada na saída desse sistema, com uma determinada incerteza na precisão que será chamada de erro de diagnóstico. Com o objetivo de reduzir o erro de diagnóstico, AG's serão utilizados para otimizar esses resultados, ou seja, para buscar reduzir o erro diagnóstico.

No Capítulo 6, serão discutidas algumas sugestões para o desenvolvimento de futuros trabalhos na área de detecção, identificação e diagnóstico de faltas, como, por exemplo, a inserção de outro tipo de falta no modelo, e aplicação das técnicas em um sistema com múltiplas faltas.

2 MÉTODO DE DETECÇÃO DE FALTAS BASEADO EM MODELO DO PROCESSO

2.1 Introdução

Antes de se aplicar as técnicas para identificação e diagnóstico de faltas elétricas em estator de motor trifásico de indução, será necessário primeiramente definir o tipo de falta, suas características, etc. Também será necessário ter-se um modelo matemático do sistema sob estudo. Tal modelo matemático será obtido utilizando-se técnicas de modelagem de sistemas. Nesse trabalho se fará uso de técnicas não-invasivas, que são técnicas que se baseiam em medidas acessíveis (medidas externas). No caso, tensão e corrente eficazes no estator de um motor trifásico de indução são usadas, para que uma representação matemática do sistema seja obtida. Finalizando essa etapa, técnicas para estimação dos parâmetros desse modelo serão apresentadas, para que um modelo matemático do sistema seja obtido e para que os desvios provocados pela falta sejam detectados.

2.2 Modelagem da falta aplicada na planta

Para o correto funcionamento dos métodos que serão aplicados nesse trabalho é muito importante um estudo sobre a modelagem da falta. Uma abordagem realista pressupõe o entendimento entre a falta física real e os seus efeitos sobre os modelos matemáticos do processo. Isso normalmente só pode ser obtido por uma inspeção do processo real, que ocorre através do entendimento da física e da análise dos sintomas das faltas. Há muitas razões para o aparecimento de faltas, e basicamente ocorrem por:

- a) Erro de projeto ou de implementação;
- b) Erro de operação ou falta de manutenção;
- c) Envelhecimento, desgaste, e corrosão durante a operação normal.

Uma falta é definida como um desvio de pelo menos uma propriedade particular, ou característica, ou de uma condição normal. A característica pode ser qualquer quantidade física. Se a quantidade é parte de uma lei física $Y(t) = g[U(t), x(t), \theta]$, sob a forma de uma equação, e medidas de $U(t)$ e $Y(t)$ estão disponíveis, a característica se expressa em termos da variável de entrada $U(t)$, variável de saída $Y(t)$, variável de estado $x_i(t)$ (função

dependente do tempo), e parâmetro θ_i (geralmente o valor constante). Portanto, as faltas podem aparecer como alterações de sinais ou de parâmetros.

2.3 Classificação das faltas

Basicamente as faltas podem ser classificadas quanto: ao tipo de falta, a sua localização e a sua atuação no sistema, a seguir serão discutidos cada um dos casos apresentados.

2.3.1 Classificação quanto ao tipo de falta

A Figura 2.1 a seguir representa o comportamento da falta versus o tempo de funcionamento do sistema, como observado são três os tipos de falta.

- a) Falta abrupta (*stepwise*);
- b) Falta incipiente (*drift-like*);
- c) Falta intermitente (*with interrupts*).

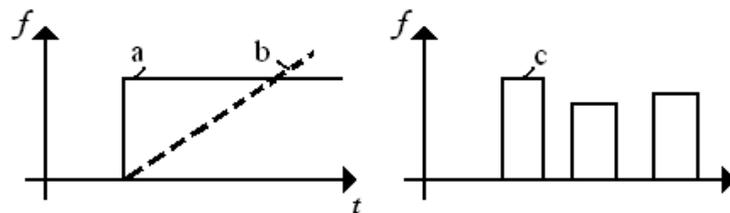


Figura 2. 1: Tipos de faltas em função do tempo: (a) abrupta; (b) incipiente; (c) intermitente.
Fonte: (ISERMANN, 2006)

Como sugere a própria Figura 2.1, as faltas abruptas (a) são aquelas que ocorrem sem que haja “aviso” prévio do sistema, sem sintomas, ou seja, repentinamente, e, portanto, dificilmente será detectada, podendo provocar faltas permanentes no sistema (falhas) se medidas imediatas não forem tomadas. As faltas do tipo incipientes (b) são faltas que se caracterizam por pequenos desvios do comportamento normal do sistema, muitas vezes seus sintomas são camuflados por controladores (sistemas adaptativos). Tais faltas dificilmente são detectadas utilizando técnicas clássicas de manutenção como a variação de temperatura, trepidações ou ruídos provenientes do sistema (CHOW, 1997). Já as faltas intermitentes (c) são aquelas que apresentam certa alternância no tempo, causadas por perturbações que podem ser periódicas ou não. Embora seja uma falta detectável, dependendo da natureza, necessitará da substituição imediata do equipamento devido principalmente à aleatoriedade de sua ocorrência, caracterizando um cenário de falha.

Para este estudo, será aplicado no sistema uma falta incipiente (b) tipo curto-circuito parcial nas espiras do enrolamento do estator de um motor trifásico de indução. Sendo assim, um sinal do tipo rampa que decresça lentamente ao longo do tempo, será aplicado ao sistema. O objetivo é detectar a falta em seu início, permitindo ao operador programar a parada para manutenção muito antes de haver um risco de dano permanente ao sistema.

2.3.2 Classificação quanto à localização da falta

Quanto à localização, as faltas podem se encontrar no atuador, no sistema dinâmico ou no sensor. A Figura 2.2 representa a ligação entre esses três componentes que fazem parte do processo industrial.

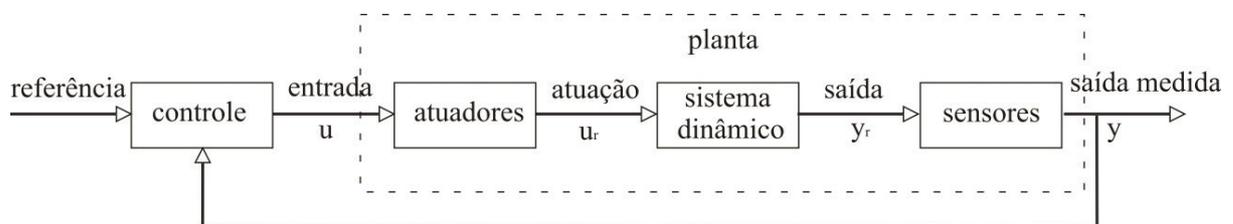


Figura 2. 2: Classificação da falta quanto a sua localização na planta.

As definições para cada situação são mostradas a seguir:

Falhas em atuadores: são faltas que atingem qualquer equipamento que atua no sistema levando-o ao mau funcionamento.

Falhas no sistema dinâmico: é qualquer tipo de alteração que provoca uma mudança na relação entrada e saída do sistema, provocando, portanto, alteração no modelo matemático que representa o sistema.

Falhas em sensores: são falhas de medição observadas em variações específicas de alguma variável de saída do sistema, geralmente quando observadas são desconsideradas como variações validas do sistema.

2.3.3 Quanto à atuação da falta no sistema

Quanto a sua atuação no sistema, as faltas são classificadas como faltas aditivas ou multiplicativas (Figura 2.3). Alterações de sinais são faltas aditivas, porque uma variável $Y_u(t)$ é alterada por uma adição de $f(t)$.

$$Y(t) = Y_u(t) + f(t) \quad (2.1)$$

e mudanças de parâmetros são consideradas faltas multiplicativas, pois uma outra variável $U(t)$ é multiplicada por $f(t)$

$$Y(t) = (a + \Delta a(t))U(t) = aU(t) + \Delta a(t)U(t)$$

$$Y(t) = Y_u(t) + f(t)U(t). \quad (2.2)$$

Para a falta aditiva a mudança detectável $\Delta Y(t)$ da variável é independente de qualquer outro sinal

$$\Delta Y(t) = f(t) \quad (2.3)$$

(Em vez do sinal de saída $Y(t)$, o sinal de entrada $U(t)$ ou uma variável de estado $x_i(t)$ podem ser influenciados).

No entanto, para as faltas multiplicativas, a alteração detectável da saída $\Delta Y(t)$ depende do sinal de entrada $U(t)$

$$\Delta Y(t) = f(t)U(t) \quad (2.4)$$

Isto significa que, se o sinal $Y(t)$ pode ser medido, a falta aditiva é detectável para qualquer $Y_u(t)$, mas a falta multiplicativa somente pode ser detectável se $U(t) \neq 0$. Logo a medida da mudança de $\Delta Y(t)$, depende do tamanho de $U(t)$.

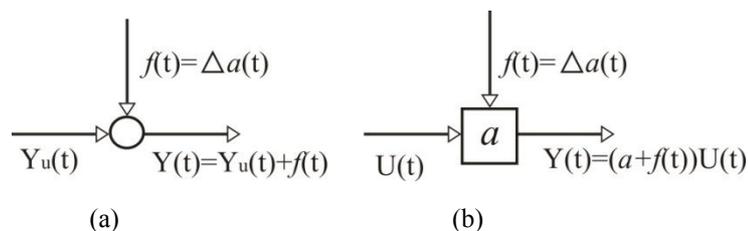


Figura 2. 3: Tipos de Faltas: (a) falta aditiva para um sinal de saída; (b) falta multiplicativa.

2.4 Etapas do processo de detecção e diagnóstico de faltas

As etapas de monitoramento de processos industriais que vão desde o seu funcionamento normal até a detecção e diagnóstico de faltas, envolve algumas fases, como mostradas na Figura 2.4.



Figura 2. 4: Etapas do processo de detecção e isolamento de faltas

Analisando a Figura 2.4, percebe-se que os sinais de entrada e saída do processo real são inseridos no sistema de *fault detection and isolation* (FDI), e através dessa relação entre os sinais, é possível verificar se o funcionamento do sistema fugiu de suas condições normais de operação, nessa etapa embora não se tenha muita informação do sistema estudado, é possível detectar desvios do comportamento normal do sistema, ou seja, possíveis faltas, por esse motivo essa etapa refere-se à etapa de detecção.

A segunda etapa refere-se ao isolamento da falta, ou seja, a descoberta do local físico do sistema avariado. A terceira etapa corresponde à identificação e ao diagnóstico da falta, identificar significa classificar a falta e definir sua intensidade. E, por último, na etapa de restauração do sistema, procura-se tomar decisões que reduzam danos ao sistema ou que não comprometam a produção, como parada programada para manutenção ou substituição de equipamentos avariados por reservas. Nesse trabalho será tratada a detecção e identificação da falta, e serão propostos futuros trabalhos envolvendo todas as etapas aqui discutidas.

2.5 Modelo do processo

Os métodos de detecção de faltas baseados em modelo do processo, como já mencionado no início do Capítulo, são métodos que utilizam técnicas não-invasivas e, por esse motivo, dispensam análise minuciosa para descrever condições internas do sistema estudado. Pelo método do modelo do processo, um modelo do sistema em questão é obtido utilizando apenas sinais de entrada e saída aplicados e coletados diretamente de um modelo dinâmico que representa o sistema. Desse modo, nessa etapa, é possível gerar vários modelos matemáticos do mesmo sistema, o que possibilita verificar possíveis mudanças matemáticas nos modelos obtidos. Essas mudanças (desvios), são os sintomas gerados que indicam a diferença entre um estado correspondente à ação da falta e o estado onde o sistema está livre de faltas, logo além de ser possível obter uma representação matemática do sistema, é possível detectar desvios do comportamento normal, ou seja, as faltas, caracterizando essa etapa como etapa de detecção da falta.

A Figura 2.5 representa uma estrutura de detecção de faltas baseada no método do modelo do processo. Analisando a figura observa-se que a identificação de uma falta aplicada em atuadores, processos ou sensores da planta é feita pela correlação entre os sinais de entrada U e saída Y nos inúmeros processos dessa planta resultando em diferentes sinais medidos e, através da técnica de estimação paramétrica, são gerados resíduos (r) e

parâmetros estimados (θ) os quais representam as características do processo. Os valores medidos são comparados com os valores nominais e as mudanças de características são detectadas, então os sintomas (s) são gerados para fins de diagnóstico.

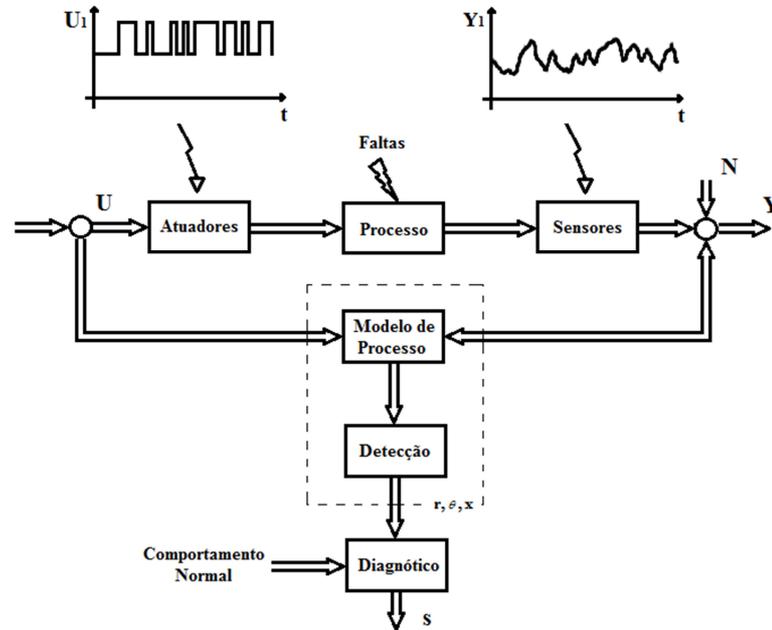


Figura 2. 5: Método de detecção de falta baseado em modelo do processo.
Fonte: Adaptado (ISERMANN, 2006).

2.6 Métodos de detecção de faltas

Diversas são as técnicas já utilizadas para construção de ferramentas capazes de detectar, identificar e diagnosticar faltas ou falhas em sistemas industriais. Nas referências consultadas observa-se que cada autor tem um método particular de como sistematizar essas técnicas, como em Simani *et al* (2003), Gertler (1998), e Patton *et al* (2000). Embora consultadas essas bibliografias, neste trabalho, escolheu-se seguir a abordagem de Isermann (2006), principalmente por tratar de maneira mais intuitiva à classificação dessas técnicas. Em Isermann (2006), são apresentadas diversas técnicas de detecção de faltas, mostradas em sequência abaixo, porém, neste trabalho, trata-se apenas do método de identificação de faltas utilizando identificação de processo:

- Detecção de faltas com verificação de limite
- Detecção de faltas com modelos de sinal
- Detecção de faltas com equações de paridade
- Detecção de faltas com método de identificação de processos

- Detecção de faltas com observadores de estados e estimadores de estados
- Detecção de faltas de malhas de controle
- Detecção de faltas com análise de componentes principais (PCA)

A metodologia adotada no trabalho será a detecção de faltas com método de identificação do processo. Como já mencionamos anteriormente, é um dos métodos tratados em Isermann (2006) baseado em modelo do processo. Esse método, portanto, identifica um modelo matemático do sistema através da correlação de variáveis obtidas por medições externas ao sistema, essas variáveis são definidas como entrada $u(t)$ e saída $y(t)$. Como não há necessidade de se conhecer internamente a estrutura do sistema, essa metodologia é preferida quando o objetivo é a obtenção de um modelo matemático que represente adequadamente o comportamento dinâmico do sistema em uma dada faixa de operação, e quando se deseja obter informações de possíveis mudanças no comportamento do processo através da análise das variáveis provenientes do modelo e do processo real com a introdução de faltas. Desse modo tais modelos são fundamentais para essa modalidade de detecção de faltas, dado que eles servirão, neste caso, como referência do processo industrial quando o mesmo está em situação normal de funcionamento. A Figura 2.6 mostra o diagrama em blocos representativo desse modelo.

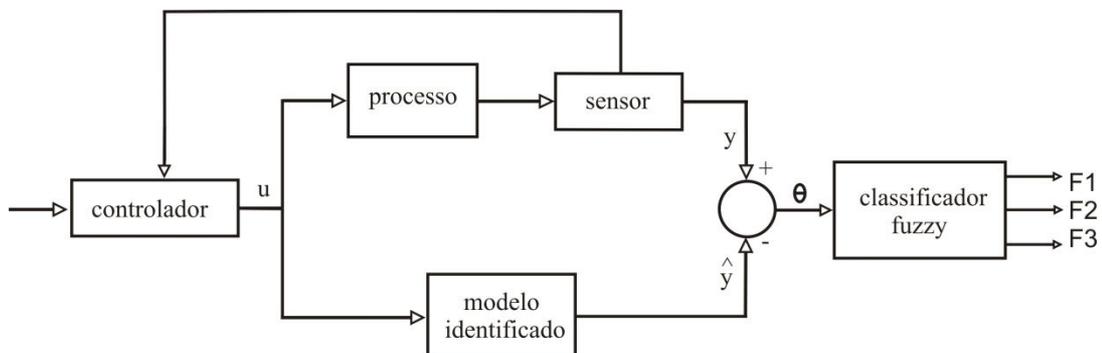


Figura 2. 6: Diagrama em blocos para representação do método de detecção e classificação de faltas.
Fonte: (SILVA, 2008).

Assim como na Figura 2.5, θ representa na Figura 2.6, os parâmetros do modelo matemático do sistema identificado. Como se sabe, os parâmetros não apresentam nenhum significado físico, porém esses parâmetros, independentes do tipo de modelagem, trazem as características dinâmicas do sistema. Isso significa que, ao alterarmos a dinâmica do sistema com a introdução de faltas, esperam-se variações paramétricas, logo os parâmetros θ , além representarem matematicamente o sistema, podem indicar possíveis faltas devido às variações

detectadas. Para um sistema multi-faltas, ou para o caso de faltas variantes no tempo (faltas incipientes, por exemplo), os parâmetros serão entradas de um sistema *fuzzy* de identificação, tal sistema *fuzzy* irá ou identificar a localidade da falta ou a sua intensidade. No sistema *fuzzy* proposto no trabalho, se fará a identificação da intensidade da avaria, mais detalhes sobre o sistema *fuzzy* utilizado serão tratados no Capítulo 3.

Na próxima seção, será discutida qual será o modelo representativo escolhido para o sistema, e o qual será a técnica de estimação paramétrica utilizada para se obter os parâmetros do modelo representativo do mesmo.

2.7 Introdução às técnicas convencionais de estimação

Estimação de parâmetros de máquinas elétricas é um processo muito importante nas áreas de predição de desempenho, análises de simulações e controle. Uma estratégia muito comum, mas não muito eficaz para estimação paramétrica, é a obtenção dos parâmetros em motores de indução por meio de dados provenientes de ensaios de rotor bloqueado e ensaios a vazio. Porém, industrialmente, essa medida torna-se bastante inviável devido à necessidade de se ter em setores estratégicos de produção algumas máquinas em constante operação, ou também pelo fato destes testes negligenciarem o comportamento dinâmico das máquinas. Em vista disso, o uso de técnicas de estimação de parâmetros *on-line* e formulação em espaço de estados se tornam mais interessantes. A seguir será apresentado o modelo ARX (autoregressivo com entradas exógenas, do inglês *autoregressive with exogenous inputs*), que é um dos modelos de representação de sistemas baseado em modelos do processo, e também o método dos MQR (mínimos quadrados recursivos), método paramétrico de obtenção dos parâmetros do modelo matemático, modelo ARX. A Figura 2.7 retrata o procedimento de modelagem e identificação de sistemas.

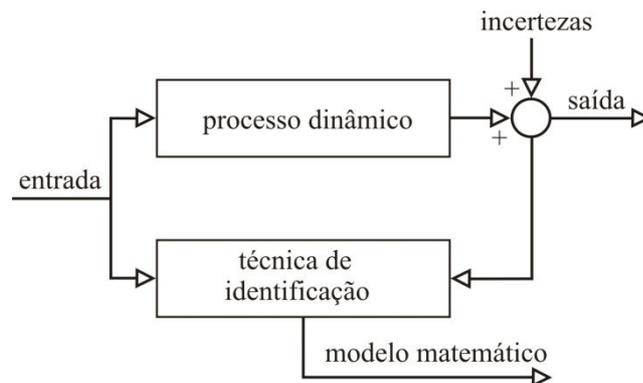


Figura 2. 7: Procedimento para identificação de processos.
Fonte: (COELHO & COELHO, 2004).

2.8 Representação linear em tempo discreto com ruído

Na presente secção o modelo representativo do sistema, máquina elétrica, que será apresentado, é o modelo ARX (autoregressivo com entradas exógenas, do inglês *autoregressive with exogenous inputs*), esse modelo dado pela expressão $A(q)y(k) = B(q)u(k)$ é exemplo de um modelo IIR (resposta infinita ao impulso, do inglês *infinite impulse response*), sendo assim apresenta natureza recursiva, pois a presença de $A(q)$ implica recursividade, como pode ser constatado pelo fato da respectiva função de transferência, $Z\{B(q)\}/Z\{A(q)\}$, ser racional, ao passo que em sistemas cujos modelos são FIR (resposta finita ao impulso, do inglês *finite impulse response*) as respectivas funções de transferência são polinomiais (AGUIRRE, 2007).

De maneira geral os modelos FIR e IIR são obtidos pela Equação 2.5. O modelo ARX por ser a representação de um modelo IIR também é obtido da equação geral a seguir:

$$A(z^{-1})y(t) = z^{-d} \frac{B(z^{-1})}{F(z^{-1})} u(t) + \frac{C(z^{-1})}{D(z^{-1})} e(t) \quad (2.5)$$

Fazendo $C(q) = D(q) = F(q) = 1$, e sendo $A(q)$ e $B(q)$ polinômios arbitrários, o modelo ARX será:

$$A(z^{-1})y(t) = z^{-d} B(z^{-1})u(t) + v(t) \quad (2.6)$$

Onde

$$\begin{aligned} A(z^{-1}) &= 1 + a_1 z^{-1} + \dots + a_{n_a} z^{-n_a} \\ B(z^{-1}) &= b_0 + b_1 z^{-1} + \dots + b_{n_b} z^{-n_b} \end{aligned} \quad (2.7)$$

e n_a é o número de parâmetros de $A(z^{-1})$, n_b é o número de parâmetros de $B(z^{-1})$, e d é o atraso puro do sistema.

Ou substituindo (2.7) em (2.6) tem-se (2.8), obtém-se:

$$y_k + a_1 y_{k-1} + \dots + a_{n_a} y_{k-n_a} = b_1 u_{k-d} + \dots + b_{n_b} u_{k-n_b-d+1} + e_k \quad (2.8)$$

Uma vez que o ruído $v(k)$ aparece diretamente na equação, o modelo ARX é normalmente classificado como pertencente à classe de modelos de erro da equação. A equação do modelo (2.6) pode ser reescrita da seguinte forma:

$$y(t) = \frac{B(z^{-1})}{A(z^{-1})} u(t-d) + \frac{1}{A(z^{-1})} e(t) \quad (2.9)$$

O que evidencia as funções de transferência do sistema $B(z^{-1})/A(z^{-1})$ e do ruído $1/A(z^{-1})$, representadas esquematicamente na Figura 2.8.

A Equação 2.9 é a forma canônica (modelo paramétrico) para um sistema dinâmico discreto com uma entrada, uma saída e um atraso de transporte que é um múltiplo inteiro do período de amostragem, quando sujeito a perturbações estocásticas.

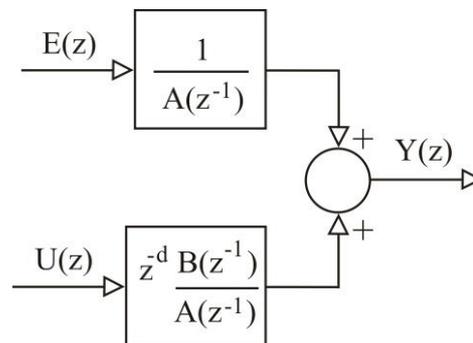


Figura 2. 8: Representação esquemática do modelo ARX.

Esse modelo inclui uma variável exógena $E(z)$ (e_k) entrando no sistema, visando representar um erro no modelo. A atuação dessa variável no modelo é feita através de um processo autoregressivo, o que justifica o nome do modelo.

2.9 Estimador dos mínimos quadrados recursivo

O estimador dos mínimos quadrados recursivos (MQR) é um algoritmo de identificação com diversos propósitos, tais como supervisão, rastreamento de parâmetros variantes para controle adaptativo, filtragem, previsão, processamento de sinais, detecção e diagnóstico (COELHO & COELHO, 2004).

Na implementação de um estimador recursivo para obtenção de parâmetros em sistemas sob atuação de faltas em tempo real, o algoritmo do estimador de parâmetros deve ser interativo, com o modelo do sistema sendo atualizado a cada período de amostragem, essa característica torna esse tipo de identificação ideal para a detecção de faltas, visto que se tem, no caso de faltas incipientes, variações na dinâmica do sistema com a evolução da falta e, sendo o algoritmo um estimador *on-line*, a cada nova medida disponível tem-se um conjunto de vetores de parâmetros atualizados, o procedimento é apresentado na Figura 2.9.

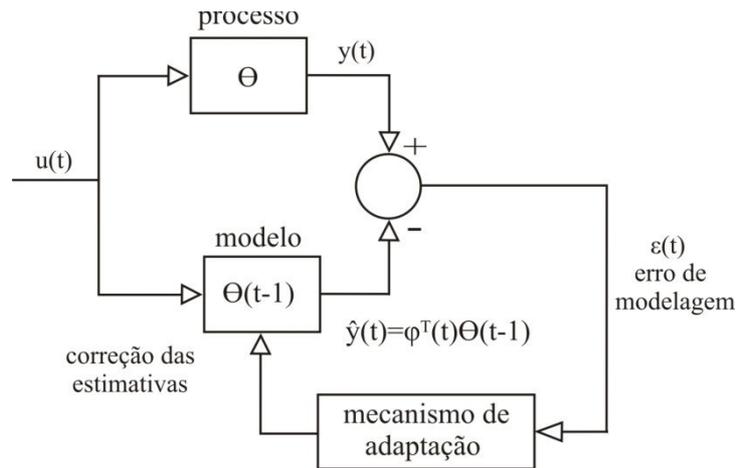


Figura 2. 9: Procedimento iterativo na estimação de parâmetros.
Fonte: (COELHO & COELHO, 2004).

Para o desenvolvimento das equações de estimador dos MQR, deve-se comparar a estimativa baseada nas medidas em instantes que variam de 1 (um) até $t = N$ com a estimativa nas medidas nos instantes de 1 (um) até $(t + 1)$ (COELHO & COELHO, 2004).

Da teoria dos estimadores de mínimos quadrados não-recursivo para amostras variando de $N = [1 \rightarrow t]$ tem-se a equação (2.10):

$$\hat{\theta}(t) = [\phi^T \phi]^{-1} \phi^T Y \quad (2.10)$$

Onde:

$\hat{\theta}(t)$, é o meu vetor de parâmetros estimados; $\phi(t)$, é o vetor de medidas; Y , é o vetor de saídas.

$$\phi(t) = \begin{bmatrix} \phi^T(1) \\ \phi^T(2) \\ \dots \\ \phi^T(t) \end{bmatrix}; Y = \begin{bmatrix} y(1) \\ y(2) \\ \dots \\ y(t) \end{bmatrix}$$

Supor que no instante $(t+1)$ obtém-se nova medida do sistema, então os vetores de medida e saída são reescritos como

$$\phi(t+1) = \begin{bmatrix} \phi^T(1) \\ \phi^T(2) \\ \dots \\ \phi^T(t) \\ \phi^T(t+1) \end{bmatrix} = \begin{bmatrix} \phi(t) \\ \phi^T(t+1) \end{bmatrix}; Y(t+1) = \begin{bmatrix} y(1) \\ y(2) \\ \dots \\ y(t) \\ y(t+1) \end{bmatrix} = \begin{bmatrix} Y(t) \\ y(t+1) \end{bmatrix}$$

e as estimativas no instante de tempo t são

$$\hat{\theta}(t) = [\phi^T(t)\phi(t)]^{-1} \phi^T(t)Y(t) \quad (2.11)$$

enquanto que, no instante $(t+1)$, são dadas por (2.12)

$$\hat{\theta}(t+1) = [\phi^T(t+1)\phi(t+1)]^{-1} \phi^T(t+1)Y(t+1) \quad (2.12)$$

onde

$$\begin{aligned} \phi^T(t+1)\phi(t+1) &= [\phi^T(t) \quad \varphi(t+1)] \begin{bmatrix} \phi(t) \\ \varphi^T(t+1) \end{bmatrix} \\ \phi^T(t+1)\phi(t+1) &= \phi^T(t)\phi(t) + \varphi(t+1)\varphi^T(t+1) \end{aligned} \quad (2.13)$$

Seguindo o desenvolvimento matemático para obtenção do estimador paramétrico dos MQR como em Coelho e Coelho (2004, p.114), a forma final do vetor de parâmetros estimados recursivamente do modelo ARX de 1ª ordem em tempo discreto no instante $(t+1)$, é dada por:

$$\hat{\theta}(t+1) = \hat{\theta}(t) + K(t+1) \{y(t+1) - \varphi^T(t+1)\hat{\theta}(t)\} \quad (2.14)$$

Onde:

$\hat{\theta}(t)$, é o vetor de parâmetros estimados dos MQR para amostras variando de $N=[1 \rightarrow t]$;

$K(t+1) = P(t+1)\varphi(t+1) = \frac{P(t)\varphi(t+1)}{1 + \varphi^T(t+1)P(t)\varphi(t+1)}$, é um vetor coluna denominado de ganho

do estimador;

$P(t+1)$, é a matriz de covariância dada por $P(t+1) = P(t) - \frac{P(t)\varphi(t+1)\varphi^T(t+1)P(t)}{1 + \varphi^T(t+1)P(t)\varphi(t+1)}$;

$y(t+1) - \varphi^T(t+1)\hat{\theta}(t)$, é convencionalmente utilizada como definição da variável erro $\varepsilon(t+1)$, denominada erro de precisão.

2.10 Conclusão

Neste Capítulo, foi abordado, de forma teórica, o processo da inserção de faltas na planta, sua classificação, seus possíveis efeitos no comportamento dinâmico do sistema e sua detecção através da análise de sinais capturados externamente ao processo. Neste sentido, foi proposta uma modelagem matemática do sistema do tipo modelo do processo com representação linear em tempo discreto e com ruído. Nessas condições, um modelo ARX foi escolhido e, para a obtenção dos parâmetros da função de transferência do modelo discreto, foi utilizada a técnica dos MQR, que permitiu obtê-los através de medições *on-line*. Assim um vetor de parâmetros é atualizado em tempo real a cada período de amostragem e, por meio dos parâmetros, que “funcionam” como indicadores do estado do sistema, é possível detectar as faltas. Justifica-se a escolha da técnica de estimação recursiva devido à quantidade de dados armazenada exigir pouca memória, se comparado com técnicas de estimação paramétricas não-recursivas.

3 CONJUNTO *FUZZY* INTERVALAR DO TIPO-2

3.1 Introdução

Baseada na teoria de conjuntos *fuzzy*, a lógica *fuzzy* ou difusa permite a classificação de dados, de informações vagas, imprecisas ou ambíguas. Esta característica permite aplicar essa lógica nos mais variados tipos de sistemas, como por exemplo, para a obtenção de soluções em problemas que envolvam muitas variáveis, para aquisição de soluções de dados não definidos, permitindo reportar muito mais informação do que a lógica clássica, por não estar restrita a valores verdades do tipo “verdadeiro” ou “falso” (SHAW & SIMÕES, 1999).

Desse modo Zadeh (1965), introduziu o conceito de conjuntos *fuzzy* com o objetivo de capturar, representar e processar dados associados a noções linguísticas ou objetos com fronteiras mal definidas de maneira formal. Assim valores verdades anteriormente limitados, em lógica nebulosa, ganham imprecisões para introduzirem outras margens de classificação anteriormente desconsideradas, podendo ser expressos linguisticamente como: “verdade”, “muito verdade”, “não verdade”, “falso” e “muito falso”, onde cada termo linguístico é interpretado como um subconjunto *fuzzy* no intervalo unitário. Assim, a lógica *fuzzy* descreve uma solução com muito mais detalhe e gradualmente, reduzindo a perda de informação e fornecendo um resultado mais aproximado possível com a realidade do problema.

Embora a lógica *fuzzy* tenha introduzido a classificação de conjuntos com fronteiras mal definidas, incertezas provenientes do processo de medição, ou erros numéricos do próprio algoritmo de identificação não são considerados no algoritmo para o desenvolvimento do sistema *fuzzy* convencional e, para esses casos, outra abordagem é adotada neste trabalho.

Em nível empírico, a incerteza está presente em qualquer medida, sendo o resultado de uma combinação de sucessivos erros de medição e de limites de resolução dos instrumentos de medição; em nível cognitivo, a incerteza está associada à informação ambígua inerente à linguagem natural (KLIR & WIERMAN, 1998). Além disso, incerteza é o resultado da aleatoriedade nos dados e no processo que os gera (BERENJI, 1988).

Adicionalmente, é sabido que sistemas reais são, por natureza, ruidosos e não lineares, e que qualquer elemento do sistema pode contribuir com incertezas. Incerteza é uma parte inerente a sistemas de inferência *fuzzy* (SIF) usados em aplicações reais. As seguintes fontes de incerteza podem estar presentes em um SIF (MENDEL, 2000; MENDEL, 2003):

- Imprecisão linguística (*fuzziness*)

A imprecisão linguística é a incerteza em relação ao significado das palavras usadas nos antecedentes e consequentes de regras linguísticas.

- Conflito (*strife*)

O conflito é um tipo de incerteza que ocorre quando diferentes consequentes podem ser obtidos para uma mesma regra, isso ocorre quando o conhecimento é extraído de um grupo de especialistas que não estão totalmente de acordo.

- Imprecisão numérica (*nonspecificity*)

A imprecisão numérica é a incerteza causada por deficiência de informação ou por ruídos presentes nas informações que ativam o SIF, sendo usadas para ajustar os seus parâmetros.

Assim, além dessas imprecisões próprias do SIF, existem as imprecisões próprias do sistema devido a ruídos provenientes da dinâmica do processo, que não são eliminados completamente, mesmo quando os sinais capturados na saída do sistema utilizados para estimação paramétrica sejam tratados adequadamente; além dessas imprecisões tem-se também, para o nosso caso, os erros numéricos provenientes do estimador paramétrico.

Assim todas essas incertezas recaem sobre o sistema FDI e a utilização do sistema *fuzzy* tradicional, chamado por Zadeh a partir de 1975, de sistema *fuzzy* do tipo-1, não são apropriados para modelar diretamente tais incertezas porque suas funções de pertinências são exatas, ou seja, o valor retornado por uma função de pertinência de um conjunto *fuzzy* do tipo-1 é um número real. Essa característica foi motivo de críticas desde o início dos conjuntos *fuzzy*, pelo fato de que funções de pertinência de um conjunto *fuzzy* tipo-1 não apresentarem incertezas associada a eles, algo que parece contradizer a palavra “*fuzzy*”, uma vez que a palavra tem conotação de incerteza. Sendo assim, para resolver a questão das incertezas sobre os valores de entrada dos conjuntos *fuzzy*, em Zadeh (1975), foi proposto um tipo mais sofisticado de conjuntos *fuzzy*, o qual se chamou de sistemas *fuzzy* do tipo-2.

No sistema *fuzzy* deste trabalho, destinado à identificação de faltas elétricas, o conjunto *fuzzy* tipo-2 incorpora essas incertezas no algoritmo de identificação, porém em uma situação em que as incertezas são desconsideradas, o conjunto *fuzzy* tipo-2 se reduz ao conjunto *fuzzy* tipo-1. Isto é facilmente obtido anulando a incerteza no algoritmo de programação como veremos neste Capítulo.

Neste Capítulo se fará a apresentação de conjuntos *fuzzy* tipo-2, mostrando suas definições e as principais diferenças com relação ao conjunto *fuzzy* tipo-1, também será apresentado um sistema genérico de inferência *fuzzy* do tipo-2, e cada uma das partes desse sistema, o fuzzificador, a base de regras, a máquina de inferência, o processo de redução de tipo (reductor de tipo), e o defuzzificador serão detalhados.

3.2 Definições do SIF tipo-2

Introduzido por Zadeh (1975) como uma extensão do conceito de conjunto *fuzzy* do tipo-1, o conjunto *fuzzy* do tipo-2 é caracterizado pela sua função de pertinência. Como se sabe funções de pertinência de conjuntos *fuzzy* do tipo-1 são bidimensionais ao passo que funções de pertinência de conjuntos *fuzzy* do tipo-2 são tridimensionais. É esta terceira dimensão dos conjuntos *fuzzy* tipo-2 que permite um grau adicional de liberdade que torna possível modelar essas incertezas diretamente, sendo que nessa terceira dimensão o grau de pertinência para cada elemento deste conjunto é um número *fuzzy* no intervalo $[0,1]$; além desse grau de liberdade adicional ainda tem-se a incerteza no conjunto *fuzzy* primário, limitado pelas funções de pertinências superior (*upper*) e inferior (*lower*), assim para cada intervalo compreendido entre funções de pertinência superior e inferior, tem-se um “peso” associado, que representa a terceira dimensão do SIF do tipo-2.

Na Figura 3.1, é ilustrado uma função de pertinência do tipo-1 em duas condições, a condição “a)” que representa um caso clássico do tipo-1, em que a função de pertinência retorna um valor exato na saída, e o caso “b)” em que o valor de $x = x'$, não retorna um único valor de u' na função de pertinência, mais sim valores na vertical u' que interceptam a região de incerteza. Estes valores não precisam ser ponderados da mesma forma, e sendo assim, podemos aplicar uma distribuição para todos estes pontos.

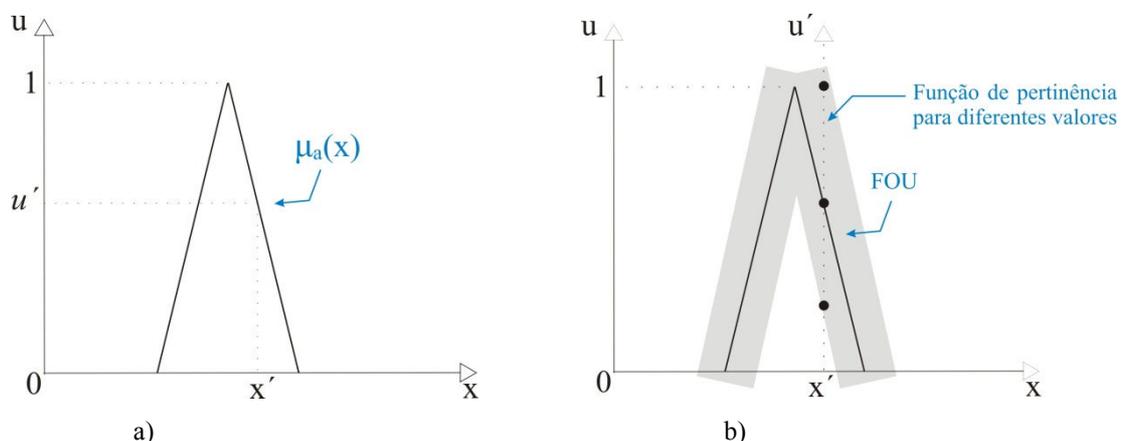


Figura 3. 1: Função de pertinência *fuzzy* tipo-1 e *fuzzy* tipo-1 manchada.

Aplicando a distribuição para todos os pontos $x \in X$, obtém-se a função de pertinência tridimensional, característica do conjunto *fuzzy* tipo-2. Um conjunto *fuzzy* tipo-2 denotado por \tilde{A} , é caracterizado por uma função de pertinência do tipo-2 $\mu_{\tilde{A}}(x, u)$, onde $x \in X$ e $u \in J_x \subseteq [0, 1]$, onde J_x é a função de pertinência primária e é definida como o domínio da função de pertinência secundária. Então o conjunto *fuzzy* tipo-2 é:

$$\tilde{A} = \{(x, u), \mu_{\tilde{A}}(x, u) \mid \forall x \in X, \forall u \in J_x \subseteq [0, 1]\} \quad (3.1)$$

também representado como a união de todos os x e u admissíveis como a seguir

$$\tilde{A} = \int_{x \in X} \int_{u \in J_x} \mu_{\tilde{A}}(x, u) / (x, u) \quad (3.2)$$

onde a função de pertinência primária é $J_x \subseteq [0, 1]$ e a função de pertinência do tipo-2 assume valor entre $0 \leq \mu_{\tilde{A}}(x, u) \leq 1$, que são os “pesos”, ou as incertezas distribuídas sobre a função de pertinência primária J_x .

Dada as definições acima, e considerando-se que para X e U , discretos, onde $X = \{1, 2, 3, 4, 5\}$ e $U = \{0, 0.2, 0.4, 0.6, 0.8\}$, e sabendo-se que, para cada valor de $x = x'$, o plano 2-D formado pelos eixos u e $\mu_{\tilde{A}}(x', u)$ é chamado de corte vertical da função $\mu_{\tilde{A}}(x, u)$, então denomina-se função de pertinência secundária ao corte vertical $\mu_{\tilde{A}}(x = x', u)$ para $x \in X$ e $\forall u \in J_x \subseteq [0, 1]$, exemplificada na Figura 3.2, e definida como:

$$\mu_{\tilde{A}}(x' = x, u) \equiv \mu_{\tilde{A}}(x') = \int_{u \in J_x} f_x(u) / u \quad J_x \subseteq [0, 1] \quad (3.3)$$

onde $0 \leq f_x(u) \leq 1$.

Pelas definições apresentadas até então, se percebe que as funções de pertinência secundárias assim como as funções de pertinência primárias, são conjuntos *fuzzy* do tipo-1 por serem bidimensionais. As funções de pertinência secundárias também são conhecidas como conjunto secundário; a união de todos os conjuntos secundários no universo X forma o conjunto *fuzzy* do tipo-2 (Figura 3.2). Percebe-se na Figura 3.2 que a função de pertinência do tipo-2 apresenta cinco cortes verticais com os valores de alguns dos conjuntos secundários para cada x do universo X , sendo colocados a seguir como exemplo:

- Para $x=2$, a função de pertinência secundária é:

$$\mu_{\tilde{A}}(2) = 0,1/0 + 0,9/0,2 + 0,3/0,4 + 0,2/0,6 + 0,1/0,8$$

- Para $x=4$, a função de pertinência secundária é:

$$\mu_{\tilde{A}}(4) = 0,9/0 + 0,6/0,2 + 0,35/0,4 + 0,2/0,6 + 0,3/0,8$$

- Para $x=5$, a função de pertinência secundária é:

$$\mu_{\tilde{A}}(5) = 0,2/0 + 0,7/0,2 + 0,3/0,4 + 0,5/0,6 + 0,15/0,8$$

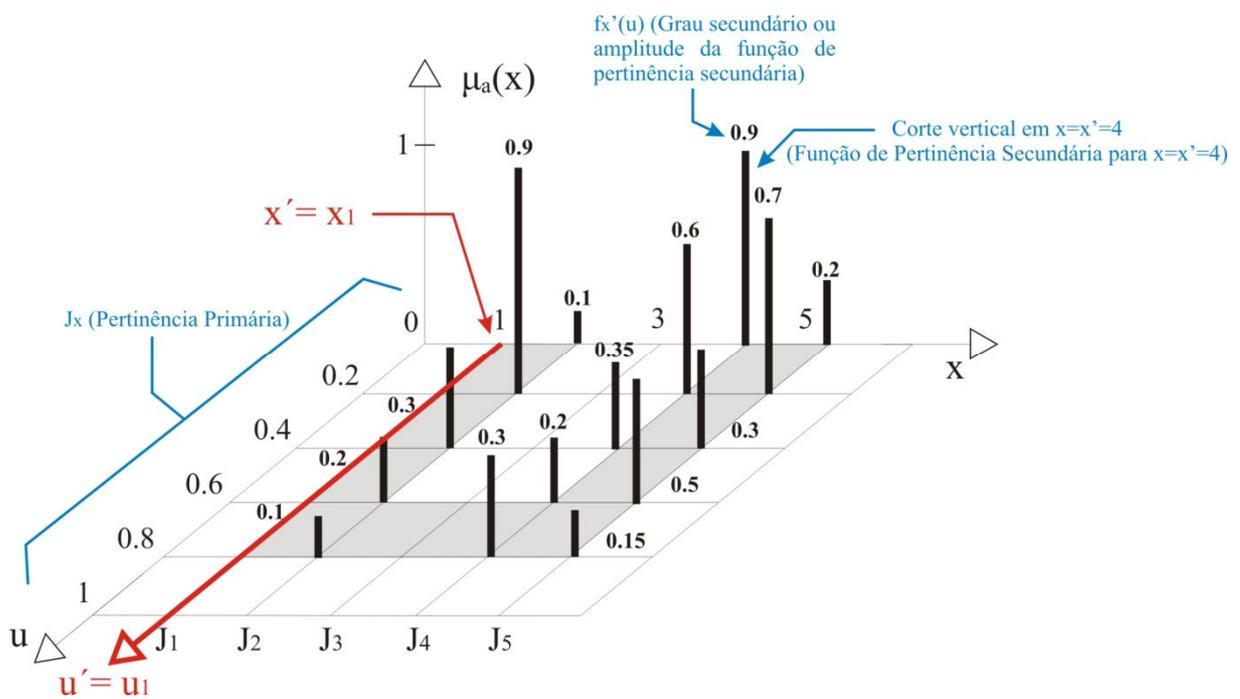


Figura 3. 2: Conjunto *fuzzy* tipo-2 representado tridimensionalmente.
Fonte: Adaptado (MENDEL & JOHN, 2002).

Assim, de posse das definições apresentadas sobre conjuntos secundários, um conjunto *fuzzy* do tipo-2 é dado pela união de todos os conjuntos secundários no universo X , assim de um modo geral um conjunto *fuzzy* tipo-2, \tilde{A} , é dado por:

$$\tilde{A} = \{(x, \mu_{\tilde{A}}(x)) | \forall x \in X\} \tag{3.4}$$

ou para sistemas contínuos que representam a união dos conjuntos secundários

$$\tilde{A} = \int_{x \in X} \mu_{\tilde{A}}(x) / x = \int_{x \in X} \left[\int_{u \in J_x} f_x(u) / u \right] / x \quad J_x \subseteq [0,1] \tag{3.5}$$

onde $f_x(u)$ é o grau secundário. Em outras palavras, é a amplitude da função de pertinência secundária. Já para a Equação (3.1) o grau secundário é $\mu_{\tilde{A}}(x', u')$, $x' \in X$, $u' \in J_x$.

Dada à definição de conjuntos *fuzzy* secundários, definimos o domínio desse conjunto, representado matematicamente pela Equação (3.5), como J_x , denominado de *pertinência primária* de x , onde para todo $x \in X$ tem-se $J_x \subseteq [0,1]$. Para o exemplo apresentado, o domínio do conjunto *fuzzy* secundário é dada por:

$$J_1 = J_2 = J_4 = J_5 = \{0, 0.2, 0.4, 0.6, 0.8\} \text{ e } J_3 = \{0.6, 0.8\}$$

3.3 Definições para o universo discreto

Seja X e J_x discretos, então o conjunto *fuzzy* tipo-2 pode ser reescrito como a Equação (3.6):

$$\tilde{A} = \sum_{x \in X} \left[\sum_{u \in J_x} f_x(u) / u \right] / x \quad (3.6)$$

Discretizado o universo X em N valores obtém-se a Equação (3.7):

$$\tilde{A} = \sum_{i=1}^N \left[\sum_{u \in J_{x_i}} f_{x_i}(u) / u \right] / x_i \quad (3.7)$$

Para cada um desses valores x_i o universo U foi discretizado em M_i valores, e a representação estendida da Equação (3.7) é:

$$\tilde{A} = \left[\sum_{k=1}^{M_1} f_{x_1}(u_{1k}) / u_{1k} \right] / x_1 + \dots + \left[\sum_{k=1}^{M_N} f_{x_N}(u_{Nk}) / u_{Nk} \right] / x_N \quad (3.8)$$

3.4 Mancha de incerteza e Conjunto *fuzzy* intervalar do tipo-2

Conjuntos *fuzzy* do tipo-2, \tilde{A} , apresentam como característica própria, incertezas nas suas funções de pertinência primária, essa incerteza consiste em uma região limitada chamada de *footprint of uncertainty*, ou macha de incerteza, ou simplesmente FOU. A FOU é a união de todas as pertinências primárias, como representado matematicamente na Equação (3.9).

$$FOU(\tilde{A}) = \bigcup_{x \in X} J_x \quad (3.9)$$

A definição de FOU permite que seja possível representar o conjunto *fuzzy* do tipo-2 graficamente em apenas duas dimensões, assim teremos uma representação bidimensional e não mais tridimensional como era o previsto ao tratar-se de conjuntos *fuzzy* do tipo-2, a macha de incerteza, ou FOU, faz o papel dessa terceira dimensão, indicando que existe uma distribuição disposta em cima dessa macha de incerteza, e é essa distribuição que é a terceira dimensão. Na Figura 3.2 a região sombreada é um exemplo de FOU.

No presente trabalho, iremos considerar um caso particular de conjuntos *fuzzy* do tipo-2, caso em que a função de pertinência secundária é um conjunto intervalar, ou seja, o grau de pertinência secundário é 0 ou 1, e assim tem-se o que chamamos de conjunto *fuzzy* intervalar do tipo-2. Para conjuntos *fuzzy* intervalares tipo-2 a terceira dimensão, que representa o conjunto *fuzzy* secundário, assume valores fixos, a aplicação dessa metodologia em sistema de detecção de faltas, consistiu em fixar os valores do conjunto *fuzzy* secundário, ou seja, os seus “pesos”, como valores unitários. Assim, o grau secundário $f_x(u)$, Equação (3.5), é igual a um ($f_x(u)=1$). Embora isso possa nos indicar uma perda nas características do conjunto *fuzzy* tipo-2, não é exatamente o que acontece, pois as incertezas, ou imprecisões, ainda continuam presente nas funções de pertinência do conjunto *fuzzy* primário, ou seja, nas FOU's, porém o que temos agora são incertezas uniformes nas funções de pertinência primárias, o que nos permite uma considerável simplificação na programação.

3.5 Incertezas nas funções de pertinência de conjuntos *fuzzy* do tipo-2

Conjuntos *fuzzy* de um modo geral podem ter suas funções de pertinência nos formatos trapezoidal, gaussiana e triangular, nessa secção será aplicado o conceito de FOU de conjuntos *fuzzy* do tipo-2 em funções pertinências, com o objetivo de visualizar o comportamento da mancha de incerteza para as condições definidas no trabalho.

3.5.1 FOU no valor modal da função de pertinência primária gaussiana

A função de pertinência primária gaussiana é representada matematicamente como:

$$\mu_A(x) = \exp\left[-\frac{1}{2}\left(\frac{x-m}{\sigma}\right)^2\right] \quad (3.10)$$

Incerteza no valor modal significa uma incerteza na média, m , que assume valores no intervalo $[m_1, m_2]$ definido pelo programador com base nos dados de entrada. No caso específico desse trabalho, esses valores são definidos com base no comportamento dos parâmetros do sistema. Nesse caso o desvio padrão σ é um valor fixo, ver Figura 3.3.

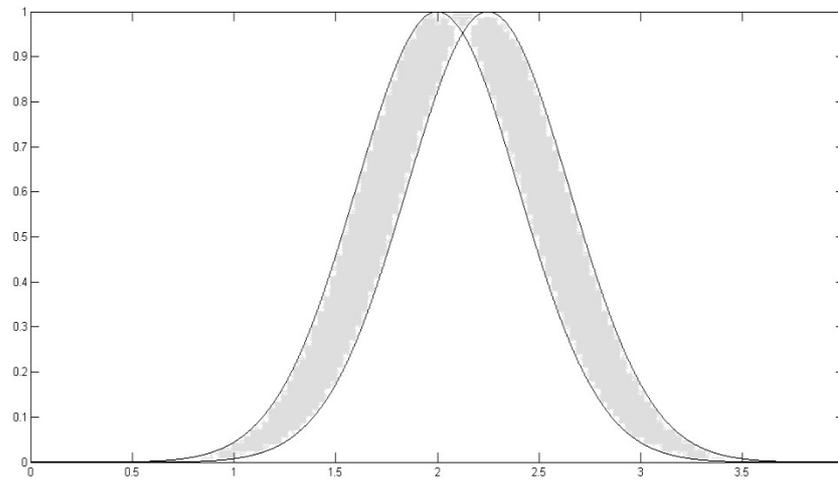


Figura 3. 3: FOU em função de pertinência primária com incerteza no valor modal

3.5.2 FOU na dispersão da função de pertinência primária gaussiana

Uma incerteza na dispersão sugere que σ , na Equação 3.10, não assuma um valor fixo, mas sim valores no intervalo $[\sigma_1, \sigma_2]$, enquanto que a média m permanece fixa, esse caso, assim como o anterior, resulta em diferentes curvas de pertinência como ilustrado na Figura 3.4. Outra consideração é quanto a FOU, que sendo uniforme, caracteriza essa função de pertinência primária, como pertencente a conjuntos intervalares para funções de pertinência secundárias.

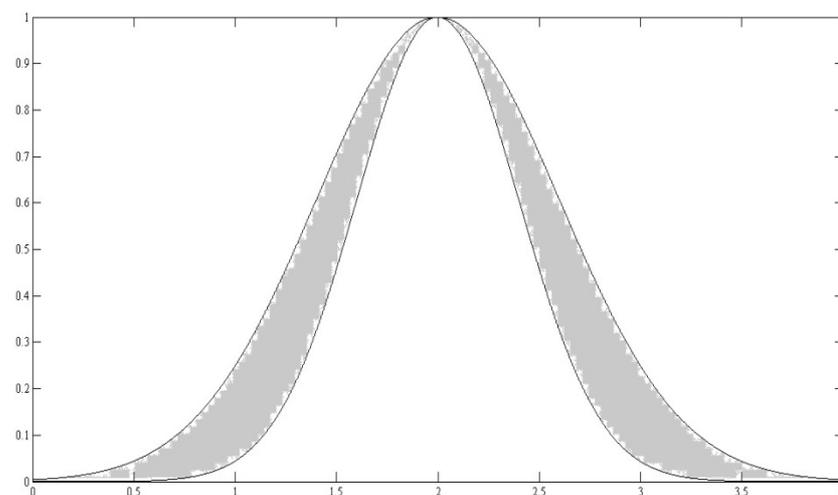


Figura 3. 4: FOU em função de pertinência primária com incerteza na dispersão

Para ambos os casos temos funções de pertinência superior, mais externa, também denominada de *upper*, e a função de pertinência inferior, mais interna, conhecida também como *lower*, ambas são função de pertinência *fuzzy* do tipo-1, que limitam a FOU de um conjunto *fuzzy* \tilde{A} do tipo-2.

3.5.3 FOU na base da função de pertinência primária triangular

Assim como em funções de pertinência primária gaussiana, as funções de pertinência primária triangulares podem apresentar incertezas, nesse caso na base do triângulo, na altura ou em ambos. A Figura 3.5 ilustra esses casos.

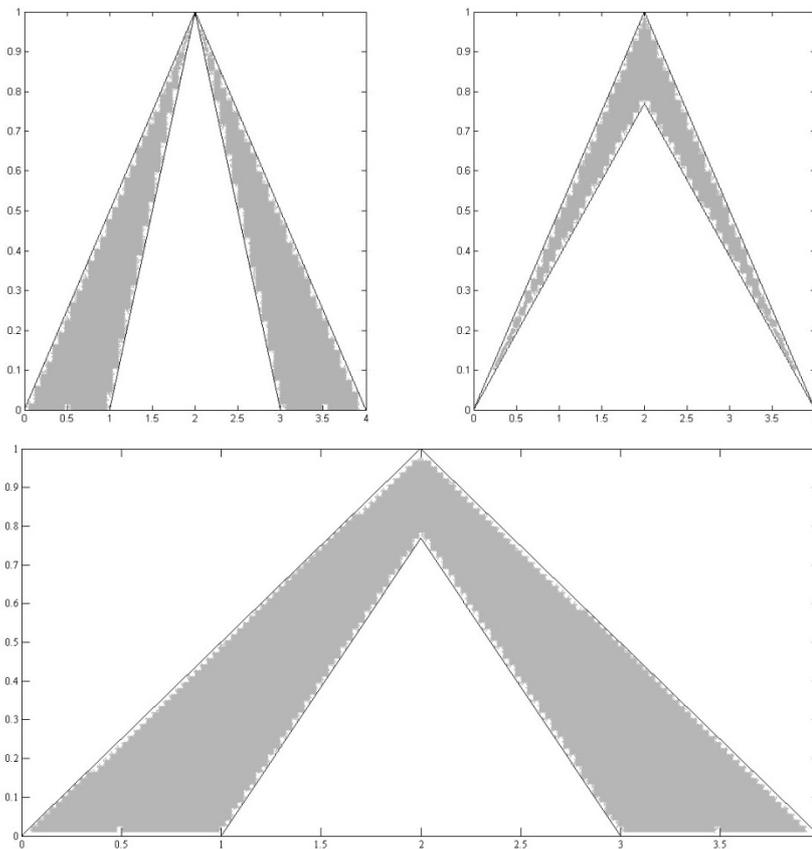


Figura 3. 5: FOU em funções de pertinência primárias triangulares

E o procedimento para o caso das funções de pertinência gaussianas pode ser repetido em funções de pertinência triangulares, assim, pode-se aplicar incertezas na altura e/ou no valor de suporte da função de pertinência, Figura 3.5. Imprecisões aplicadas na base e/ou altura de funções de pertinência triangulares, geram uma região de incerteza limitada pelas funções de pertinência triangulares; o triângulo maior, externo, é chamado de função de pertinência superior (*upper*), e o triângulo menor, interno, é chamado de função de pertinência

inferior (*lower*), como já comentado, correspondem à pertinência primária de conjuntos *fuzzy* do tipo-2, e ambos limitam a macha de incerteza, ou FOU, de conjuntos *fuzzy* do tipo-2. Para conjuntos *fuzzy* intervalares do tipo-2, o conjunto *fuzzy* secundário assume valores unitários uniformemente distribuídos sobre a FOU.

A função de pertinência superior representa o limite superior da $FOU(\tilde{A})$, definida como $\overline{\mu}_A(x)$, $\forall x \in X$, e é dada por:

$$\overline{\mu}_A(x) \equiv \overline{FOU(\tilde{A})} = \bigcup_{x \in X} \overline{J}_x \quad (3.11)$$

Em contrapartida a função de pertinência inferior representa o limite inferior de $FOU(\tilde{A})$, definida por $\underline{\mu}_A(x)$, $\forall x \in X$, e é dada por:

$$\underline{\mu}_A(x) \equiv \underline{FOU(\tilde{A})} = \bigcup_{x \in X} \underline{J}_x \quad (3.12)$$

Sabendo-se que J_x é a pertinência primária de x , então \overline{J}_x e \underline{J}_x representam o limite superior e inferior respectivamente do conjunto *fuzzy* primário do tipo-2, e a união de todas as pertinências primárias nesse intervalo é o que até então nós chamamos de *footprint of uncertainty* ou simplesmente, FOU, como definido na Equação (3.9).

De posse das definições acima, podemos representar um conjunto *fuzzy* do tipo-2 por meio das funções de pertinência superior e inferior, como em (3.13).

$$\tilde{A} = \mu_{\tilde{A}}(x, u) = \int_{x \in X} \mu_{\tilde{A}}(x)/x = \int_{x \in X} \left[\int_{u \in J_x} f_x(u)/u \right] / x \quad (3.13)$$

onde a função de pertinência primária J_x na integral pode ser substituída pelas funções de pertinência superior e inferior, $[\underline{\mu}_{\tilde{A}}(x), \overline{\mu}_{\tilde{A}}(x)]$ e 3.12 se resume como em 3.14

$$\mu_{\tilde{A}}(x) = \int_{u \in [\underline{\mu}_{\tilde{A}}(x), \overline{\mu}_{\tilde{A}}(x)]} f_u(u)/u \quad (3.14)$$

Com base na Equação (3.14), e considerando conjuntos *fuzzy* intervalares do tipo-2, onde o conjunto *fuzzy* secundário, a FOU, apresenta distribuição uniforme com grau secundário igual a 1, $f_x(u) = 1$, a Equação (3.13), pode ser reescrita como:

$$\tilde{A} = \mu_{\tilde{A}}(x, u) = \int_{x \in X} \left[\int_{u \in J_x} 1/u \right] / u = \int_{x \in X} \left[\int_{u \in [\underline{\mu}_{\tilde{A}}(x), \overline{\mu}_{\tilde{A}}(x)]} 1/u \right] / x \quad (3.15)$$

3.6 Estrutura de um sistema de inferência *fuzzy* do tipo-2 Mamdani

De um modo geral, em sistemas de inferência *fuzzy* consideram-se entradas não-*fuzzy*, ou precisas, geralmente obtidas por medições, como é o caso da maioria das aplicações práticas, por esse motivo torna-se necessário fazer um mapeamento desses dados precisos para os conjuntos *fuzzy* de entrada relevantes, por isso a necessidade do *fuzzificador*, que irá converter entradas numéricas precisas, em um conjunto *fuzzy*, processo que conhecemos como *fuzzificação*, além disso, nessa etapa ocorrerá a ativação das regras relevantes a cada situação.

A base de regras juntamente com a máquina de inferência, pode ser considerado o núcleo do sistema baseado em regras *fuzzy*. Ele é composto por um conjunto de proposições *fuzzy* na forma se - então, e cada uma dessas proposições pode ser descrita linguisticamente de acordo com o conhecimento de um especialista. A base de regras descreve relações entre as variáveis linguísticas, para serem utilizadas na máquina de inferência *fuzzy*, que descrevemos no próximo item.

A máquina de inferência é a parte da estrutura do sistema *fuzzy* responsável por traduzir matematicamente cada uma das proposições *fuzzy*, isso dar-se por meio de técnicas de raciocínio aproximado, uma característica de sistemas *fuzzy*, visto que a lógica *fuzzy* foi estabelecida para lidar justamente com proposições *fuzzy* subjacentes a esse raciocínio aproximado. E é, a partir de cada entrada *fuzzy*, e da relação definida pela base de regras, onde os operadores matemáticos serão selecionados para definir a relação *fuzzy* que modela a base de regras, que se obtém uma saída *fuzzy*. Na literatura existem diferentes tipos de inferência *fuzzy*, entre esses os principais estão o modelo de inferência *fuzzy* Mamdani, e o modelo de inferência *fuzzy* paramétrico ou simplesmente TSK (Takagi - Sugeno - Kang).

Concluído o processo de inferência, o conjunto *fuzzy* do tipo-2 de saída do bloco de inferência deve ser processado pelo bloco denominado processador de saída. A primeira operação é o processo de Redução de Tipo, o qual transforma o conjunto de saída do bloco de inferência em um conjunto *fuzzy* do tipo-1. Este conjunto é chamado conjunto tipo-reduzido (KARNIK & MENDEL, 1998).

No estágio da defuzzificação, é efetuada uma interpretação da informação da saída do redutor de tipo, isso porque, com funções de pertinência sendo funções *fuzzy* do tipo-2, na

saída do redutor de tipo tem-se funções *fuzzy* tipo-1, e na grande maioria das aplicações práticas se deseja uma saída precisa, ou seja, um número; para esse processo geralmente emprega-se o centro de gravidade, ou a média ponderada dos máximos. Na média dos máximos a saída precisa é obtida tomando-se a média entre os dois elementos extremos no universo que correspondem aos maiores valores da função de pertinência do consequente. Já no centro de gravidade, a saída é o valor no universo que divide a área sob a curva da função de pertinência em duas partes iguais.

Como se observa nas explicações acima, em nenhum momento preocupou-se diferenciar *fuzzy* do tipo-1 e *fuzzy* do tipo-2, isso porque a diferença entre sistemas *fuzzy* do tipo-1 e do tipo-2 está associada à natureza das funções de pertinência e não às regras. Portanto, as regras permanecem as mesmas para os sistemas *fuzzy* do tipo-1 ou tipo-2 (KARNIK *et al*, 1999).

A Figura 3.6 mostra a estrutura de um sistema de inferência *fuzzy* do tipo-2 (MENDEL, 2000). Como já mencionamos os SIF do tipo-2 apresentam fuzzificador, base de regras, máquina de inferência, redutor de tipo e defuzzificador. A seguir uma abordagem mais sistemática será dada para alguns dos elementos desse processo.

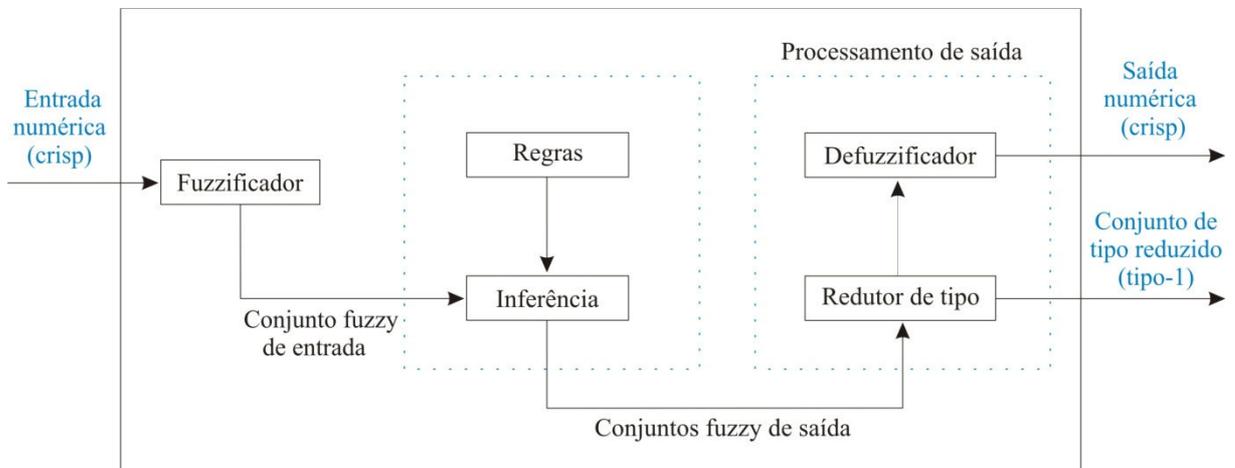


Figura 3. 6: Estrutura de um sistema *fuzzy* do tipo-2.
Fonte: Adaptado (KARNIK *et al*, 1999).

a) Base de Regras

Em um sistema genérico do tipo-2 com p entradas $x_1 \in X_1, \dots, x_p \in X_p$ e uma saída $y \in Y$, suponha M regras, então, e l -ésima regra é dada por:

$$R^l: \text{SE } x_1 \text{ é } F_1^l \text{ e } \dots \text{ e } x_p \text{ é } F_p^l, \text{ ENTÃO } y \text{ é } \tilde{G}^l \quad (3.16)$$

onde $l = 1, \dots, M$, sendo X_i o domínio da variável x_i e \tilde{F}_i é o valor linguístico.

Nesta regra do tipo-2, todos os conjuntos envolvidos são do tipo-2 (PIMENTA, 2009).

b) Bloco de inferência

O bloco máquina de inferência combina regras e mapeia conjuntos *fuzzy* do tipo-2 de entrada em conjuntos *fuzzy* tipo-2 de saída. E para isso calcula uniões e interseções de conjuntos *fuzzy* do tipo-2.

Em sistemas de inferência *fuzzy* do tipo-2, cada uma das regras são interpretadas como uma relação *fuzzy* do tipo-2, ou seja:

$$R^l : \tilde{F}_1^l \times \dots \times \tilde{F}_p^l \rightarrow \tilde{G}^l = \tilde{A}^l \rightarrow \tilde{G}^l \quad l = 1, \dots, M \quad (3.17)$$

onde a função de pertinência l -ésima regra R^l é dada por:

$$\mu_{R^l}(x, y) = \mu_{R^l}(x_1, \dots, x_p, y) = \mu_{\tilde{A}^l \rightarrow \tilde{G}^l}(x, y) \quad (3.18)$$

por (MENDEL, 2000), tem-se:

$$\mu_{R^l}(x, y) = \mu_{\tilde{F}_1^l}(x_1) \prod \dots \prod \mu_{\tilde{F}_p^l}(x_p) \prod \mu_{\tilde{G}^l}(y) = \left[\prod_{i=1}^p \mu_{\tilde{F}_i^l}(x_i) \right] \prod \mu_{\tilde{G}^l}(y) \quad (3.19)$$

onde:

\prod = operador *meet* (usando o mínimo ou o produto como t-norma)

p = número de variáveis de entrada

De modo geral a entrada p -dimensional para a regra R^l é dada por um conjunto *fuzzy* do tipo-2 (representado por \tilde{A}_x), cuja função de pertinência é:

$$\mu_{\tilde{A}_x}(x) = \mu_{\tilde{X}_1}(x_1) \prod \mu_{\tilde{X}_2}(x_2) \prod \dots \prod \mu_{\tilde{X}_p}(x_p) = \prod_{i=1}^p \mu_{\tilde{X}_i}(x_i) \quad (3.20)$$

onde $\tilde{X}_i (i = 1, \dots, p)$ são rótulos (*labels*) dos conjuntos *fuzzy* do tipo-2 que descrevem as entradas.

Cada regra R^l determina um conjunto *fuzzy* do tipo-2 da forma $\tilde{B}^l = \tilde{A}_x \circ R^l$. Para um SIF do tipo-2 tem-se:

$$\mu_{\tilde{B}^l}(y) = \mu_{\tilde{A}_x \circ R^l}(y) = \coprod_{x \in X} [\mu_{\tilde{A}_x}(x) \prod \mu_{R^l}(x, y)] \quad y \in Y \quad l = 1, \dots, M \quad (3.21)$$

onde :

\coprod = operador *join* (união de conjuntos *fuzzy* do tipo-2)

\prod = operador *meet* (usando o mínimo ou o produto como *t-norm*)

substituindo as Equações (3.19) e (3.20) em (3.21), obtêm-se:

$$\begin{aligned} \mu_{\tilde{B}^l}(y) &= \coprod_{x \in X} [\mu_{\tilde{A}_x}(x) \prod \mu_{R^l}(x, y)] = \coprod_{x \in X} \left\{ \prod_{i=1}^p \mu_{\tilde{X}_i}(x_i) \prod \left[\prod_{i=1}^p \mu_{\tilde{F}_i^l}(x_i) \prod \mu_{\tilde{G}^l}(y) \right] \right\} \\ \mu_{\tilde{B}^l}(y) &= \coprod_{x \in X} \left\{ \prod_{i=1}^p \mu_{\tilde{X}_i}(x_i) \prod \mu_{\tilde{F}_i^l}(x_i) \prod \mu_{\tilde{G}^l}(y) \right\} \end{aligned} \quad (3.22)$$

Da propriedade de comutatividade do operador *meet* (usando o mínimo ou o produto para *t-norm*), tem-se:

$$\mu_{\tilde{B}^l}(y) = \mu_{\tilde{G}^l}(y) \prod \left\{ \prod_{x_1 \in X_1} \mu_{\tilde{X}_1}(x_1) \prod \mu_{\tilde{F}_1^l}(x_1) \prod \dots \prod \prod_{x_p \in X_p} \mu_{\tilde{X}_p}(x_p) \prod \mu_{\tilde{F}_p^l}(x_p) \right\}$$

$y \in Y$

(3.23)

A Equação 3.23 representa a relação entrada-saída entre os conjuntos *fuzzy* do tipo-2 que excitam uma regra de inferência e o conjunto *fuzzy* do tipo-2 na saída do bloco de inferência.

c) Fuzzificador

Em sistemas de inferência *fuzzy* do tipo-2 Mamdani com entradas numéricas, o fuzzificador utilizado é o singleton do tipo-2. O fuzzificador mapeia o ponto crisp $x = (x_1, \dots, x_p)^T \in X_1 \times X_2 \times \dots \times X_p \equiv X$ dentro de um conjunto *fuzzy* do tipo-2 \tilde{A}_x X.

Para este caso, \tilde{A}_x é um conjunto *fuzzy* do tipo-2 singleton, onde, $\mu_{\tilde{A}_x}(x) = 1/1$ para $x = x'$ e $\mu_{\tilde{A}_x}(x) = 1/0$ para $x \neq x'$. Como usamos funções de pertinência separáveis, então $\mu_{\tilde{X}_i}(x_i) = 1/1$ quando $x_i = x_i'$ e $\mu_{\tilde{X}_i}(x_i) = 1/0$ quando $x_i \neq x_i'$ para $i = 1, \dots, p$.

d) Redutor de Tipo

De modo genérico, o SIF do tipo-2 é uma versão “perturbada” de um SIF do tipo-1 devido às incertezas nas funções de pertinência. Então o conjunto tipo-reduzido em um SIF do tipo-2 é uma representação das incertezas nas saídas *crisp* devido a essas “perturbações” (KARNIK & MENDEL, 1998; MENDEL, 2000).

Desse modo, alguma medida de largura do conjunto tipo-reduzido pode ser usada para indicar a possível variação da saída *crisp* devido a essa “perturbação”. Nesse trabalho o redutor de tipo escolhido foi à média dos centros (centroide).

e) Defuzzificador

Essa é a última parte do processo de saída, nele os valores obtidos na saída do redutor de tipo, que são valores *fuzzy*, ou seja, imprecisos, são defuzzificados, e valores numéricos precisos, *crisp*, são obtidos. Nesse trabalho o defuzzificador utilizado é a média aritmética.

3.7 Sistemas de inferência *fuzzy* intervalares do tipo-2

Devido à complexidade dos sistemas de inferência *fuzzy* do tipo-2 já discutidos neste Capítulo, a proposta nesta seção é trabalhar com o caso particular de conjuntos *fuzzy* do tipo-2, os SIF intervalares do tipo-2. Nos SIF intervalares do tipo-2, as operações *meet* e *join* e o processo de redução de tipo ficam simplificados. Além do que, como os SIF intervalares do tipo-2 apresentam uma distribuição uniforme da sua função de pertinência secundária, a escolha da forma das funções de pertinência fica solucionada. Nesta seção serão apresentadas as mudanças no bloco de inferência, no redutor de tipo, e na defuzzificação com a utilização de SIF intervalares do tipo-2.

a) Bloco de inferência

O SIF intervalar do tipo-2 Mamdani com o *meet* calculado usando o mínimo ou o produto como t-norma, apresenta os seguintes resultados:

- Os resultados das operações de entrada e os antecedentes são um conjunto intervalar do tipo-1 contido no conjunto ativado $\prod_{i=1}^p \mu_{\tilde{F}_i}(x'_i) \equiv F^l(x')$, e dado por:

$$F^l(x') = [\underline{f}^l(x'), \overline{f}^l(x')] \equiv [\underline{f}^l, \overline{f}^l] \quad (3.24)$$

onde

$F^l(x')$, é o conjunto intervalar ativado, e, $\underline{f}^l(x')$, $\overline{f}^l(x')$, são respectivamente, o ponto limite esquerdo e direito do domínio do conjunto intervalar ativado, dados por:

$$\underline{f}^l(x') = \underline{\mu}_{\tilde{F}_1}(x_1) * \dots * \underline{\mu}_{\tilde{F}_p}(x_p) \quad (3.25)$$

$$\overline{f}^l(x') = \overline{\mu}_{\tilde{F}_1}(x_1) * \dots * \overline{\mu}_{\tilde{F}_p}(x_p) \quad (3.26)$$

e onde

$\underline{\mu}_{\tilde{F}_1}(x_1)$ e $\overline{\mu}_{\tilde{F}_1}(x_1)$ são o grau de pertinência de x_1 na função de pertinência inferior e superior do conjunto antecedente F_1 , respectivamente.

- O conjunto consequente de saída da l -ésima regra ativada da Equação (3.23), $\mu_{\tilde{B}^l}(y)$, é um conjunto *fuzzy* do tipo-1 dado por:

$$\mu_{\tilde{B}^l}(y) = \int_{b^l \in [\underline{f}^l * \underline{\mu}_{\tilde{G}^l}(y), \overline{f}^l * \overline{\mu}_{\tilde{G}^l}(y)]} 1/b^l \quad y \in Y \quad (3.27)$$

onde $\underline{\mu}_{\tilde{G}^l}(y)$ e $\overline{\mu}_{\tilde{G}^l}(y)$ são o grau de pertinência inferior e superior de $\mu_{\tilde{G}^l}(y)$

- Considerando que N regras de M regras do SIF do tipo-2 são ativadas, onde $N \leq M$, e supondo que o conjunto *fuzzy* de saída do tipo-1 é obtido combinando os conjuntos consequentes de saída que são ativados, como em:

$\mu_{\tilde{B}}(y) = \prod_{l=1}^N \mu_{\tilde{B}^l}(y)$, então a função de pertinência do conjunto consequente é:

$$\mu_{\tilde{B}}(y) = \int_{b \in [\underline{f}^1 * \underline{\mu}_{\tilde{G}^1}(y) \vee \dots \vee \underline{f}^N * \underline{\mu}_{\tilde{G}^N}(y)], [\overline{f}^1 * \overline{\mu}_{\tilde{G}^1}(y) \vee \dots \vee \overline{f}^N * \overline{\mu}_{\tilde{G}^N}(y)]} 1/b \quad y \in Y \quad (3.28)$$

onde, \vee é a *t-conorm* máximo.

b) Redutor de Tipo e Defuzzificador

O processo de redução de tipo para SIF intervalar do tipo-2 Mamdani com entradas numéricas, desenvolvido neste trabalho, é do tipo centroide, onde $Y_{\cos}(x)$ é dado por (KARNIK & MENDEL, 1998).

$$Y_{\cos}(x) = [y_l, y_r] = \int_{y^1 \in [y_l^1, y_r^1]} \cdots \int_{y^M \in [y_l^M, y_r^M]} \int_{f^1 \in [\underline{f}^1, \bar{f}^1]} \cdots \int_{f^M \in [\underline{f}^M, \bar{f}^M]} 1 / \frac{\sum_{i=1}^M f^i y^i}{\sum_{i=1}^M f^i} \quad (3.29)$$

com y_l e y_r dados por (3.30)

$$y_l = \frac{\sum_{i=1}^M f_l^i y_l^i}{\sum_{i=1}^M f_l^i}, \quad y_r = \frac{\sum_{i=1}^M f_r^i y_r^i}{\sum_{i=1}^M f_r^i} \quad (3.30)$$

onde

$Y_{\cos}(x)$ é o conjunto intervalar de pontos limites $[y_l, y_r]$, sendo y_l e y_r calculados por procedimentos iterativos.

$Y^i = [y_l^i, y_r^i]$ é o centroide do conjunto consequente intervalar do tipo-2, \tilde{G}^i , pré-calculados antes de calcular $Y_{\cos}(x)$.

M = Número de regras.

f_r^i, y_r^i = valores de f^i, y^i que estão associados a y_r , respectivamente.

f_l^i, y_l^i = valores de f^i, y^i que estão associados a y_l , respectivamente.

e onde $f^i \in F^i = [\underline{f}^i, \bar{f}^i]; y^i \in Y^i$.

E a saída defuzzificada do SIF intervalar do tipo-2 com entradas numéricas é descrita como a média dos intervalos de $Y_{\cos}(x)$, ou seja, a média aritmética de y_l e y_r .

3.8 Conclusão

Neste Capítulo discutiu-se o SIF do tipo-2, e o seu caso particular, os conjuntos *fuzzy* intervalares do tipo-2, que apresentam como principal característica a distribuição uniforme de sua função de pertinência secundária. Além disso, em SIF intervalares do tipo-2 as operações *meet* e *join* e o processo de redução de tipo por serem simplificados, acabam reduzindo esforço no desenvolvimento do algoritmo para identificação da falta, o próximo passo é utilizarmos algoritmos genéticos para a otimização da FOU e do redutor de tipo.

4 ALGORITMOS GENÉTICOS

Algoritmos genéticos (AG's) são métodos de busca inspirados nos mecanismos de seleção natural (Teoria da Evolução) e da genética. Na estrutura do algoritmo genético é programado um mecanismo para seleção dos melhores indivíduos, ou dos mais aptos ao objetivo em questão, com uma estrutura para combinar e “reproduzir” aleatoriamente estes indivíduos, criando uma nova população. Desse modo a cada geração um conjunto de novos indivíduos é criado utilizando-se informações contidas nas gerações passadas (CAMPOS & SAITO, 2004).

Na busca de encontrar soluções que melhorem o desempenho de um determinado processo, os AG's utilizam métodos heurísticos e probabilísticos para obter novos elementos, porém explorando inteligentemente as informações disponíveis para obter essas novas soluções, por isso não podem ser considerado uma simples busca aleatória. AG's abordam uma série ampla de problemas, em especial problemas de otimização, é uma ferramenta genérica e facilmente adaptável em diversas áreas.

4.1 Introdução aos algoritmos de otimização

Algoritmos genéticos fazem parte de uma área particular da computação evolutiva que tem como base as estratégias evolutivas formuladas por Darwin em sua teoria da evolução natural.

De acordo com a teoria da evolução de Darwin, o princípio da seleção privilegia os indivíduos mais aptos com maior longevidade e, conseqüentemente, com maior probabilidade de reprodução. Indivíduo com maior quantidade de descendentes tem mais chance de perpetuarem seus códigos genéticos nas próximas gerações. Tais códigos genéticos constituem a identidade de cada indivíduo, e estão representados nos cromossomos.

Esses algoritmos computacionais são projetados para buscarem a melhor solução para um determinado problema imitando o processo de seleção natural, por meio da evolução de populações de soluções codificadas através de cromossomos artificiais. Em AG's o cromossomo é uma estrutura de dados que representa uma das possíveis soluções do espaço de busca do problema. Cromossomos são então submetidos a um processo evolucionário que envolve avaliação, seleção, recombinação sexual (*crossover*) e mutação. Após vários ciclos de evolução a população deverá conter indivíduos mais aptos (PACHECO, 1999).

A analogia entre os sistemas natural e os algoritmos genéticos é dada na tabela abaixo:

Tabela 4. 1: Sistema natural x Algoritmos genéticos

Natureza	Algoritmos Genéticos
Cromossoma	Palavra binária, vetor, etc.
Gene	Característica do Problema
Alelo	Valor da característica
Loco	Posição na palavra, vetor.
Genótipo	Estrutura
Fenótipo	Estrutura submetida ao problema
Indivíduo	Solução
Geração	Ciclo

Fonte: (PACHECO, 1999).

4.2 Algoritmos genéticos: princípios e aplicações

Antes de iniciarmos o processo de avaliação dos algoritmos genéticos algumas considerações devem ser feitas, como por exemplo, a escolha do problema a ser otimizado e as possíveis representações das soluções de um problema, como veremos a seguir.

4.2.1 Problema a ser otimizado

Algoritmos genéticos são aplicados em problemas complexos de otimização, quando um problema apresenta diversos parâmetros ou características que precisam ser combinadas para se obter a melhor solução. Utiliza-se algoritmos genéticos também para problemas com muitas restrições ou condições que não podem ser representadas matematicamente, e problemas com grande espaço de busca. O objetivo da otimização no caso de um sistema de diagnóstico de faltas, é melhorar o desempenho do sistema em direção a um ponto ou região ótima, em outras palavras, significa convergir uma determinada função para um ponto desejado.

4.2.2 Representação das soluções de problema

Uma possível solução para um determinado problema é chamada de indivíduo. A escolha da forma de representação do indivíduo depende do tipo de problema, e do que essencialmente se deseja manipular geneticamente. A definição da representação das soluções do espaço de busca define a estrutura do cromossomo a ser manipulado pelo algoritmo; é uma

das partes mais importantes durante o projeto de um algoritmo genético, visto que sua representação é um dos principais fatores responsáveis pelo seu desempenho. Os principais tipos de representação são:

Tabela 4. 2: Tipos de representação dos cromossomos

Representação	Problemas
Binária	Números, Inteiros
Números Reais	Numéricos
Permutação de Símbolos	Baseados em Ordem
Símbolos repetidos	Grupamento

1	0	1	0	0	1	1	0
---	---	---	---	---	---	---	---

(a)

1.1	0.4	0.4	1.8	5.4	2.2	4.2	0.5
-----	-----	-----	-----	-----	-----	-----	-----

(b)

F	J	A	B	U	R	T	C
---	---	---	---	---	---	---	---

(c)

Figura 4. 1: (a) Cromossomo binário, (b) Cromossomo real, e (c) Cromossomo de símbolos.

Na biologia os cromossomos são formados por genes, de maneira análoga, cada posição do vetor (cromossomo), ou seja, cada um dos parâmetros que formam o cromossomo, Figura 4.1, chamamos de genótipo.

4.2.3 Decodificação do cromossomo

Em Pacheco (1999) afirma-se que a decodificação do cromossomo consiste na construção da solução real do problema a partir do mesmo. A decodificação do cromossomo permite que seja construída a solução que posteriormente será avaliada pelo problema, e o resultado desse processo de decodificação do genoma do indivíduo é o que chamamos de fenótipo.

4.3 Funcionamento dos algoritmos genéticos

Basicamente, o que o um algoritmo genético faz é criar uma população de possíveis respostas para o problema a ser tratado (inicialização) para depois submetê-la ao processo de

evolução. Em Holland (1992), foi decomposto o funcionamento dos AG's nas etapas de inicialização, avaliação, seleção, cruzamento, mutação, atualização e finalização, ver Figura 4.2.

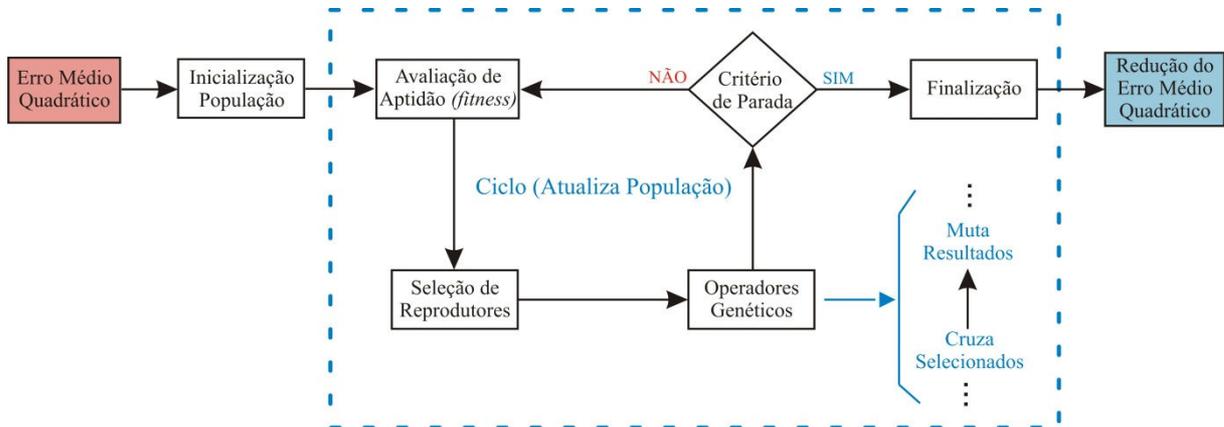


Figura 4. 2: Etapas do funcionamento dos AG's

4.3.1 Inicialização

É na inicialização que é gerada a população inicial em que serão aplicadas todas as ações subsequentes do processo. A população é gerada de maneira aleatória de tal forma a garantir sua diversidade. As funções mais utilizadas para inicialização são:

- a) Inicialização aleatória uniforme: Cada gene irá receber um valor dentro de uma faixa de valores possíveis para este gene, esse processo ocorre de maneira aleatória.
- b) Inicialização aleatória não-uniforme: Semelhante o processo acima porém há genes que apresentam maior ocorrência de escolha.
- c) Inicialização aleatória com “dope”: Nesse processo de inicialização, indivíduos já otimizados são inseridos em meio a população aleatoriamente gerada, o risco da utilização dessa função é levar ao aparecimento de super indivíduos que podem se destacar no processo de evolução e causar o problema de convergência prematura.

4.3.2 Avaliação de aptidão (*fitness*)

É a etapa que pode ser considerada o elo entre o AG e o mundo externo. É na avaliação que é dado o primeiro passo para a seleção, cada indivíduo recebe uma avaliação de

acordo com o seu grau de aptidão, essa avaliação é feita através de uma função que melhor representa o problema, denominada de função objetivo, e tem por finalidade fornecer uma medida da aptidão de cada indivíduo na população corrente, que irá dirigir o processo de busca; é essencial que esta função tenha uma boa representativa, para assim diferenciar na proporção correta as más das boas soluções, caso contrário se terá pouca precisão na avaliação, e uma boa solução poderá ser colocada de lado na avaliação, além de ser gasto mais tempo explorando soluções pouco promissoras. Fazendo uma analogia com o processo de seleção natural, a função de avaliação é para o AG o que o meio ambiente é para os seres vivos.

4.3.3 Seleção de reprodutores

Nessa etapa os indivíduos são selecionados para a etapa seguinte, o cruzamento. Nessa etapa, fazendo uso do grau de adequação de cada um dos indivíduos, é efetuado um sorteio onde os mais aptos possuem maior probabilidade de se reproduzirem, esse critério de seleção é calculado a partir da função objetivo de cada indivíduo, e determina o quão apto ele está para a reprodução em relação à população a que pertence, em outras palavras, a solução mais apta na população tem maior probabilidade de ser escolhida, ou seja, selecionada, para a reprodução. Assim, se f_i é a avaliação do indivíduo i na população corrente, a probabilidade p_i do indivíduo i ser selecionado é dado por:

$$p_i = \frac{f_i}{\sum_{j=1}^N f_j} \quad (4.1)$$

onde N é o número de indivíduos da população..

O operador de seleção é um componente essencial de algoritmos genéticos. Existem vários métodos para se efetuar seleção, dentre as quais se destacam:

- a) Seleção por giro de roleta (*roulette wheel selection*): Os indivíduos de uma geração são selecionados para a próxima geração utilizando-se uma roleta, onde cada indivíduo da população ocupa uma fatia da roleta, que é proporcional ao seu índice de aptidão. Desse modo após N giros da roleta, onde N corresponde ao tamanho da população inicial, o indivíduo selecionado será copiado para a próxima geração, e sendo assim, o

indivíduo com maior “fatia”, correspondente a maior aptidão, tem uma probabilidade maior de passar suas características para as futuras gerações;

- b) Seleção por torneio (*tournament selection*): Grupos de soluções são escolhidos sucessivamente e os indivíduos mais adaptados dentro de cada um destes são selecionados (GOLDBERG,1989).
- c) Seleção de ranking (*rank selection*): os indivíduos da população são ordenados de acordo com seu valor de aptidão e então sua probabilidade de escolha é atribuída conforme a posição que ocupam.

4.3.4 Operadores genéticos

Os operadores genéticos têm como princípio básico transformar a população através das sucessivas gerações, estendendo a busca até um resultado satisfatório. Eles são responsáveis pela diversificação da população mantendo as características de adaptação adquiridas nas gerações anteriores e, por esse motivo, são fundamentais em AG's.

a) Cruzamento (*crossover*)

É o operador genético considerado predominante, e através do qual são criados novos indivíduos misturando as características dos cromossomos antecedentes, “os pais”; é nessa etapa que, pares de genitores, indivíduos, escolhidos aleatoriamente na população, utilizando critério baseado na aptidão, são recombinados através do cruzamento de alelos, e novos indivíduos são criados a partir da troca do material genético, genes. Os indivíduos gerados, descendentes, são diferentes dos pais, mas combinam as melhores características de seus genitores, cromossomas bases.

Alguns tipos de cruzamento bastante utilizados são o cruzamento em um ponto e o cruzamento em dois pontos, mostrados nas Figuras 4.3 e 4.4.

- i. Cruzamento em um ponto: O cruzamento em um ponto consiste em se selecionar aleatoriamente um ponto de corte no cromossoma e permutar os genes entre os cromossomas gerando-se descendentes. A máscara de cruzamento é um vetor que define a região de corte, é formado por uma série de 0's (zeros) sucedidos de 1's (uns) na região de corte.

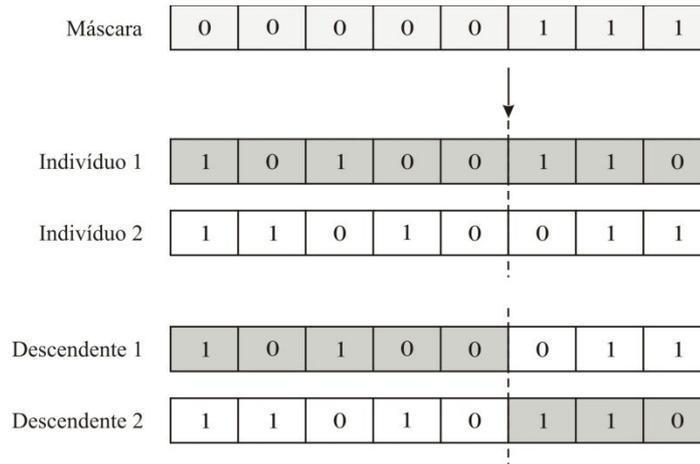


Figura 4. 3: Crossover em um ponto

- ii.** Cruzamento multiponto: O cruzamento multiponto é uma generalização do cruzamento em um ponto, porém nesse caso são selecionados genes em um número fixo n de pontos de corte. A Figura 4.4 representa um caso particular do cruzamento multiponto, onde $n = 2$. Um operador com n pontos de cruzamento apresentaria uma máscara de cruzamento com n mudanças em sua sequência de zeros e uns.

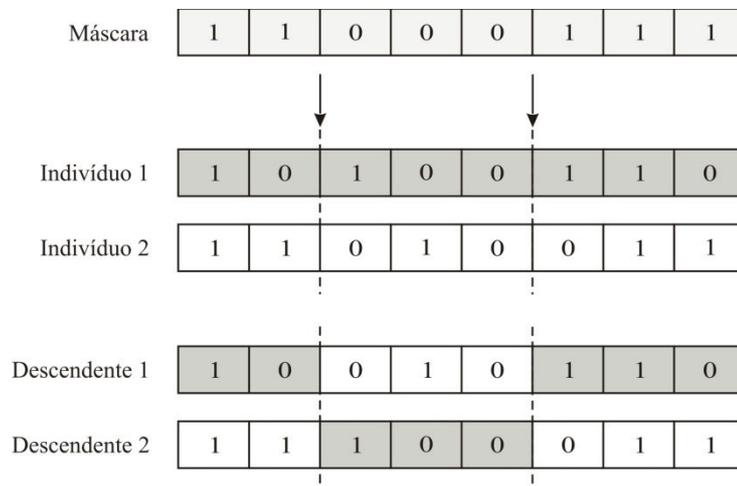


Figura 4. 4: Crossover em dois pontos

No cruzamento em dois pontos ($n = 2$), cada descendente gerado fica com a parte central de um dos cromossomas pais, e as partes periféricas do outro.

- iii.** Cruzamento uniforme: É o tipo de cruzamento em que os genes dos cromossomos filhos são obtidos por meio de um operador de cruzamento

uniforme, que sorteia de qual dos pais esse gene deve ser gerado. O operador de cruzamento é uma sequência qualquer de zeros e uns.

Máscara	0	1	1	0	1	0	0	1
Indivíduo 1	1	0	1	0	0	1	1	0
Indivíduo 2	1	1	0	1	0	0	1	1
Descendente 1	1	1	0	0	0	1	1	1
Descendente 2	1	0	1	1	0	0	1	0

Figura 4. 5: Crossover uniforme

b) Mutação

É a operação genética que modifica aleatoriamente alguma característica do cromossoma. Esse operador é necessário por introduzir e manter a diversidade genética na população, nessa etapa a troca do gene permite criar novos valores de características que não existiam ou apareciam em pouca quantidade entre os indivíduos, garantindo uma probabilidade de busca não nula para qualquer que seja a característica desejada na população. Embora a taxa de mutação seja geralmente pequena, a mutação é sempre importante para obtenção de populações com indivíduos mais aptos. A Figura 4.6 é um exemplo de mutação simples.

Descendente	1	1	0	0	0	1	1	1
Descendente Mutado	1	1	0	0	1	1	1	1

Figura 4. 6: Mutação simples

A mutação ela pode ser classificada como:

- i. Mutação aleatória (*Flip Mutation*): cada gene a que será mutado receberá um valor selecionado dentro do intervalo de genes;
- ii. Mutação por troca (*Swap Mutation*): são sorteados N pares de genes e posteriormente os pares trocam de valor entre si;
- iii. Mutação *creep*: um valor aleatório é somado ou subtraído do valor do gene.

4.3.5 Atualização

Nessa etapa os indivíduos gerados pela operação genética são inseridos na população segundo critério adotado no AG's. Um dos critérios é conhecido como AG's simples, nesse, o tamanho da população não sofre alteração, desse modo, os indivíduos são criados em mesmo número que seus antecessores e os substituem por completo. Alternativas a essa abordagem podem se feitas como, por exemplo, considerar que o número de indivíduos gerados pode ser menor que os seus antecedentes, ou modificar o critério de inserção, nesse último caso os filhos só substituiriam os pais se estes possuísem maior aptidão, caso contrário o número de indivíduos n pode ser mantido.

4.3.6 Finalização

A finalização é a etapa que determina o fim do processo de evolução do AG quando algum critério de parada pré-estabelecido for atingido, os critérios para a parada são variados podendo ser o tempo de execução, o número de gerações já criadas, a falta de diversidade entre os indivíduos da população, e o grau de convergência da atual população, ou seja, as últimas k gerações sem melhora, ou o valor de aptidão de algum indivíduo da população. Todas as etapas anteriores exceto a criação da população inicial são repetidas até que um dos critérios acima seja satisfeito.

4.4 Desenvolvimento do algoritmo genético

Para o desenvolvimento do algoritmo de otimização serão utilizadas funções disponíveis na própria ferramenta de trabalho, o Matlab. Como foi visto no início deste Capítulo, a primeira etapa corresponde à geração da população inicial, e para isso será utilizada a função *inicializaga*, essa função cria uma matriz de números aleatórios, e é utilizada pelo GA justamente para criar aleatoriamente a população inicial, seus principais parâmetros são: *populationSize*, *variableBounds*, *evalFN*, e *options*. Como sugere o próprio nome, *populationSize* corresponde ao tamanho da população que será criada, que no nosso caso será de 500 indivíduos, que correspondem as *quinhentas* possíveis melhores soluções iniciais do nosso problema. O limite de cada uma dessas soluções criadas é dado pelo parâmetro *variableBounds*, esse intervalo e nada mais que o espaço de busca para seleção das melhores soluções, que no problema corresponde a uma variação em 10% para mais ou para menos no valor de suporte das funções de pertinência triangulares. O parâmetro *evalFN*

corresponde a um arquivo *.m* contendo as instruções que irão avaliar cada solução, atribuindo a cada um dos indivíduos um grau de aptidão. Como já mencionado, a função avaliação irá utilizar o grau de aptidão de cada indivíduo, que por sua vez é fornecido pela *fitness function*, ou função de aptidão, que no trabalho em questão corresponderá ao MSE, para categoriza-los para etapa seguinte, a seleção dos reprodutores. Na seleção dos reprodutores os indivíduos são selecionados por ranking, e os indivíduos com maior ranking tem maior probabilidade de gerar novos descendentes. E por último o parâmetro *options*, esse parâmetro fornece opções para inicialização, sendo um vetor (1x2), o primeiro elemento corresponde à precisão da solução, seis casas decimais, e o segundo elemento e a definição de flutuador ou binário, 1 ou 0 respectivamente.

Na primeira etapa da reprodução ocorre o *crossover*. O *crossover* será aritmético, a função no Matlab que será utilizada é a *arithXover*. Esse tipo de *crossover* proporciona a interpolação entre dois indivíduos “pais” ($p1$ e $p2$) por meio da soma ponderada por um número aleatório “ a ”. Os novos indivíduos ($c1$ e $c2$) são obtidos conforme Equação 4.2:

$$\begin{aligned} c1 &= p1.a + p2.(1 - a) \\ c2 &= p1.(1 - a) + p2.a \end{aligned} \quad (4.2)$$

A etapa seguinte corresponde à mutação, a função do Matlab responsável por essa etapa é a *nonUnifMutate*, esta função como sugere o próprio nome, realiza uma mutação não uniforme, onde um dos genes do cromossomo pai é alterado com base em uma distribuição de probabilidade não uniforme.

As etapas anteriores serão executadas, e a cada nova geração os indivíduos descendentes substituem os seus antecedentes com o objetivo de garantir a permanência dos mais aptos. O fim do processo de evolução do AG ocorre quando o número de gerações já criadas atinge o valor definido no algoritmo de programação.

4.5 Conclusão

Neste Capítulo procurou-se abordar de maneira sucinta conceitos fundamentais relacionados à AG, e um esboço das funções em Matlab, utilizadas para o desenvolvimento do algoritmo de programação, foram apresentadas. O Capítulo seguinte irá aplicar as técnicas aqui propostas, com o objetivo de minimizar o erro de identificação da falta.

5 ESTUDO DE CASO APLICADO À DETECÇÃO E AO DIAGNÓSTICO DE FALTAS INCIPIENTES EM ENROLAMENTO DE ESTATOR DE MOTOR TRIFÁSICO DE INDUÇÃO

5.1 Considerações iniciais

Neste Capítulo serão aplicadas as ferramentas desenvolvidas neste trabalho, para detecção e diagnóstico de faltas. Primeiramente, será definido um modelo fenomenológico do sistema, nesse caso, do motor de indução trifásico (MIT). Definidas as equações matemáticas desse sistema, o próximo passo foi o desenvolvimento de um simulador em Matlab/Simulink para aplicarmos os testes envolvendo a falta incipiente. Para a falta do tipo curto-circuito parcial nas espiras do enrolamento do estator, um sinal do tipo rampa que decresce com o tempo (coeficiente angular negativo) foi introduzida multiplicando-se a reatância de magnetização do motor, de modo a simular o caráter incipiente da falta. Para o processo de identificação do sistema foi utilizado o sinal sequência binária pseudoaleatória (SBPA), sinais de baixa amplitude, que não interferem na operação linear do processo, e consagrados em identificação de sistemas. Sua utilização é justificada por razões numéricas e argumentos dinâmicos, já que, por excitar uma faixa mais abrangente de frequências do sistema, permitem obter um modelo que melhor represente ou se aproxime das características dinâmicas do processo. Assim, aplicando-se as técnicas de identificação paramétrica e variando-se a intensidade da falta, espera-se obter diferentes modelos matemáticos do referido sistema para cada uma das condições de operação (0%, 5%, 10%, 15% e 20%). Os parâmetros dos modelos obtidos serão entradas de um sistema *fuzzy* do tipo-2 que fará o processo inverso, ou seja, identificar a quantidade de espiras avariadas para as condições definidas e não definidas, e os eventuais erros de identificação da falta serão reduzidos (otimizados) com a introdução de algoritmos genéticos. As próximas seções irão tratar da identificação paramétrica, da detecção e da identificação da falta incipiente no processo.

5.2 Identificação do sistema para a condição livre de faltas

O motor de indução trifásico estudado tem potência de 20HP (ONG, 1998), com uma variação na amplitude da tensão, devido à adição de um sinal SBPA a V_m . Os valores dos parâmetros físicos do motor serão apresentados na Tabela 5.1, e o diagrama em blocos do modelo dinâmico com falta desenvolvido para simular o motor de indução trifásico em Matlab/Simulink é representado na Figura 5.1.

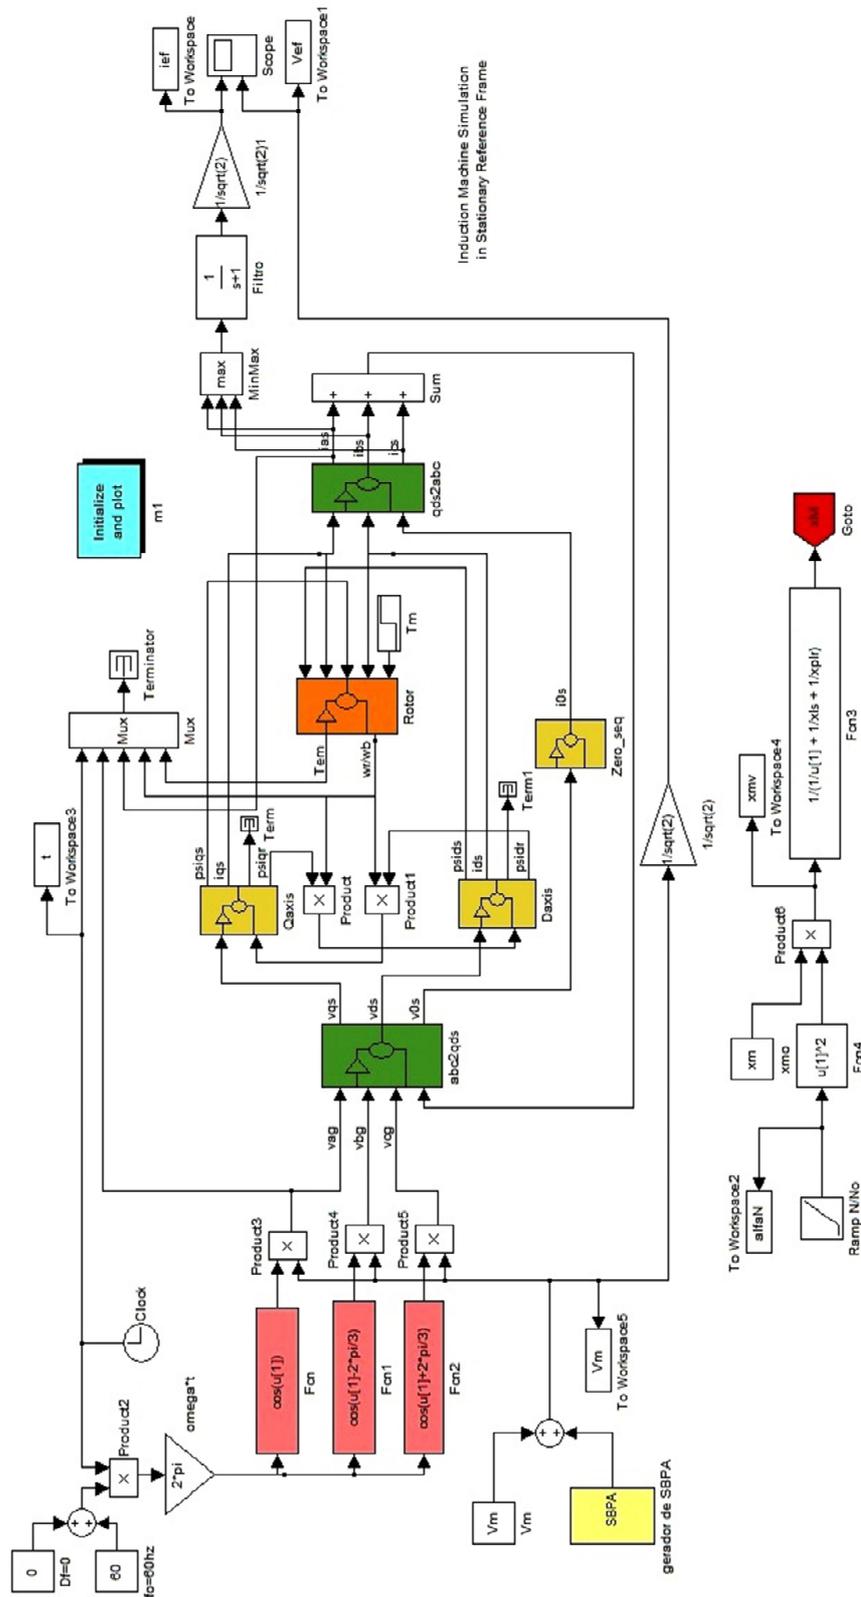


Figura 5. 1: Modelo de simulação do motor de indução em Matlab/Simulink
Fonte: Adaptado (ONG, 1998).

Na Figura 5.1, o bloco em cor amarelo é o gerador de sinal SBPA. Os blocos em cor vermelha representam as tensões de alimentação. Os blocos em cor verde (abc2qds) e

(qds2abc) realizam as transformações de referência, de abc para qd0, e de qd0 para abc. O bloco em cor laranja representa a dinâmica rotativa do motor de indução. A entrada T_m simula a carga acoplada ao sistema, e por último, o bloco em cor azul é um filtro adicionado na saída do simulador, esse filtro faz parte dos instrumentos de medição do sistema.

Tabela 5. 1: Parâmetros do MIT de 20HP

Parâmetros do Motor de Indução Trifásico de 20HP	
$r_s = 0,1062 \Omega$	Resistência <i>wdg</i> do estator em ohms
$x_{ls} = 0,2145 \Omega$	Reatância de dispersão do estator em ohms
$x_{plr} = 0,2145 \Omega$	Reatância de dispersão do rotor em ohms
$x_m = 5,8339 \Omega$	Reatância de magnetização do estator em ohms
$r_{pr} = 0,0764 \Omega$	Resistência <i>wdg</i> referida ao rotor em ohms

Nos testes de identificação do sistema, foram coletados os sinais de tensão de linha eficaz do estator, nas três fases, V_{nl} (tensão sem carga) e as correntes de linha eficaz do estator, nas três fases I_{nl} (corrente sem carga), Figura 5.2, para o sistema livre de faltas. Como definido no Capítulo 2, esse tipo de identificação é baseado no modelo do processo, pois por meio da correlação dos sinais de entrada e saída estima-se um modelo matemático e o correlaciona com o modelo fenomenológico do motor. Os sinais de tensão e corrente serão entradas de um algoritmo baseado em MQR que identificará os parâmetros do modelo ARX.

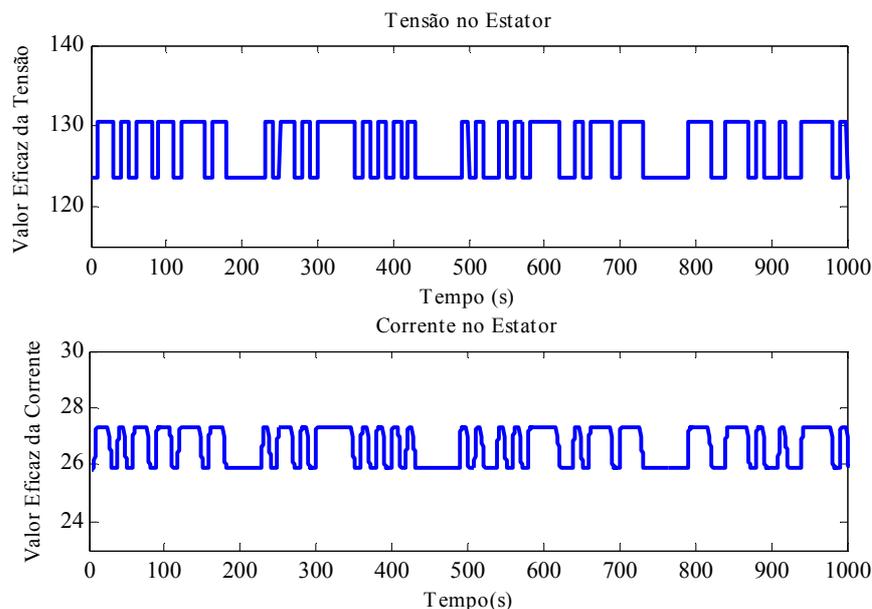


Figura 5. 2: Tensão e corrente eficazes no estator, sem a falta.

Quanto à ordem da função de transferência para o sistema, essa é dada pela ordem do filtro. Isso porque, de acordo com Krause *et al* (2002), a relação tensão-corrente obedece a seguinte aproximação, para operação em regime permanente:

$$x_{ls} + x_m \approx \frac{V_{nl}}{\sqrt{3}I_{nl}} \quad (5.1)$$

$$I_{nl} = \frac{1}{x_m + x_{ls}} \left(\frac{V_{nl}}{\sqrt{3}} \right) \quad (5.2)$$

Como se pode observar, a Equação 5.2 representa um sistema de ordem 0, por ser uma relação algébrica e, portanto, independente do tempo, é simplesmente um ganho, cuja a representação equivalente é dada por:

$$\begin{aligned} y &= a.u \\ \Delta y &= a.\Delta u \end{aligned} \quad (5.3)$$

Fazendo analogia entre as Equações 5.2 e 5.3, obtêm-se as seguintes correspondências:

$$y = I_{nl}, \quad u = V_{nl} / \sqrt{3}$$

$$e \quad G_0 = \frac{y}{u} = \frac{1}{x_m + x_{ls}} \quad (5.4)$$

Assim o simulador é um sistema que tem o ganho em regime permanente dado pela soma dos inversos da reatância de magnetização e reatância de dispersão do estator. Sendo assim, deve-se obter como resultado na estimação um ganho em regime próximo a G_0 , como calculado a seguir:

$$G_0 = \frac{1}{x_m + x_{ls}} = \frac{1}{5,8339 + 0,2145}$$

$$G_0 = 0,16533$$

Assim, observa-se que a relação tensão-corrente é somente um ganho, esse ganho associado a um filtro passa-baixa de 1ª ordem, representando o condicionamento do sinal, permite representar a planta como um modelo aproximado de 1ª ordem. E a função de transferência, ou seja, o modelo matemático para o sistema é representado como na Equação 5.5.

$$G(s) = \frac{G_0}{1 + s\tau} \quad (5.5)$$

ou na forma discreta:

$$G(z^{-1}) = \frac{b_1 z^{-1}}{1 + a_1 z^{-1}} \quad (5.6)$$

Desse modo o modelo ARX é um modelo de 1ª ordem, nessas condições somente dois parâmetros serão estimados, o parâmetro a_1 e o parâmetro b_1 , ambos estimados pelo MQR. Através da correlação dos sinais de entrada e saída, tensão e corrente do estator, um modelo estimado da planta é obtido, e comparando a saída real com a saída estimada obtida tem-se a Figura 5.3.

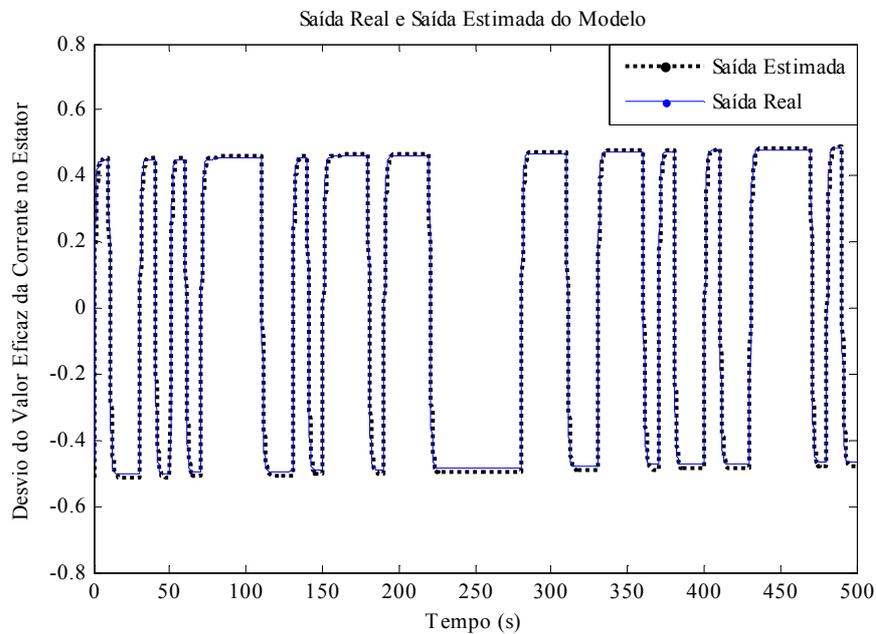


Figura 5. 3: Saída real e saída estimada sem a falta.

Inserindo os valores de tensão e correntes eficazes do estator, no algoritmo dos mínimos quadrados recursivos (MQR) com fator de esquecimento de $\lambda = 0,999$, os parâmetros estimados, a_1 e b_1 da função de transferência discreta para o sistema livre de faltas apresentam média igual a:

$$a_1 = 0,8619 \text{ e } b_1 = 0,0186$$

Substituindo os valores dos parâmetros na equação (5.6), tem-se:

$$G(z^{-1}) = \frac{0,0186 z^{-1}}{1 - 0,8619 z^{-1}}$$

Em regime permanente $z = I$, e o ganho é:

$$G_0 = \frac{0,0186}{1 - 0,8619} = 0,13468$$

valor aproximadamente igual ao valor de ganho obtido pela Equação 5.4

O comportamento dos parâmetros no tempo é mostrado na Figura 5.4

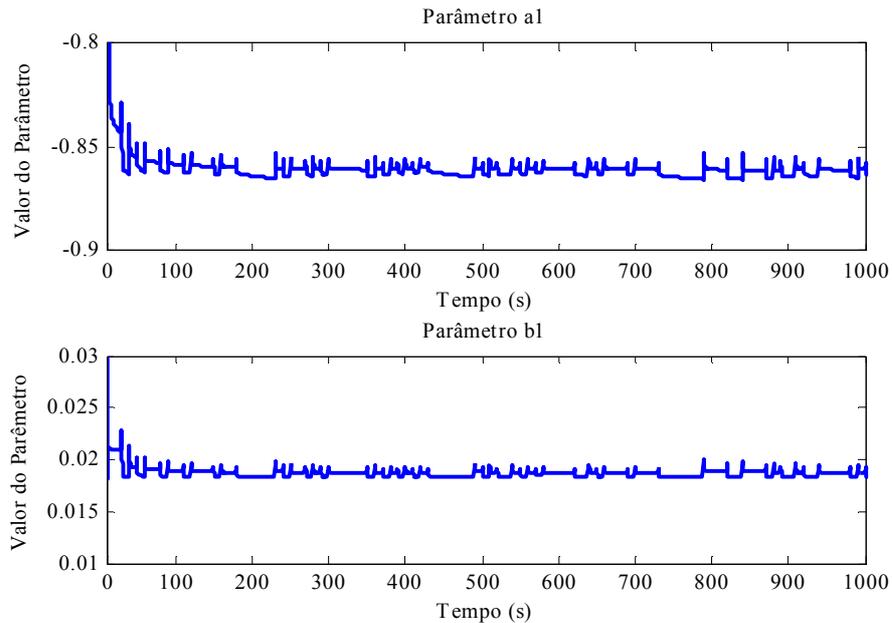


Figura 5. 4: Parâmetros estimados a_1 e b_1

5.3 Identificação do sistema para condição com falta incipiente

Identificado o sistema para condição livre de faltas, o objetivo na próxima etapa é emular a falta para que se possa analisar o comportamento paramétrico do modelo matemático quando se iniciar o curto-circuito parcial entre as espiras. Primeiramente, esse curto-circuito irá acontecer em estágio incipiente, inicial, evoluindo para um grau de severidade maior com o decorrer do tempo de simulação.

O tipo de falta que será inserido no processo é o curto-circuito parcial nas espiras do enrolamento do estator do motor de indução trifásico. Quando a falta for aplicada ao simulador, as bobinas do estator sofrerão um curto-circuito virtual, ou seja, os enrolamentos irão progressivamente com o tempo perder isolamento e entrarem em curto-circuito entre si. Para fins de simulação isso irá significar uma redução do número de espiras do enrolamento, e desse modo, parâmetros físicos do motor, como resistência e reatância sofrerão variações. A

seguir será estudada justamente a influência dessa redução sobre os parâmetros físicos da máquina.

Segundo Fitzgerald *et al* (2003), para um circuito magnético composto de material ferromagnético constante ou que inclua um entreferro dominante, a relação entre o fluxo magnético e a corrente i , através das espiras, é linear e, desse modo, a indutância do enrolamento em uma das fases pode ser expressa como a razão entre o fluxo magnético concatenado λ , e a corrente i através do indutor, como na Equação 5.7.

$$L = \frac{\lambda}{i} \quad (5.7)$$

Como, $\lambda = N_s \cdot \psi$, então

$$L = N_s \cdot \frac{\psi}{i} \quad (5.8)$$

E sabendo-se que, o fluxo magnético é $\psi = N_s \cdot i \cdot \mathcal{P}$, e sendo \mathcal{P} , a permeância magnética, que é representada matematicamente pela Equação 5.9.

$$\mathcal{P} = \frac{\mu \cdot S}{l} \quad (5.9)$$

E, observando-se que, a permeância magnética \mathcal{P} , é uma grandeza física que depende apenas das características intrínsecas do material ferromagnético, e de suas características construtivas, então seu valor é constante e não sofre alteração com a atuação da falta. Então a Equação 5.7, se resume como a Equação 5.10.

$$L_{ss} = N_s^2 \cdot cte \quad (5.10)$$

Onde: L_{ss} , é a indutância própria do estator em uma das fases dada em (H), ψ , é o fluxo magnético em (W_b); i é a corrente no enrolamento em uma das fases dada em (A); e \mathcal{P} , é a permeância magnética em (W_b/A).

Do mesmo modo, a resistência do estator em função das espiras é dada como em (5.11).

$$r_s = \rho \frac{l}{A} = \rho \frac{N_s \cdot 2\pi \cdot r}{\pi \cdot r^2} \quad (5.11)$$

$$r_s = N_s \cdot cte \quad (5.13)$$

Onde: ρ , é a resistividade elétrica em (Ωm); l é o comprimento do condutor em (m); A , é a área em (m^2); e r , é o raio em (m).

Sabendo-se que, para um circuito RL a constante de tempo τ é dada pela razão entre a indutância própria do estator e a resistência do estator, e como a indutância de dispersão, L_{ls} , também no estator, pode ser desconsiderada durante a simulação, porque as perdas de fluxo magnético não dependem desse tipo de falta, mas somente do material ferromagnético que compõem o núcleo, então a constante de tempo é uma variável, quando sob atuação desse tipo de falta, e é dada como a Equação 5.14:

$$\tau = \frac{L_{ss}}{r_s} = \frac{L_{ls} + L_m}{r_s} = \frac{L_m}{r_s} \quad (5.14)$$

A relação entre indutância e reatância de magnetização é dada pela Equação 5.15.

$$x_m = 2\pi \cdot f \cdot L_m \rightarrow L_m = \frac{x_m}{2\pi \cdot f} \quad (5.15)$$

E então, a Equação 5.14, da constante de tempo para um circuito RL, se resume como a Equação 5.16,

$$\tau = \frac{L_{ss}}{r_s} = \frac{L_{ls} + L_m}{r_s} = \frac{L_m}{r_s}$$

$$\tau = \frac{x_m}{2\pi \cdot f \cdot r_s} \quad (5.16)$$

Onde: τ - Constante de tempo; L_{ss} - Indutância mútua do estator; r_s - Resistência do enrolamento do estator; L_{ls} - Indutância de dispersão do enrolamento do estator; L_m - Indutância de magnetização; x_m - Reatância de magnetização; f - Frequência da rede de alimentação.

Para simplificação do método foi levado em consideração o fato, de que, a indutância própria do estator, ou mais precisamente, com base na Equação 5.15, a reatância de magnetização, é proporcional ao quadrado do número de espiras do enrolamento, Equação 5.10, além do que, a reatância de magnetização é muito maior do que a resistência do estator (aproximadamente 60 vezes maior) ver Tabela 5.1, então, a rampa que simula os efeitos da falta incipiente irá ser aplicada somente sobre a reatância de magnetização, como na Figura 5.7. As Figuras 5.5 e 5.6 são os blocos *Qaxis* e *Daxis* detalhados da Figura 5.1.

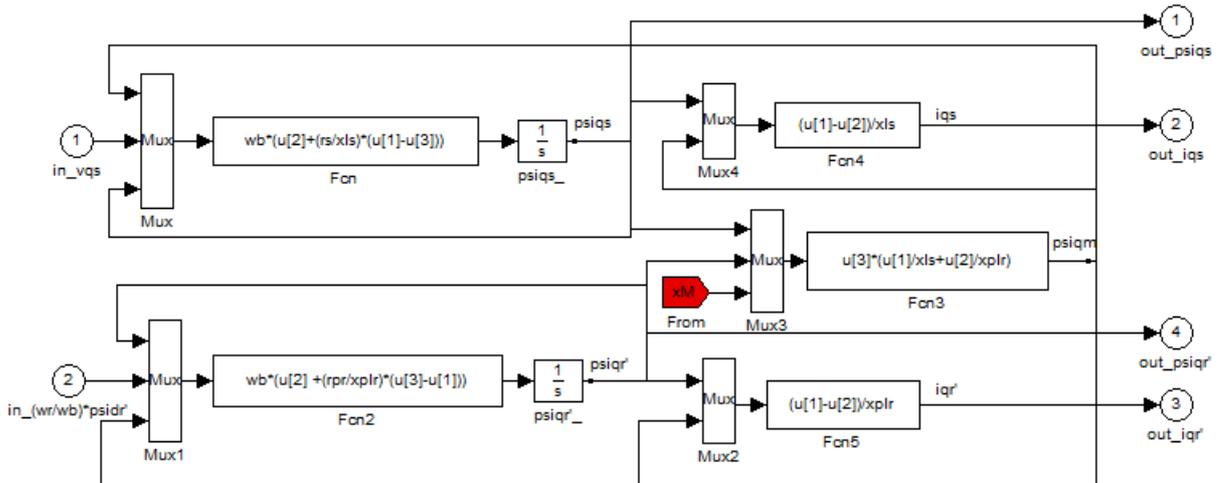


Figura 5. 5: Bloco Qaxis (eixo de referência q) detalhado com a falta

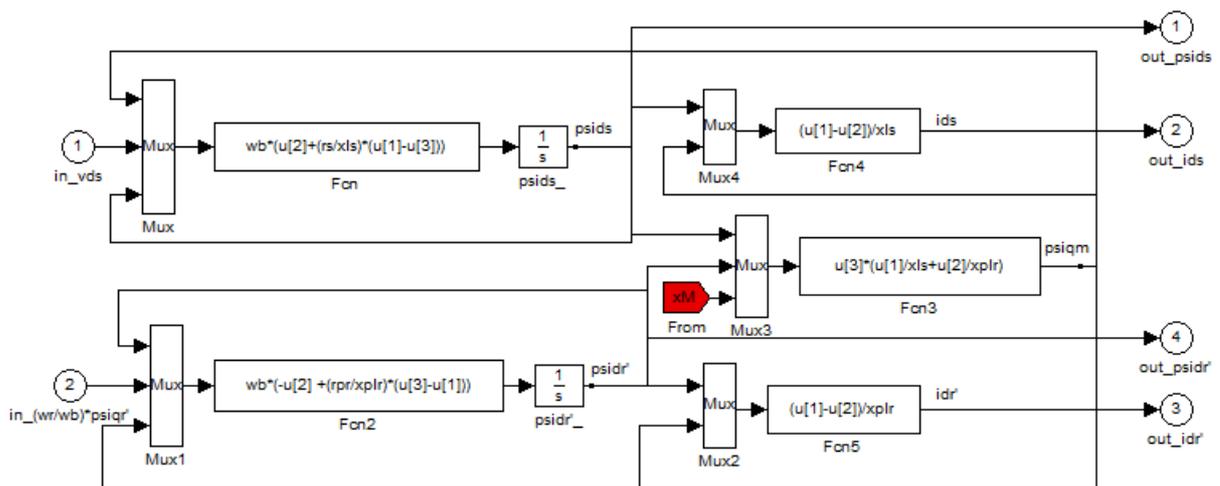


Figura 5. 6: Bloco Daxis (eixo de referência q) detalhado com a falta

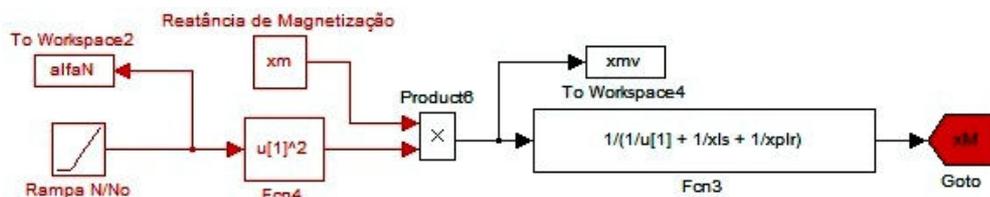


Figura 5. 7: Bloco falta

Quando o simulador programado com a falta é executado, um curto-circuito parcial nas espiras do enrolamento do estator ocorre. A rampa de declínio que simula a redução do número de espiras tem um coeficiente angular igual a $-0,00005$ pu/seg, então para $t = 0$ s, o valor da amplitude é 1, e no decorrer do tempo, o valor de amplitude decai para 0,95, o que corresponde a um curto-circuito de 5% das espiras que compõem o estator, a Figura 5.8 retrata o processo.

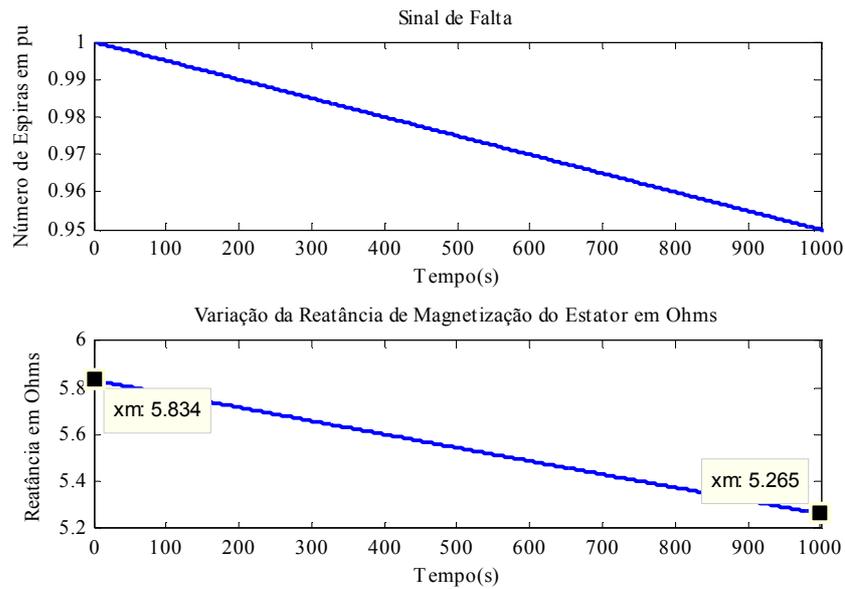


Figura 5. 8: Evolução do curto-circuito e redução do valor da reatância de magnetização

Para o estudo em questão a reatância do enrolamento declina aproximadamente 9,75% em um período de 1000 segundos, devido à variação de 5% no número de espiras.

$$x'_m = x_m \cdot (\bar{N})^2 = 5,8839 \cdot (0,95)^2 \therefore x_m = 5,265 \Omega$$

$\% \text{ final de espiras} = \frac{5,265}{5,8339} = 90,24\%$, confirmando a variação de aproximadamente 9,75%.

Com a redução do valor da reatância de magnetização, tem-se uma redução na impedância equivalente vista do estator, e para um valor da tensão eficaz constante, espera-se então, um aumento no valor da corrente eficaz (Lei de Ohm), confirmado na Figura 5.9.

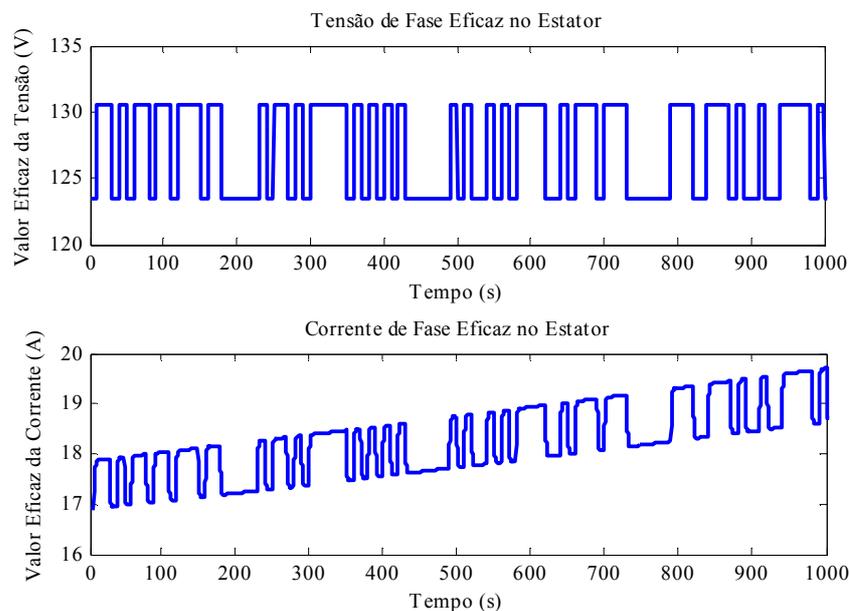


Figura 5. 9: Tensão e corrente eficazes no estator com a falta

Na identificação do sistema, de maneira semelhante ao caso sem falta incipiente, os valores de tensão e correntes eficazes serão entradas do algoritmo MQR, porém com a condição de que não haverá variação no ponto de operação, ou seja, em determinando período de tempo, para cada uma das condições de faltas (5%, 10%, 15% e 20% das espiras um curto-circuito) serão coletados valores de tensão de fase e corrente de fase, eficazes.

Primeiramente será avaliado o caso em que apenas 5% das espiras se encontram avariadas, e a comparação entre a saída real e a saída estimada é mostrada na Figura 5.10.

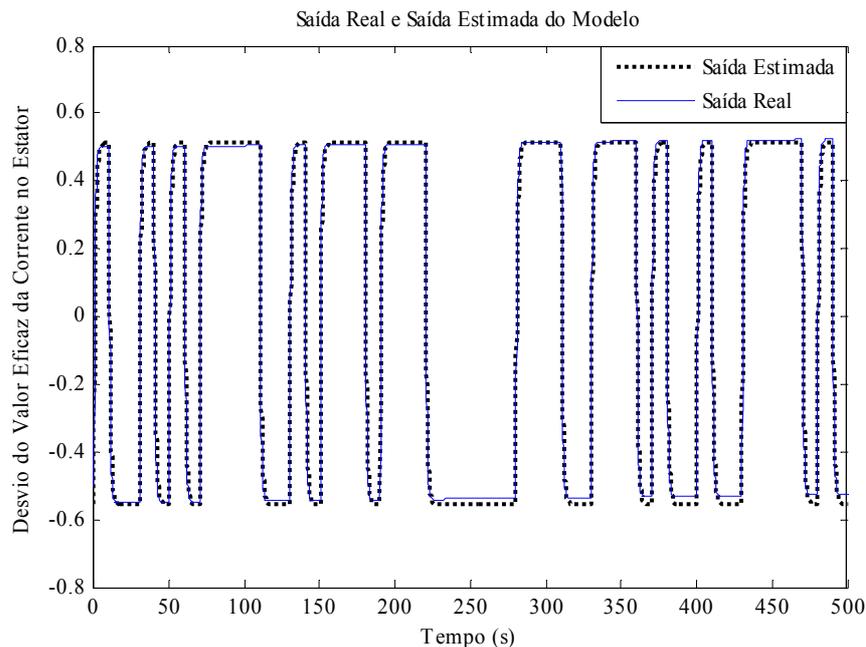


Figura 5. 10: Saída real e saída estimada com a falta

Os parâmetros a_1 e b_1 do modelo ARX da função de transferência discreta de 1ª ordem, obtidos pelo algoritmo dos mínimos quadrados recursivos para todas as intensidades de faltas são detalhados nas Figuras 5.11 e 5.12; para obtenção desses parâmetros, como já informado, o mesmo procedimento foi adotado do problema anterior. Desse modo, tensão e corrente eficazes para cada uma das condições foram inseridos individualmente no algoritmo do MQR, e os valores dos parâmetros da função de transferência do sistema correspondente às respectivas condições de operação foram obtidos.

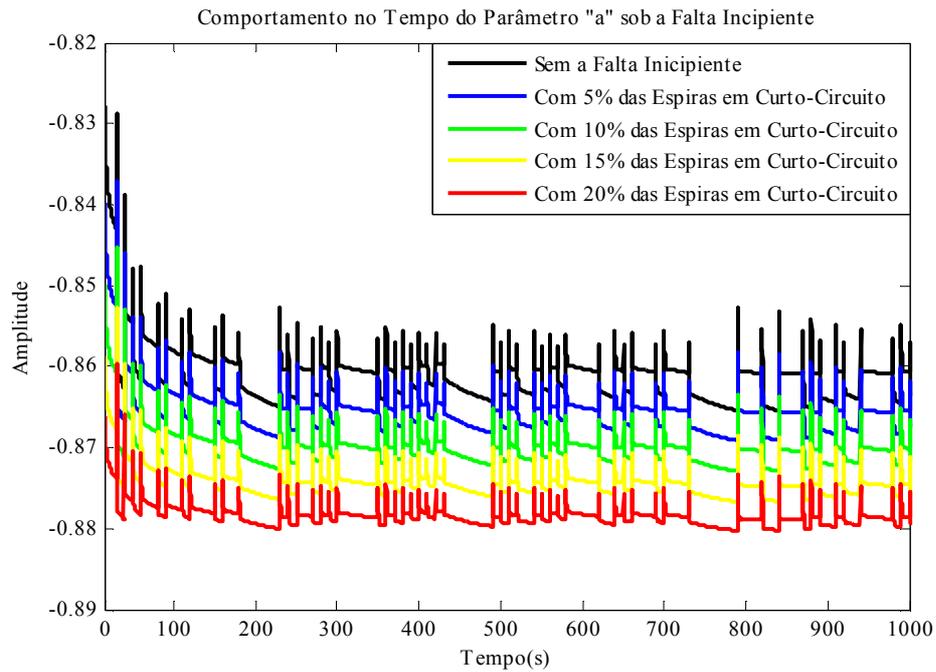


Figura 5. 11: Comportamento do parâmetro a

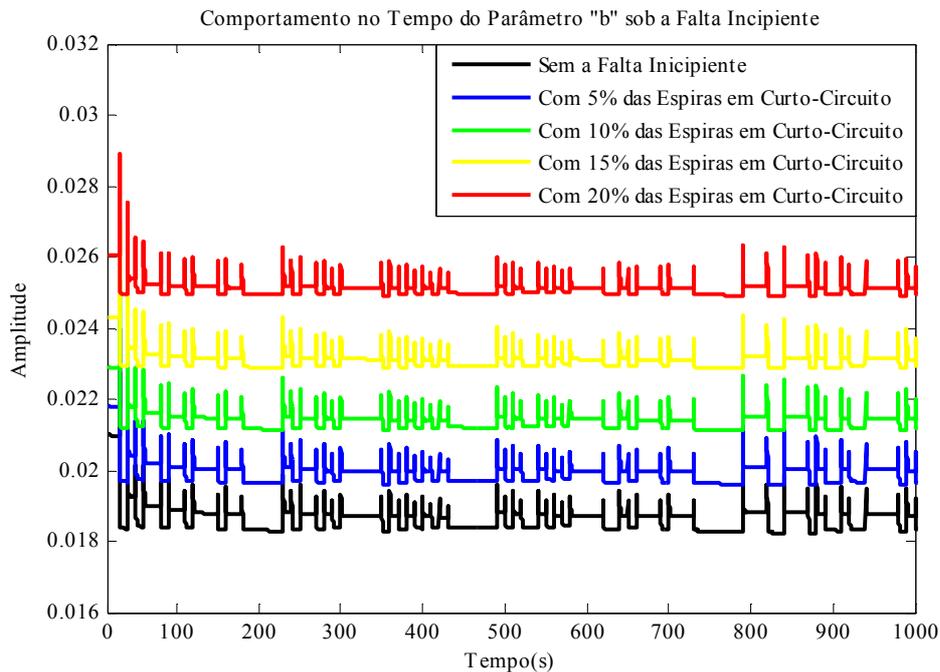


Figura 5. 12: Comportamento do parâmetro b

Os gráficos das Figuras 5.11 e 5.12 evidenciam a distorção provocada pela falha incipiente nos parâmetros do motor de indução. Nos gráficos observa-se o comportamento dinâmico do sistema sobre as condições de funcionamento 0%, 5%, 10%, 15%, e 20% das espiras em curto-circuito, de tal modo que a falha incipiente seja invariante em um dado

período de tempo. Como se pode observar tanto o parâmetro a_1 como o parâmetro b_1 sofreram alterações com a introdução da falta incipiente, ainda sobre o comportamento dos parâmetros, observa-se que enquanto o parâmetro a_1 tende a decrescer com a evolução da falta, o parâmetro b_1 , tende a crescer, desse modo, os parâmetros podem ser utilizados para detecção da falta incipiente, a Tabela 5.2 mostra a média dos parâmetros correspondente a intensidade da falta nas espiras do estator do motor de indução (ROCHA *et al*, 2012).

Tabela 5. 2: Valor médio dos parâmetros com a intensidade da falta

Intensidade da falta	Parâmetro a_1	Parâmetro b_1
0%	0,8619	0,0186
5%	0,8663	0,0199
10%	0,8707	0,0213
15%	0,8749	0,0230
20%	0,8788	0,0251

Terminada a etapa de detecção, o objetivo agora, é a identificação da falta, e para isso utilizaremos os conjuntos fuzzy intervalares do tipo-2.

5.4 Identificação da falta incipiente utilizando-se sistemas de inferência fuzzy intervalar do tipo-2.

O desenvolvimento de um sistema *fuzzy* infere que através dos parâmetros a_1 e b_1 gerados recursivamente, deve-se obter o correspondente número de espiras em curto-circuito, para isso esses parâmetros serão entradas de um sistema *fuzzy* de identificação, o qual irá sinalizar qual a quantidade de espiras em curto-circuito, operação inversa à aplicada até então, isso porque na maioria dos casos apenas se terá a informação dos parâmetros, que são obtidos pela coleta dos dados de entrada e saída, tensão e corrente no estator, que ao serem inseridos no algoritmo do MQR, fornecerão o comportamento dos parâmetros, mas não indicarão em qual estado o sistema se encontra.

Desse modo, os SIF intervalares do tipo-2, ou simplesmente SIF do tipo-2, indicarão qual o estado do sistema, em outras palavras, identificará a falta incipiente. Neste trabalho as características do sistema *fuzzy* do tipo-2 são:

- Entradas numéricas precisas (*crisp*), não-*fuzzy*, parâmetros (a e b), no *fuzzyficador*;
- o modelo da máquina de inferência é Mamdani, e base de regras é na forma, SE-ENTÃO, e as funções de pertinência são triangulares;
- o redutor de tipo escolhido é a média ponderada dos centros (centroide);
- e o *defuzzyficador* escolhido, para se obter a saída precisa (número de espiras), é a média aritmética.

Para continuação do estudo em questão, e objetivando um menor erro de identificação da falta, programaram-se dois sistemas *fuzzy* do tipo-2 com funções de pertinências em formatos diferentes (gaussianas e triangulares). Para funções de pertinências gaussianas, a FOU foi inserida no valor do parâmetro de dispersão da função gaussiana (σ). Já para funções de pertinência triangulares, a FOU foi inserida nos valores da base do triângulo (suporte da função de pertinência). Nesse caso, exigiu-se um esforço de programação muito grande devido à necessidade de representar a função de formato triangular por intervalos, o que não ocorre no caso de funções gaussianas, ver Equação 3.10. As Figuras 5.13 e 5.14 representam as funções de pertinências gaussianas e triangulares para os parâmetros a e b nas cinco condições de falta, com suas respectivas FOU's.

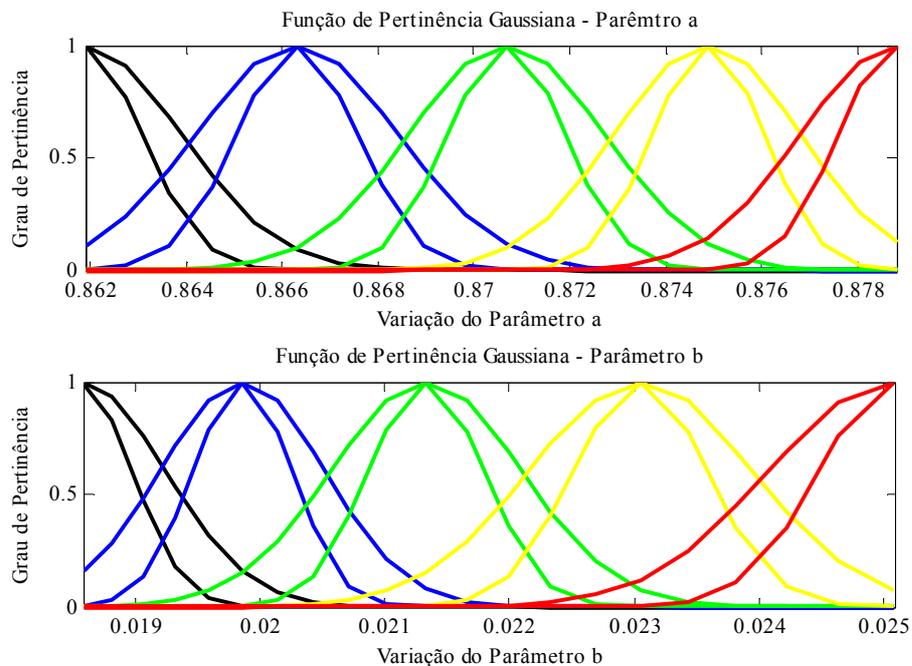


Figura 5. 13: Função de pertinência gaussiana dos parâmetros a e b .

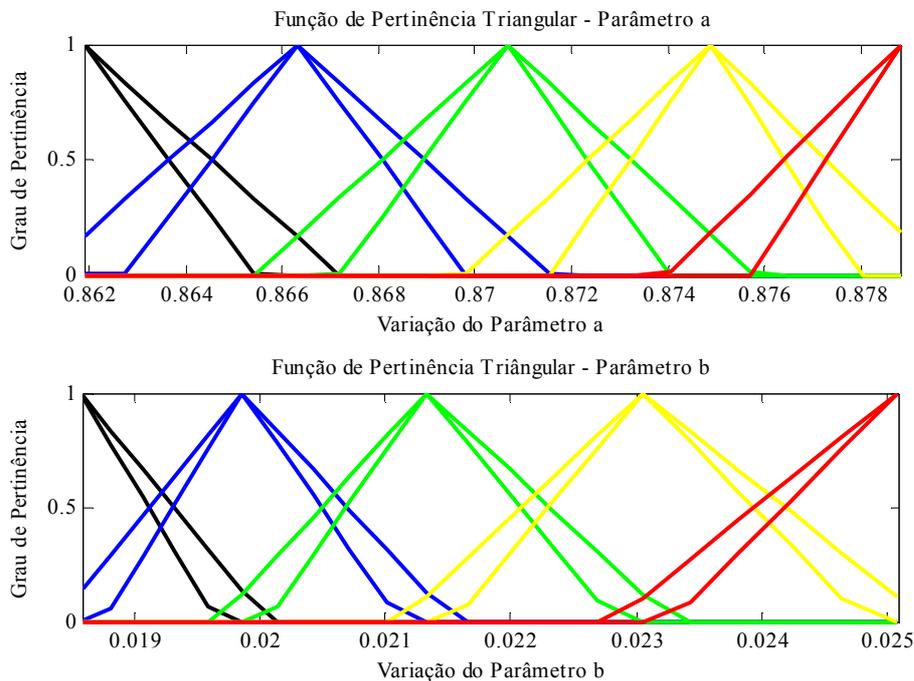


Figura 5. 14: Função de pertinência triangular dos parâmetros a e b .

A definição da região de incerteza, FOU, nesse primeiro momento, foi feita por meio de testes que levaram em consideração principalmente os valores dos parâmetros e suas variações; já para a identificação da falta objetivando um erro de identificação mínimo, foram escolhidos pontos dentro da FOU que pudessem fornecer um valor da falta identificada mais próximo possível do valor real. Assim, desenvolve-se um estudo comparativo com a premissa de identificar as vantagens do SIF do tipo-2 em relação ao SIF do tipo-1, além de indicar para o caso de faltas incipientes, qual a “forma” da função de pertinência mais adequada para o caso de identificação de faltas. As Figuras 5.15 e 5.16 mostram a falta identificada e o erro de identificação para as variações do método proposto.

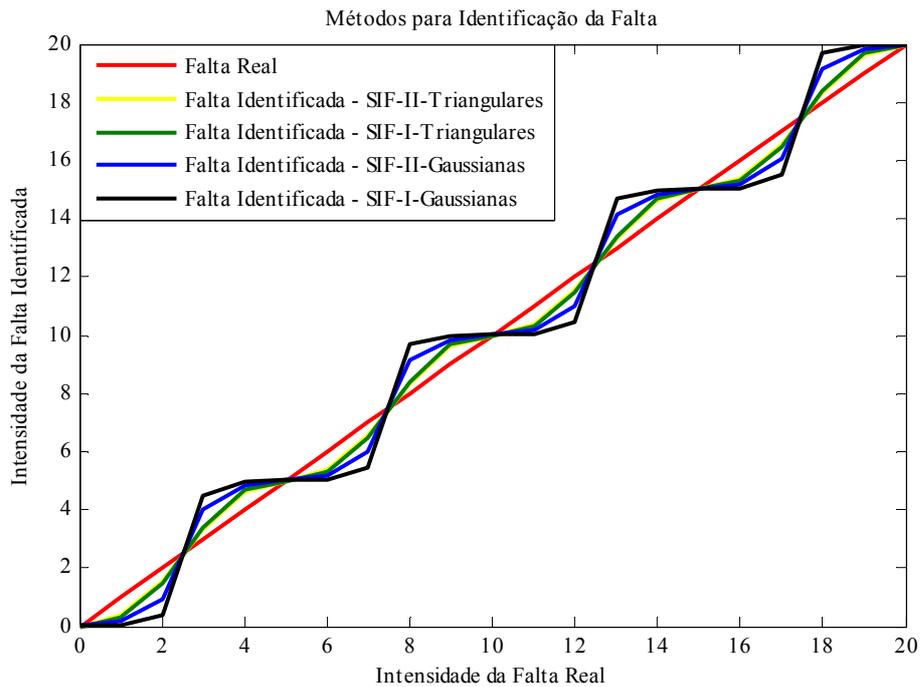


Figura 5. 15: Falta identificada para as variações do método proposto

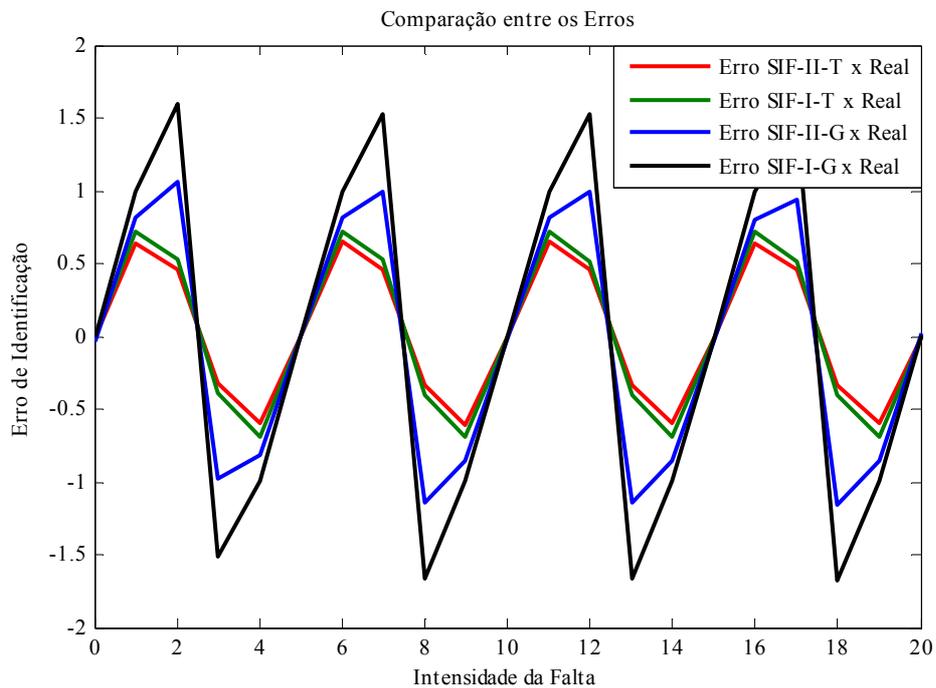


Figura 5. 16: Erro de identificação para as variações do método proposto

Comparando as variações do método proposto, função de pertinência gaussiana ou triangular, o que apresentou menor erro de identificação, ou seja, que mais aproximou a falta identificada da falta real foi à técnica de sistemas de inferência *fuzzy* do tipo-2 com funções de pertinência triangulares; analisando a Figura 5.16, essa melhoria significou uma redução de

mais de 50% do erro de diagnóstico, o que levou a predileção para o uso de funções de pertinência triangulares, mesmo essa apresentando um esforço de programação muito maior, sendo assim, o objetivo agora é aperfeiçoar o sistema aplicando algoritmos genéticos (AG's) para a obtenção dos valores de suporte das funções de pertinência que permitam reduzir ainda mais o erro de identificação, método já consagrado em diversas pesquisas sobre o assunto; e mais, é apresentada outra proposta para utilização de AG, mas agora aplicado na otimização do redutor de tipo (RT) do SIF do tipo-2, com isso espera-se reduzir o erro de identificação com a obtenção de valores mais adequados para os “pesos” associados a cada uma das condições de falta, nesse último caso, não é encontrado nenhum artigo ou bibliografia da área que justifique a técnica proposta, porém os resultados se mostram satisfatórios quando a otimização aplicada na FOU é associada à otimização aplicada no RT.

5.5 Uso de algoritmos genéticos para minimização do erro de identificação

Em diagnóstico de faltas, erros numéricos inerentes ao sistema, e provenientes do processo de identificação paramétrica, acabam por injetar nos sistema FDI (*Fault Detection and Isolation*), incertezas que comprometem um diagnóstico preciso do processo, por isso, técnicas utilizadas para isolar e detectar faltas devem levar em consideração essas incertezas e devem possuir robustez as mesmas, isso significa reduzir a quantidade de alarmes falsos, bem como o valor do erro de diagnóstico. Nesse sentido é justificada a utilização de SIF do tipo-2 para a identificação de faltas, porém ainda que essas incertezas sejam representadas pela FOU, essa técnica não é suficiente para obter-se um reduzido erro de diagnóstico sendo necessária a utilização de otimizadores para esses fins.

Nesse trabalho, seguindo uma metodologia já consagrada por diversos artigos e trabalhos da área, optou-se pela utilização de algoritmos genéticos para otimização da faixa (mancha) de incerteza das funções de pertinência dos sistemas *fuzzy* do tipo-2. Além disso, foi proposta a utilização da mesma ferramenta para otimizar os “pesos” no redutor de tipo, assim espera-se reduzir ainda mais o erro de identificação. Devido à simetria do erro de diagnóstico, a função objetivo proposta a ser minimizada para este tipo de sistema será o erro médio quadrático (MSE), e seu valor corresponde ao erro cometido na tentativa de se diagnosticar a falta (erro de diagnóstico).

A Figura 5.17 mostra a redução no Erro de Identificação aplicando AG na FOU, no RT e em ambos, e a Figura 5.18 trata da redução do erro médio quadrático para as mesmas condições, comprovando eficiência da técnica utilizada.

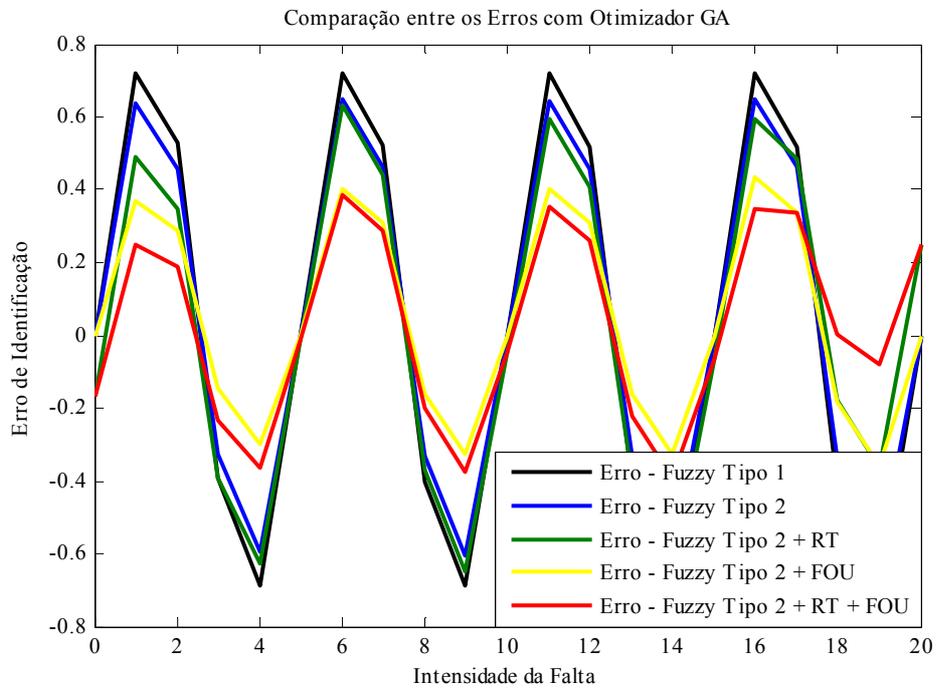


Figura 5. 17: Erro de identificação para as variações do método proposto.

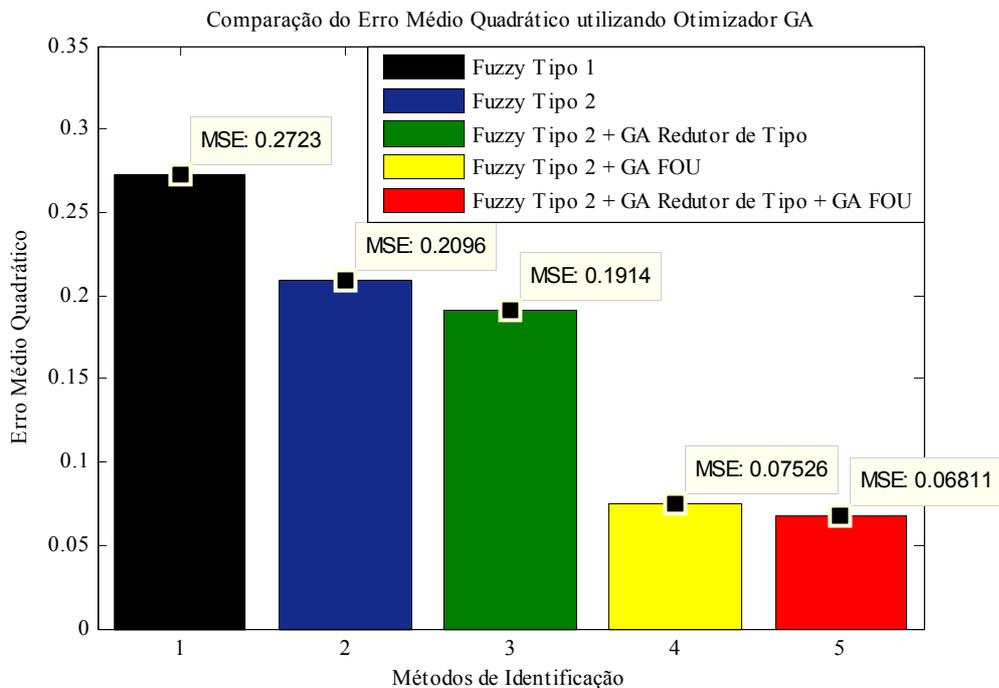


Figura 5. 18: Erro Médio Quadrático para as variações do método proposto

Avaliando as Figuras acima, observa-se que a utilização de AG para otimização do SIF do tipo-2 mostrou-se bastante satisfatório, visto que reduziu de forma acentuada o erro de diagnóstico, Figura 5.17, o mesmo ocorreu com o MSE, onde a redução foi superior a 50%, Figura 5.18. A Tabela 5.3 compara em números os valores da falta real com os valores da falta identificada utilizando SIF do tipo-1 e SIF do tipo-2 com AG.

Tabela 5. 3: Falta Identificada utilizando-se SIF TIPO-2 + AG

Falta Real	Falta Identificada (%)						
	SF- I- G	SF- II- G	SF- I- T	SF- II- T	GA-RT	GA-FOU	RT+FOU
0%	0,0000	0,0385	0,0000	0,0000	0,1671	0,0000	0,1671
1%	0,0044	0,1865	0,2769	0,3591	0,5086	0,6319	0,7519
2%	0,4015	0,9350	1,4721	1,5400	1,6538	1,7133	1,8083
3%	4,5118	3,9825	3,3945	3,3236	3,3927	3,1442	3,2327
4%	4,9952	4,8160	4,6884	4,5970	4,6280	4,2986	4,3619
5%	5,0000	5,0017	5,0000	5,0000	5,0114	5,0000	5,0114
6%	5,0045	5,1815	5,2786	5,3533	5,3668	5,5974	5,6111
7%	5,4732	6,0039	6,4786	6,5384	6,5608	6,6885	6,7110
8%	9,6706	9,1418	8,4010	8,3330	8,3695	8,1626	8,1989
9%	9,9978	9,8608	9,6901	9,6047	9,6507	9,3287	9,3745
10%	10,0000	10,0142	10,0000	10,0000	10,0484	10,0000	10,0484
11%	10,0044	10,1837	10,2794	10,3560	10,4052	10,5981	10,6473
12%	10,4692	11,0008	11,4817	11,5418	11,5945	11,6894	11,7421
13%	14,6658	14,1372	13,4043	13,3321	13,3904	13,1624	13,2207
14%	14,9977	14,8615	14,6910	14,6016	14,6637	14,3272	14,3892
15%	15,0001	15,0206	15,0000	15,0000	15,0630	15,0000	15,0630
16%	15,0059	15,2023	15,2798	15,3516	15,4078	15,5621	15,6496
17%	15,5327	16,0596	16,4833	16,5386	16,5172	16,6632	16,6603
18%	19,6808	19,1515	18,4059	18,3366	18,1766	18,1816	17,9985
19%	19,9977	19,8519	19,6914	19,6063	19,3636	19,3601	19,0808
20%	20,0000	19,9765	20,0000	20,0000	19,7507	20,0000	19,7507

Algumas observações devem ser levadas em consideração, comparando a falta identificada pelo SIF do tipo-2 e função de pertinência triangular, com o SIF do tipo-2 e

função de pertinência gaussiana nota-se que o valor identificado da porcentagem do número de espiras em curto-circuito para o primeiro caso se aproxima mais do valor real, tanto para faltas incipientes (entre 0 e 5%) quanto para os demais valores de falta. Já com a introdução de AG para otimização do SIF do tipo-2 com função de pertinência triangular, nota-se que para o caso em que a otimização é feita somente no RT, o erro de diagnóstico para os valores de centro das funções de pertinência deixa de ser nulo, e o erro só diminui em 50% dos casos quando comparado com o SIF do tipo-2 sem otimização. Para o caso de otimização da FOU, os resultados representaram uma redução do erro de identificação, visto que a falta identificada se aproximou da falta real em todos os casos quando comparado com o SIF do tipo-2 sem otimização, e quando comparado com SIF do tipo-2 com otimização do RT, apenas no valor de 18% do número de espiras esse último se apresentou melhor que o primeiro. E por fim, quando associada a otimização do RT com a da FOU, e comparada com os SIF do tipo-2 com otimização da FOU, as melhoras só foram significativas para os valores intermediários aos centros das funções de pertinência, e mesmo assim não foram observadas em todos os casos.

5.6 Conclusão

A metodologia apresentada neste trabalho apresentou boa aplicabilidade para esse tipo de falta, porém algumas melhorias, com o objetivo de reduzir ainda mais o erro de diagnóstico podem ser propostas. No próximo Capítulo será feita uma análise geral das técnicas e dos resultados obtidos e sugestões para aplicação de algumas destas propostas.

6 CONCLUSÃO

Neste trabalho apresentou-se uma metodologia capaz de detectar e identificar faltas incipientes em sistemas industriais. Para o caso específico desse trabalho, as técnicas propostas foram experimentadas em motores trifásicos de indução, um tipo de motor de grande aplicação industrial.

A falta aplicada na planta foi do tipo curto-circuito parcial nas espiras do enrolamento do estator. Para a detecção da falta foi utilizado método baseado em estimação paramétrica recursiva, com os parâmetros obtidos correspondendo aos parâmetros do modelo ARX da função de transferência discreta de primeira ordem do sistema. No processo de estimação foram inseridos na entrada do algoritmo do MQR, os valores de tensão e corrente eficazes para as situações de 0% (sem falta incipiente), 5%, 10%, 15% ou até 20% das espiras em curto-circuito, e parâmetros a e b para as respectivas condições de entrada foram também obtidos; como era de esperar os parâmetros também sofreram variações no comportamento assim que se aumentava a intensidade da falta aplicada, isso porque, com a propagação do curto-circuito entre as espiras, altera-se o ponto de operação do sistema e conseqüentemente sua dinâmica, logo espera-se variações paramétricas.

Ainda com relação ao comportamento dos parâmetros, observou pelos gráficos das Figuras 5.11 e 5.12 que, enquanto o parâmetro a diminuía tornando-se mais negativo com o aumento da intensidade da falta, o parâmetro b aumentava, justificando a análise paramétrica para detecção da falta. Cabe ressaltar que, em sistemas de ordem superior, nem todos os parâmetros sofreriam uma evidente variação em seus valores quando a planta fosse submetida a um único tipo de falta, como é o caso, de tal forma que, para uma condição de multi-faltas, há a possibilidade de criar um sistema que localize a falta justamente por essa diferença de sensibilidade (variação) nos parâmetros.

Para identificação da falta foram testadas algumas estratégias utilizando-se sistemas *fuzzy*, primeiramente a dúvida partiu da necessidade da escolha da forma da função de pertinência que iria fornecer um menor erro de diagnóstico, desse modo foram utilizados sistemas *fuzzy* tipo-1 e sistemas *fuzzy* tipo-2, ambos com funções de pertinência gaussianas e triangulares, observou-se que, a falta estimada para conjuntos *fuzzy* com funções de pertinência triangulares se aproximava mais da falta real quando comparado com funções de pertinência gaussianas, Figura 5.15, e conseqüentemente o erro de diagnóstico era menor, Figura 5.16, o que descartou o uso da forma gaussiana para representação das funções de pertinências no caso proposto nesse trabalho.

A utilização de SIF intervalar do tipo-2 para diagnóstico de faltas foi proposta com a justificativa de que, por considerar uma região de incerteza denominada de FOU, então ruídos inerentes a sistemas reais, e erros numéricos provenientes do processo de estimação paramétrica no processo de identificação de sistemas seriam computados, em vista disso esperava-se um menor erro de diagnóstico quando utilizássemos esse tipo de ferramenta em detrimento de conjuntos *fuzzy* ordinários, conjunto *fuzzy* tipo-1.

Os resultados gráficos, Figuras 5.15, 5.16, 5.17 e 5.18, fundamentam com valores matemáticos as vantagens da técnica proposta, analisando a Figura 5.17 destaca-se que o erro de diagnóstico da falta para SIF intervalar do tipo-2, foi menor quando comparado com sistemas *fuzzy* tipo-1 em termos do erro médio quadrático (MSE), Figura 5.18. O valor do MSE para SIF tipo-1 é de 0,2723, enquanto que para SIF intervalar tipo-2 esse valor cai para 0,2096, isso significa uma redução de 23,02% do MSE. Essa redução fica ainda mais significativa quando se utiliza AG's para otimizar as incertezas dos SIF do tipo-2 propostas nesse trabalho, ora o redutor de tipo (RT), ora a FOU, e posteriormente ambos (não simultaneamente).

Considerando a otimização das incertezas do RT, a função objetivo a ser minimizada, o MSE, é igual a 0,1914, comparando com o SIF do tipo-2 sem otimização, isso significa uma redução do MSE de 8,68%; utilizando novamente o otimizador com base em AG's para otimizar, agora, a FOU, o valor do MSE obtido é igual a 0,07254, o que corresponde a uma redução de 60,67% do valor do MSE quando comparado com SIF do tipo-2 com o RT otimizado; e por fim, quando o RT e a FOU são ambos otimizados, o MSE assume valor igual a 0,06811, comparando com o SIF do tipo-2 com somente a FOU otimizada, o MSE reduziu 9,50%; de um modo geral a metodologia adotada nesse trabalho reduziu o erro de diagnóstico de sistemas *fuzzy* tipo-1, correspondente ao erro médio quadrático, em 74,98%, e o erro de diagnóstico de sistemas *fuzzy* tipo-2 sem otimizador, em 67,50%, resultados considerados satisfatórios, o que torna promissor estudos envolvendo essa metodologia para o desenvolvimento de um sistema de diagnóstico de faltas incipientes que forneça menores erros de identificação.

E por fim, são previstas melhorias na metodologia apresentada nesse trabalho, como por exemplo, não se utilizar conjunto *fuzzy* intervalar do tipo-2, o que significa não considerar a função de pertinência secundária com distribuição uniforme, isso equivaleria a atribuir “pesos” as funções de pertinência secundárias distribuídas sobre a FOU, o que seria mais um ponto passível de aplicação de AG para que valores mais “adequados” dos “pesos” fossem obtidos e permitissem reduzir ainda mais o erro de diagnóstico; outras considerações que

poderiam ser feitas ainda com o objetivo de reduzir o erro de diagnóstico, é a otimização da base de regras e do defuzzificador, que podem também ser alternativas para fornecer uma estimativa mais exata da falta. Trabalhando com sistemas de ordem superior e com multi-faltas aumentaríamos a problemática do sistema o que nos permitiria, além de detectar e identificar a intensidade da falta, estipular sua localização com base no comportamento paramétrico, e assim um sistema de diagnóstico de faltas mais completo poderia ser projetado.

REFERÊNCIAS BIBLIOGRÁFICAS

- AGUIRRE, L. A. **Introdução à Identificação de Sistemas: Técnicas Lineares e Não - Lineares Aplicadas a Sistemas Reais**. 3ª. ed. Belo Horizonte: Editora UFMG, 2007. 730 p.
- BERENJI, H. R. **Treatment of Uncertainty in Artificial Intelligence**, Machine Intelligence and Autonomy Aerospace Systems. Washington, DC, American Institute of Aeronautics and Astronautics AIAA, pp. 233-247, 1988.
- CAMPOS, M. M. de; SAITO, K. **Sistemas Inteligentes em Controle e Automação de Processos**. Rio de Janeiro: Editora Ciência Moderna Ltda., 2004.
- CHOW, M-Y. **Methodologies of Using Neural Networks and Fuzzy Logic Technologies for Motor Incipient Fault Detection**. World Scientific Publishing Co. Pte. Ltd., 1997.
- COELHO, A. A. R.; COELHO, L. dos S. **Identificação de Sistemas Dinâmicos Lineares**. Florianópolis: Editora da UFSC, 2004. 181 p.
- FITZGERALD, A. E.; KINGSLEY JUNIOR, C.; UMANS, S. D. **Electric Machinery**. 6th ed. New York: McGraw-Hill Companies, 2003.
- GERTLER, J. J. **Fault Detection and Diagnosis in Engineering Systems**. New York: Marcel Dekker, 1998. 484p.
- GOLDBERG, D. E. **Genetic algorithms in search, optimization, and machine learning: Artificial Intelligence**. Illustrated, reprint, London: Addison-Wesley, 1989. 412 p.
- HOLLAND, J. H. **Adaptation in Natural and Artificial Systems**. 2nd edition, The MIT Press Cambridge, MA, USA, 1992.
- ISERMANN, R. **Fault-Diagnosis Systems: An Introduction from Fault Detection to Fault Tolerance**. Germany: Springer-Verlag Berlin Heidelberg, 2006.
- KARNIK N. N.; MENDEL, J. M. **Type-2 Fuzzy Logic Systems: Type-Reduction**. The 1998 IEEE International Conference on Systems, Man, and Cybernetics, San Diego, CA, USA, Vol.2, pp. 2046-2051, October 1998.
- KARNIK N. N.; MENDEL J. M.; LIANG Q. **Type-2 Fuzzy Logic Systems**. IEEE Transactions on *Fuzzy System*, v. 7, pp. 327-348, December 1999.
- KLIR, G. J.; WIERMAN, M. J. **Uncertainty-Based Information**. Physica-Verlag, Heidelberg, Germany, 1998.
- KRAUSE, P. C.; WASYNCZUK, O.; SUDHOFF, S. D. **Analysis of Electric Machinery and Drive Systems**. 2nd ed. Wiley India Pvt. Limited, 2010. 632p.
- MENDEL, J. M. **Uncertain Rule-Based Fuzzy Logic Systems: Introduction and New Directions**, Ed. Prentice Hall, USA, 2000.
- MENDEL, J. M. **Type-2 Fuzzy Sets: Some Questions and Answers**, IEEE Connections, Newsletter of The IEEE Neural Networks Society, Vol. 1, pp., 10-13, August 2003.

MENDEL, J. M.; JOHN, R. I. **Type-2 Fuzzy Sets Made Simple**. IEEE Trans. on *Fuzzy Systems*, vol. 10, pp. 117–127, April 2002.

ONG, C.-M. **Dynamic Simulation of Electric Machinery: Using MATLAB/SIMULINK**. Prentice Hall, 1998. 626 p.

PACHECO, M. A. C. Texto - **Algoritmos Genéticos: Princípios e Aplicações**. 1º Ed. PUC do Rio de Janeiro, 1999. Disponível em: <http://www.ica.ele.puc-rio.br/Downloads/38/CE-Apostila-Comp-Evol.pdf> Acesso em: 2 dez. 2012.

PATTON, R. J.; FRANK P. M.; CLARK R.N. **Issues of Fault Diagnosis for Dynamic Systems**. Great Britain: Springer-Verlag London Limited, 2000.

PIMENTA, A. H. de M. **Geração Genética de Classificador Fuzzy Intervalar do Tipo-2**. 2009. 91 f. Dissertação (Mestrado) - Curso de Programa de Pós-Graduação em Ciência da Computação, Universidade Federal de São Carlos, São Paulo, 2009.

ROCHA, E. M.; MARANHÃO, G. N. A.; BARRA JR., W.; BARREIROS, J. A. L. **Avaliador Fuzzy Tipo-2 para Detecção e Diagnóstico de Falhas Elétricas do Tipo Curto-circuito Parcial nas Espiras do Enrolamento do Estator de um Motor de Indução**. In: 10th IEEE/ IAS International Conference on Industry Applications - 10th INDUSCON, 2012, Fortaleza - CE. 10th IEEE/ IAS International Conference on Industry Applications - INDUSCON, 2012. p. 48-48.

SHAW, I. S.; SIMÕES, M. G. **Model-based Fault Diagnosis in Dynamic Systems Using Identification Techniques**. São Paulo: Editora Edgard Blucher Ltda em co-edição com FAPESP, 1999. 165 p.

SILVA, D. R. C. **Sistemas de Detecção e Isolamento de Falhas em Sistemas Dinâmicos Baseados em Identificação Paramétrica**. 2008. 115 f. Tese (Doutorado) - Curso de Programa de Pós Graduação em Engenharia Elétrica, Departamento de Engenharia Elétrica, Universidade Federal do Rio Grande do Norte, Natal, 2008.

SIMANI, S.; FANTUZZI, C.; PATTON, R. J. **Model-based Fault Diagnosis in Dynamic Systems Using Identification Techniques**. London: Springer, 2003. 284 p.

THE MATHWORKS, Inc. (2007), Student Version Installation of MATLAB 7.5.0.342 (R2007b) and Simulink 7.0 for Windows.

ZADEH, L. A. **Fuzzy Sets**. *Information and Control*, v. 3, pp. 338-353, 1965.

ZADEH, L. A. **The Concept of a Linguistic Variable and Its Application to Approximate Reasoning-I**. *Information Sciences*, v.8, pp. 199 – 249, 1975.

Os seguintes artigos foram publicados pelo discente durante o mestrado:

- **ROCHA, E. M.;** MARANHÃO, G. N. A.; BARRA JR., W. Detecção de Falhas Incipiente em Enrolamentos de Estator de Motores Trifásicos de Indução, utilizando-se Estimacão Paramétrica. In: VII Seminário Nacional de Controle e Automação (SNCA), 2011, Salvador - BA. VII Seminário Nacional de Controle e Automação, Elétrica e de Telecomunicações., 2011.
- **ROCHA, E. M.;** MARANHÃO, G. N. A.; BARRA JR., W.; COSTA JR., C. T.; BARREIROS, J. A. L.. Desenvolvimento de um Sistema *Fuzzy* para a Identificação de Falhas Incipientes em Enrolamento de Estator de Motores Trifásicos de Indução.. In: IV Simpósio Brasileiro de Sistemas Elétricos (SBSE), 2012, Goiânia - GO. Simpósio Brasileiro de Sistemas Elétricos - SBSE, 2012. v.1. p.42-42.
- **ROCHA, E. M.;** BARRA JR., W. ; COSTA JR., C. T.; BARREIROS, J. A. L.; VIEIRA JR., P.. Desenvolvimento de um Sistema Baseado em Identificação Paramétrica para Detecção e Diagnóstico de Falhas Incipientes em Enrolamento de Estator de Motores Trifásicos de Indução. In: Encontro Nacional de Máquinas Rotativas (ENAM), 2012, Angra dos Reis - RJ. V Encontro Nacional de Máquinas Rotativas - V ENAM, 2012.
- **ROCHA, E. M.;** MARANHÃO, G. N. A.; BARRA JR., W. ; BARREIROS, J. A. L. Avaliador *Fuzzy* Tipo-2 para Detecção e Diagnóstico de Falhas Elétricas do Tipo Curto-circuito Parcial nas Espiras do Enrolamento do Estator de um Motor de Indução. In: 10th IEEE/ IAS International Conference on Industry Applications - 10th INDUSCON, 2012, Fortaleza - CE. 10th IEEE/ IAS International Conference on Industry Applications - INDUSCON, 2012. p. 48-48.

APÊNDICES

APÊNDICE A

Programa para gerar funções de pertinência gaussianas

```

% Universidade Federal do Pará
% Instituto de Tecnologia
% Programa de Pós Graduação em Engenharia Elétrica
% Erick Melo Rocha
% Algoritmo para Geração de Funções de Pertinência Gaussianas

clear
clc

load('C:\Users\Erick\Documents\TCC_Artigo_Erick\Simulador_Artigo\Dissertação
o_Erick\Mestrado_Erick\Fuzzy_tipo2\Com_Falta_Comportado\casos_de_falta.mat'
)

P=[mean(abs(a0(2000:10000))),mean(abs(a1(2000:10000))),mean(abs(a2(2000:100
00))),mean(abs(a3(2000:10000))),mean(abs(a4(2000:10000))),mean(abs(a5(2000:
10000))),mean(abs(a6(2000:10000))),mean(abs(a7(2000:10000))),mean(abs(a8(20
00:10000))),mean(abs(a9(2000:10000))),mean(abs(a10(2000:10000))),mean(abs(a
11(2000:10000))),mean(abs(a12(2000:10000))),mean(abs(a13(2000:10000))),mean
(abs(a14(2000:10000))),mean(abs(a15(2000:10000))),mean(abs(a16(2000:10000)
)),mean(abs(a17(2000:10000))),mean(abs(a18(2000:10000))),mean(abs(a19(2000:1
0000))),mean(abs(a20(2000:10000)));mean(b0(2000:10000)),mean(b1(2000:10000
)),mean(b2(2000:10000)),mean(b3(2000:10000)),mean(b4(2000:10000)),mean(b5(20
00:10000)),mean(b6(2000:10000)),mean(b7(2000:10000)),mean(b8(2000:10000)),m
ean(b9(2000:10000)),mean(b10(2000:10000)),mean(b11(2000:10000)),mean(b12(20
00:10000)),mean(b13(2000:10000)),mean(b14(2000:10000)),mean(b15(2000:10000
)),mean(b16(2000:10000)),mean(b17(2000:10000)),mean(b18(2000:10000)),mean(b1
9(2000:10000)),mean(b20(2000:10000))];

X1a=P(1,1);
X2a=P(1,6);
X3a=P(1,11);
X4a=P(1,16);
X5a=P(1,21);

X1b=P(2,1);
X2b=P(2,6);
X3b=P(2,11);
X4b=P(2,16);
X5b=P(2,21);

d1a=(X5a-X1a)/14;
d2a=(X3a-X1a)/7;
d3a=(X4a-X2a)/7;
d4a=(X5a-X3a)/7;
d5a=(X5a-X1a)/14;

FALTA_ESTIMADA=0;

for i=1:length(P);

Xta=P(1,i);

```

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% PARÂMETRO "a"
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

%INCERTEZA NA DISPERSÃO

ida=0.6; % incerteza na dispersão de "a"

MF1adU(i)=exp(-0.5*((Xta-(X1a))/d1a)^2)
MF1adL(i)=exp(-0.5*((Xta-(X1a))/d1a*(ida))^2)

MF2adU(i)=exp(-0.5*((Xta-(X2a))/d2a)^2)
MF2adL(i)=exp(-0.5*((Xta-(X2a))/d2a*(ida))^2)

MF3adU(i)=exp(-0.5*((Xta-(X3a))/d3a)^2)
MF3adL(i)=exp(-0.5*((Xta-(X3a))/d3a*(ida))^2)

MF4adU(i)=exp(-0.5*((Xta-(X4a))/d4a)^2)
MF4adL(i)=exp(-0.5*((Xta-(X4a))/d4a*(ida))^2)

MF5adU(i)=exp(-0.5*((Xta-(X5a))/d5a)^2)
MF5adL(i)=exp(-0.5*((Xta-(X5a))/d5a*(ida))^2)

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%PARÂMETRO "b"
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

Xtb=P(2,i);

d1b=(X5b-X1b)/16;
d2b=(X3b-X1b)/7;
d3b=(X4b-X2b)/7;
d4b=(X5b-X3b)/7;
d5b=(X5b-X1b)/11;

%INCERTEZA NA DISPERSÃO

idb=0.6 % incerteza na dispersão de "b"

MF1bdU(i)=exp(-0.5*((Xtb-(X1b))/d1b)^2)
MF1bdL(i)=exp(-0.5*((Xtb-(X1b))/d1b*(idb))^2)

MF2bdU(i)=exp(-0.5*((Xtb-(X2b))/d2b)^2)
MF2bdL(i)=exp(-0.5*((Xtb-(X2b))/d2b*(idb))^2)

MF3bdU(i)=exp(-0.5*((Xtb-(X3b))/d3b)^2)
MF3bdL(i)=exp(-0.5*((Xtb-(X3b))/d3b*(idb))^2)

MF4bdU(i)=exp(-0.5*((Xtb-(X4b))/d4b)^2)
MF4bdL(i)=exp(-0.5*((Xtb-(X4b))/d4b*(idb))^2)

MF5bdU(i)=exp(-0.5*((Xtb-(X5b))/d5b)^2)
MF5bdL(i)=exp(-0.5*((Xtb-(X5b))/d5b*(idb))^2)

end
g=[0:1:20];

```

```
i=length(P);
pa=P(1,i);
pb=P(2,i);

subplot(2,1,1)
plot(pa,MF1adU,'k',pa,MF1adL,'k',pa,MF2adU,'b',pa,MF2adL,'b',pa,MF3adU,'g',
pa,MF3adL,'g',pa,MF4adU,'y',pa,MF4adL,'y',pa,MF5adU,'r',pa,MF5adL,'r')
subplot(2,1,2)
plot(pb,MF1bdU,'k',pb,MF1bdL,'k',pb,MF2bdU,'b',pb,MF2bdL,'b',pb,MF3bdU,'g',
pb,MF3bdL,'g',pb,MF4bdU,'y',pb,MF4bdL,'y',pb,MF5bdU,'r',pb,MF5bdL,'r')
```

APÊNDICE B

Programa para gerar funções de pertinência Triangulares

```

% Universidade Federal do Pará
% Instituto de Tecnologia
% Programa de Pós Graduação em Engenharia Elétrica
% Erick Melo Rocha
% Algoritmo para Geração de Funções de Pertinência Triangulares

clear
clc

load('C:\Users\Erick\Documents\TCC_Artigo_Erick\Simulador_Artigo\Dissertação_Erick\Mestrado_Erick\Fuzzy_tipo2\Com_Falta_Comportado\casos_de_falta.mat'
)

P=[mean(abs(a0(2000:10000))),mean(abs(a1(2000:10000))),mean(abs(a2(2000:10000))),mean(abs(a3(2000:10000))),mean(abs(a4(2000:10000))),mean(abs(a5(2000:10000))),mean(abs(a6(2000:10000))),mean(abs(a7(2000:10000))),mean(abs(a8(2000:10000))),mean(abs(a9(2000:10000))),mean(abs(a10(2000:10000))),mean(abs(a11(2000:10000))),mean(abs(a12(2000:10000))),mean(abs(a13(2000:10000))),mean(abs(a14(2000:10000))),mean(abs(a15(2000:10000))),mean(abs(a16(2000:10000))),mean(abs(a17(2000:10000))),mean(abs(a18(2000:10000))),mean(abs(a19(2000:10000))),mean(abs(a20(2000:10000)));mean(b0(2000:10000)),mean(b1(2000:10000)),mean(b2(2000:10000)),mean(b3(2000:10000)),mean(b4(2000:10000)),mean(b5(2000:10000)),mean(b6(2000:10000)),mean(b7(2000:10000)),mean(b8(2000:10000)),mean(b9(2000:10000)),mean(b10(2000:10000)),mean(b11(2000:10000)),mean(b12(2000:10000)),mean(b13(2000:10000)),mean(b14(2000:10000)),mean(b15(2000:10000)),mean(b16(2000:10000)),mean(b17(2000:10000)),mean(b18(2000:10000)),mean(b19(2000:10000)),mean(b20(2000:10000))];

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% PARÂMETRO "a"
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

i=1:length(P)
pa=P(1,i)

X1a=P(1,1);
X2a=P(1,6);
X3a=P(1,11);
X4a=P(1,16);
X5a=P(1,21);

imaU=0.001; %Coeficiente da incerteza na base
imbU=0.01; %Coeficiente da incerteza na base
imaL=0.001; %Coeficiente da incerteza na base
imbL=0.01; %Coeficiente da incerteza na base
gU=1; %Coeficiente da incerteza na altura
hU=1; %Coeficiente da incerteza na altura
gL=1; %Coeficiente da incerteza na altura
hL=1; %Coeficiente da incerteza na altura

```

```
%FUZZY TIPO-2 Incerteza na Base
%Parâmetro "a" UPPER e LOWER
```

```
y1amU=trimf(pa, [X1a X1a X2a+(X2a*imaU)])
y2amU=trimf(pa, [X1a-(X1a*imaU) X2a X3a+(X3a*imaU)])
y3amU=trimf(pa, [X2a-(X2a*imaU) X3a X4a+(X4a*imaU)])
y4amU=trimf(pa, [X3a-(X3a*imaU) X4a X5a+(X5a*imaU)])
y5amU=trimf(pa, [X4a-(X4a*imaU) X5a X5a])
```

```
y1amL=trimf(pa, [X1a X1a X2a-(X2a*imaL)])
y2amL=trimf(pa, [X1a+(X1a*imaL) X2a X3a-(X3a*imaL)])
y3amL=trimf(pa, [X2a+(X2a*imaL) X3a X4a-(X4a*imaL)])
y4amL=trimf(pa, [X3a+(X3a*imaL) X4a X5a-(X5a*imaL)])
y5amL=trimf(pa, [X4a+(X4a*imaL) X5a X5a])
```

```
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% PARÂMETRO "b"
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
```

```
i=1:length(P)
pb=P(2,i)
```

```
X1b=P(2,1);
X2b=P(2,6);
X3b=P(2,11);
X4b=P(2,16);
X5b=P(2,21);
```

```
%FUZZY TIPO-2 Incerteza na Base
%Parâmetro "b" UPPER e LOWER
```

```
y1bmU=trimf(pb, [X1b X1b X2b+(X2b*imbU)])
y2bmU=trimf(pb, [X1b-(X1b*imbU) X2b X3b+(X3b*imbU)])
y3bmU=trimf(pb, [X2b-(X2b*imbU) X3b X4b+(X4b*imbU)])
y4bmU=trimf(pb, [X3b-(X3b*imbU) X4b X5b+(X5b*imbU)])
y5bmU=trimf(pb, [X4b-(X4b*imbU) X5b X5b])
```

```
y1bmL=trimf(pb, [X1b X1b X2b-(X2b*imbL)])
y2bmL=trimf(pb, [X1b+(X1b*imbL) X2b X3b-(X3b*imbL)])
y3bmL=trimf(pb, [X2b+(X2b*imbL) X3b X4b-(X4b*imbL)])
y4bmL=trimf(pb, [X3b+(X3b*imbL) X4b X5b-(X5b*imbL)])
y5bmL=trimf(pb, [X4b+(X4b*imbL) X5b X5b])
```

```
subplot(2,1,1)
```

```
plot(pa, y1amL, 'k', pa, y1amU, 'k', pa, y2amL, 'b', pa, y2amU, 'b', pa, y3amL, 'g', pa, y3amU, 'g', pa, y4amL, 'y', pa, y4amU, 'y', pa, y5amL, 'r', pa, y5amU, 'r')
```

```
subplot(2,1,2)
```

```
plot(pb, y1bmL, 'k', pb, y1bmU, 'k', pb, y2bmL, 'b', pb, y2bmU, 'b', pb, y3bmL, 'g', pb, y3bmU, 'g', pb, y4bmL, 'y', pb, y4bmU, 'y', pb, y5bmL, 'r', pb, y5bmU, 'r')
```