

Ana Paula Lima dos Santos

DETECÇÃO DE FALHA EM MOTORES DE INDUÇÃO TRIFÁSICOS POR MEIO DE MODELOS IDENTIFICADOS APLICADOS NA ESTIMAÇÃO RECURSIVA DE PARÂMETROS

São João del-Rei 2014



Ana Paula Lima dos Santos

DETECÇÃO DE FALHA EM MOTORES DE INDUÇÃO TRIFÁSICOS POR MEIO DE MODELOS IDENTIFICADOS APLICADOS NA ESTIMAÇÃO RECURSIVA DE PARÂMETROS

Dissertação apresentada à banca examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica, associação ampla entre a Universidade Federal de São João del-Rei e o Centro Federal de Educação Tecnológica de Minas Gerais, como parte dos requisitos necessários à obtenção do grau de Mestre em Engenharia Elétrica

Orientador: Prof. Dr. Márcio Falcão Santos Barroso

Coorientadora: Prof.ª Dr. ª Lane Maria Rabelo Baccarini

São João del-Rei 2014

Dedico este trabalho aos meus queridos pais, Maria Aparecida e José Tarcísio.

AGRADECIMENTOS

A DEUS, por sempre guiar meus passos.

Aos meus pais, Maria Aparecida e José Tarcísio, por todo o amor, apoio, ensinamentos e sacrifícios exercidos. Tudo o que sou hoje devo a vocês!

Ao meu namorado Gustavo, por todo amor, carinho e compreensão nos momentos de dificuldades. Obrigada por tudo!

Ao Billy, por ser um anjinho na minha vida!

Aos meus orientadores Márcio e Lane, pela amizade e confiança empregadas ao longo destes anos. Obrigada por me inserirem no campo científico e por todos os conhecimentos e ensinamentos transmitidos.

À amiga Lívia, pela valiosa contribuição na coleta dos dados deste trabalho.

Aos amigos que fiz durante a graduação e mestrado, os quais farão sempre parte da minha vida!

Ao PPGEL pela oportunidade concedida, à CAPES, ao CNPQ e à FAPEMIG pelo apoio financeiro ao longo dos anos.

"Não é preciso entrar para a História para fazer um mundo melhor."

Mahatma Gandhi

RESUMO

O motor de indução possui grande participação nas plantas industriais, no entanto, apesar de ser uma máquina robusta, falhas podem ocorrer durante a sua operação. Devido à severidade, rápida evolução e grande porcentagem de ocorrência da falha de curto-circuito nas espiras do estator, essa será foco de estudo deste trabalho. O objetivo é desenvolver um método de detecção inicial de falha de curto-circuito, envolvendo poucas espiras, antes da evolução da falha e consequente perda do motor. A metodologia proposta baseia-se na identificação de modelos dinâmicos representativos da operação normal do MIT. A estrutura do modelo identificado será utilizada na estimação recursiva de parâmetros, a qual atualiza os valores dos parâmetros a cada período de amostragem e pode ser aplicada para detecção em tempo real das condições de operação do motor. Serão testados modelos lineares e não lineares, para se comparar a eficácia na detecção da falha de modelos com complexidades distintas, diante da situação de variação de carregamento do motor. Para a avaliação da metodologia, a estimação recursiva será realizada com dados experimentais reais, os quais são as correntes e as tensões, informações essas obtidas de sensores facilmente encontrados em uma planta industrial. Os resultados apresentados sugerem que é possível detectar falhas de curto-circuito incipientes de forma não invasiva através de modelos dinâmicos não lineares aplicados na estimação recursiva de parâmetros, utilizando-se informação auxiliar para agregar maior representatividade ao modelo.

Palavras-chave: Motor de Indução Trifásico, Diagnóstico de Falhas, Identificação de Sistemas, Modelos Dinâmicos, Estimação Recursiva de Parâmetros.

ABSTRACT

The induction motor has a large application in industrial plants, however, despite being a robust machine, faults can occur during operation. Due to the severity, rapid development and high percentage of occurrence of short circuit fault in the stator windings, this study will focus on this work. The objective is to develop a method for initial detection of a short circuit fault involving few turns, before the evolution of the failure and consequent loss of the engine. The proposed method is based on the identification of dynamic models representative of normal operation of the MIT. The structure of the identified model will be used in the recursive parameter estimation, which updates the parameter values for each sampling period and can be applied to real-time detection of the operating conditions of the engine. Linear and nonlinear models will be tested in order to compare the effectiveness of the failure detection of models with different complexities, before the situation changes in engine load. For the evaluation methodology, the recursive estimation will be performed with actual experimental data, which are the currents and voltages, information obtained from sensors easily found in an industrial plant. The results suggest that it is possible to detect incipient short-circuit fault noninvasively through nonlinear dynamical models applied in the recursive parameter estimation using auxiliary information to aggregate the most representative model.

Keywords: Induction Motor Three Phase, Fault Diagnosis, Identification Systems, Dynamic Models, Recursive Estimation of Parameters.

SUMÁRIO

Lista de Tabelas Lista de Figuras Lista de Símbolos Lista de Abreviações	X Xii XV XVii
	711
1. INTRUDUÇAU	1
1.2 Estado do Arto	ו כ
1.2 Estado da Arte	25
1.4 Estrutura da Dissertação.	5
2. IDENTIFICAÇÃO DE SISTEMAS	7
2.1 Introdução	7
2.2 Identificação de Sistemas	8
2.3 Experimentação	8
2.4 Detecção de Não Linearidades.	10
2.5 Representações para Sistemas Não Lineares.	10
2.6 Modelos NARX.	12
2.7 Detecção de Estrutura.	13
2.7.1 Taxa de Redução de Erro.	14
	14
2.6 Agrupamentos de Termos.	10
2.9 POILOS FIXOS EITI SISTEMAS AUTOHOMOS	10
2.9.1 FUIILOS FIXOS EITI SISTEMAS NAU AUTOMOS	10
2.10 Estimação de Parâmetros	17
2 11 1 O Estimados de Mínimos Quadrados (MQ)	18
2 11 2 O Estimador de Mínimos Quadrados (MQ).	19
2 12 Validação do Modelo	20
2.13 Atualização Recursiva de Parâmetros.	21
2.13.1 O Estimador Recursivo de Mínimos Quadrados com	
Fator de Esquecimento.	23
2.14 Conclusões do Capítulo	23
3. O MOTOR DE INDUÇÃO TRIFÁSICO	25
3.1 Introdução	25
3.2 Modelo Simétrico do MIT	27
3.3 Modelo Assimétrico do MIT	30
3.4 Aquisição dos dados.	32
3.4.1 Coleta de dados simulados para a identificação	32
3.4.2 Coleta de dados experimentais para detecção do curto-	~ -
	35
3.5 Conclusões do Capitulo.	- 38

4. DETECÇÃO DE CURTO-CIRCUITO EM MOTORES DE INDUÇÃO TRIFÁSICOS ATRAVÉS DE MODELO LINEAR IDENTIFICADO APLICADO NA ESTIMAÇÃO RECURSIVA DE PARÂMETROS	39
4.1 Introdução	39
4.2 Modelo Linear do MIT estimado em batelada	41
4.3 Detecção de curto-circuito inicial no MIT através da Estimação	
recursiva de Parâmetros utilizando modelo linear.	46
4.3.1 Curto-Circuito em cerca de 1.5% das espiras do	
enrolamento de uma fase do estator do MIT.	47
4.3.2 Curto-Circuito em cerca de 3% das espiras do	
enrolamento de uma fase do estator do MIT	53
4 4 Análise Estatística dos parâmetros estimados recursivamente	56
4 5 Conclusões do Canítulo	59
	00
5. DETECÇÃO DE CURTO-CIRCUITO EM MOTORES DE INDUÇÃO TRIFÁSICOS ATRAVÉS DE MODELO NÃO LINEAR IDENTIFICADO	
APLICADO NA ESTIMAÇÃO RECURSIVA DE PARAMETROS	61
5.1 Introdução	61
5.2 Modelo Não Linear do MIT estimado em batelada.	62
5.3 Estimação de Não Linearidades Estáticas.	66
5.4 Detecção de curto-circuito inicial no MII através da Estimação	
recursiva de Parâmetros utilizando modelo não linear.	67
5.4.1 Curto-Circuito em cerca de 1,5% das espiras do	
enrolamento de uma fase do estator do MIT	67
5.4.2 Curto-Circuito em cerca de 3% das espiras do	
enrolamento de uma fase do estator do MIT	73
5.5 Análise Estatística dos parâmetros estimados recursivamente	77
5.6 Influência do Ganho Estático na Detecção da Falha	80
5.7 Detecção do curto-circuito através do acompanhamento das	
correntes e tensões das fases sem falha do MIT	81
5.7.1 Detecção do curto-circuito em 1,5% das espiras	
utilizando os dados das fases $b \in c$	82
5.7.2 Detecção do curto-circuito em 3% das espiras utilizando	
os dados das fases b e c	83
5.8 Conclusões do Capítulo.	85
6. CONCLUSÕES	87
6.1 Considerações Gerais.	87
6.2 Trabalhos Futuros.	88
• · · · ·	
REFERENCIAS BIBLIOGRAFICAS	90

LISTA DE TABELAS

Parâmetros do circuito equivalente do MIT utilizados nos testes, obtidos através de ensaios à vazio e rotor travado, em conformidade com a Norma	22
Valores de média e variância dos parâmetros estimados recursivamente para os 7 ensaios realizados. Curto-circuito em 1.5% das espiras e	33
$\lambda = 0.999$	49
Valores de média e variância dos parâmetros estimados recursivamente	
para os 7 ensaios realizados. Variação de carga e $\lambda = 0,999$ Valores de média e variância dos parâmetros estimados recursivamente	50
para os 7 ensaios realizados. Curto-circuito em 1,5% das espiras e	50
$\lambda = 0.9993$	50
valores de media e valiancia dos parametros estimados recursivamente para os 7 ensaios realizados. Variação de carga e $\lambda = 0.9993$	50
Valores de média e variância dos parâmetros estimados recursivamente	00
para os 7 ensaios realizados. Curto-circuito em 3% das espiras e $\lambda = 0.999$.	53
Valores de média e variância dos parâmetros estimados recursivamente	
para os 7 ensaios realizados. Curto-circuito em 3% das espiras e $\lambda = 0.9993$.	55
Valores de média e variância dos parâmetros estimados recursivamente	
para os 7 ensaios realizados. Curto-circuito em 1,5% das espiras e	
$\lambda = 0,9993.$	68
Valores de média e variancia dos parametros estimados recursivamente	60
Valores de média e variância dos parâmetros estimados recursivamente	00
para os 7 ensaios realizados. Curto-circuito em 1.5% das espiras e $\lambda = 1$.	70
Valores de média e variância dos parâmetros estimados recursivamente	-
para os 7 ensaios realizados. Variação de carga e $\lambda = 1. \dots \dots \dots$	72
Valores de média e variância dos parâmetros estimados recursivamente	
para os <i>i</i> ensaios realizados. Curto-circuito em 3% das espiras e $\lambda = 0.0002$	71
Valores de média e variância dos parâmetros estimados recursivamente	14
para os 7 ensaios realizados. Curto-circuito em 3% das espiras e $\lambda = 1,$	75
	Parâmetros do circuito equivalente do MIT utilizados nos testes, obtidos através de ensaios à vazio e rotor travado, em conformidade com a Norma NBR 5363

LISTA DE FIGURAS

3.1	Representação de um enrolamento trifásico do estator de uma máquina de indução, na qual n_{sa2} representa o número de espiras em curto-	
3.2	Diagrama em blocos que representa a simulação do modelo simétrico de MIT o obtenção dos dados dinâmicos do entrada o saída do	30
	identificação	23
2 2	Autocorrelação do sinal de entrada $u(k)$	33
3.4	Dados dinâmicos de identificação e validação. Dados dinâmicos de identificação (amostras $0:821$) e dados de validação (amostras $822:1641$), sendo: (a) sinal de entrada do sistema, tensão de fase; (b) sinal de saída do sistema corrente de fase. Fonte: elaboração própria	34
35	Autocorrelação não linear do sinal de saída. Fonte: elaboração própria.	35
3.6	Bancada de testes experimentais Fonte: arquivo próprio	36
3.7	Dados coletados do ensaio de 1.5% das espiras em curto. (a) Tensão	
	de fase. (b) Corrente de fase. Fonte: elaboração própria.	37
3.8	Dados coletados do ensaio de 3% das espiras em curto. (a) Tensão de	
	fase. (b) Corrente de fase. Fonte: elaboração própria.	37
3.9	Dados coletados do ensaio de variação de carga. (a) Tensão de fase.	
	(b) Corrente de fase. Fonte: elaboração própria	38
4.1	Diagrama em blocos que representa a detecção da estrutura do modelo	
	dinâmico do MIT e a estimação de parâmetros em batelada	40
4.2		42
4.3	Validação dinamica do modelo, infinitos passos a frente. (-) Dados	40
л л	Validação. $()$ Simulação IIVIE. Fonte. elaboração propria	42
4.4	validação estatística para o modelo intear, eq. (4.1). (a) $T_{ee}(D) T_{ue}(C)$	13
4.5	Histograma com as distribuições de frequências dos parâmetros (a) θ_{i}	70
1.0	(b) θ_2 e (c) θ_3 . (-, vermelho) Parâmetros do MIT com operação normal. (-, preto) Parâmetros do MIT operando com curto-circuito em 3% das espiras. Dados simulados. Estimação em batelada. Fonte: elaboração	
	própria	45
4.6	Diagrama em blocos do processo de estimação recursiva de	
	parâmetros e detecção de falha de curto-circuito.	46
4.7	Variação temporal dos parâmetros detectada pelo estimador recursivo	
	com $\lambda = 0.999$. (a), (c) e (e) MII passa da operação normal para a	
	operação com curto-circuito em 1,5% das espiras. (b), (d) e (f) variação	10
10	Veriação temporal des perâmetros (vermelho) Curto sirevito em	48
4.0	1,5% das espiras. (-, azul) Variação de carga. $\lambda = 0,999$. (a) θ_1 , (b) θ_2 e	40
10	(c) θ_3 . Fonte: elaboração propria	49
4.9	com $\lambda = 0.9993$. (a), (c) e (e) MIT passa da operação normal para a operação com curto-circuito em 1,5% das espiras. (b), (d) e (f) Variação	
	de carga. Fonte: elaboração própria.	51

4.10	Variação temporal dos parâmetros. (-, vermelho) Curto-circuito em	
	1,5% das espiras. (-, azul) Variação de carga. $\lambda = 0,9993$. (a) θ_1 , (b) θ_2	
	e (c) θ_3 . Fonte: elaboração própria	52
4.11	Variação temporal dos parâmetros causada pelo curto-circuito em 3%	
	das espiras detectada pelo estimador recursivo com $\lambda = 0,999$. (a) θ_1 ,	
	(b) θ_2 e (c) θ_3 . Fonte: elaboração própria	54
4.12	Variação temporal dos parâmetros. (-, vermelho) Curto-circuito em 3%	
	das espiras. (-, azul) Variação de carga. $\lambda = 0,999$. (a) θ_1 , (b) θ_2 e (c)	
	θ_2 . Fonte: elaboração própria	54
4.13	Variação temporal dos parâmetros causada pelo curto-circuito em 3%	
	das espiras detectada pelo estimador recursivo com $\lambda = 0.9993$. (a) θ_1 .	
	(b) θ_2 e (c) θ_2 . Fonte: elaboração própria	55
4.14	Variação temporal dos parâmetros. (–. vermelho) Curto-circuito em 3%	
	das espiras. (-, azul) Variação de carga, $\lambda = 0.9993$. (a) θ_1 . (b) θ_2 e (c)	
	θ_2 Fonte: elaboração própria	56
4.15	Histograma das distribuições de frequências dos parâmetros. (a) θ_{1} . (b)	
	θ_2 e (c) θ_2 (- cinza) Parâmetros do MIT com operação normal (-	
	preto) Parâmetros do MIT operando com curto-circuito em 1.5% das	
	espiras, $\lambda = 0.9993$. Dados experimentais reais. Estimação recursiva.	
	Fonte: elaboração própria	57
4.16	Histograma das distribuições de freguências dos parâmetros. (a) θ_1 . (b)	-
	θ_2 e (c) θ_2 . (cinza) Parâmetros do MIT com operação normal. (
	preto) Parâmetros do MIT operando com curto-circuito em 3% das	
	espiras. $\lambda = 0.9993$. Dados experimentais reais. Estimação recursiva.	
	Fonte: elaboração própria	58
4.17	Histograma das distribuições de frequências dos parâmetros, (a) θ_1 , (b)	
	θ_2 e (c) θ_3 . (-, cinza) Parâmetros do MIT operando com $I = 4,12A$. (-,	
	preto) Parâmetros do MIT operando com $I = 6,1A$. $\lambda = 0,9993$. Dados	
	experimentais reais. Estimação Recursiva. Fonte: elaboração própria.	59
5.1	Critério de Akaike.	62
5.2	Validação dinâmica do modelo, infinitos passos à frente. (-) Dados	
	validação. (– –) Simulação livre. Fonte: elaboração própria	63
5.3	Validação estatística para o modelo não linear, eq. (5.1). (a) r_{ee} (b) r_{ue} (c)	
	$r_{e(eu)}$ (d) r_{u^2e} (e) $r_{u^2e^2}$	64
5.4	Histograma com as distribuições de frequências dos parâmetros, (a) θ_1 ,	
	(b) θ_2 , (c) θ_3 e (d) θ_4 . (-, vermelho) Parâmetros do MIT com operação	
	normal. (-, preto) Parâmetros do MIT operando com curto-circuito em	
	3% das espiras. Dados simulados. Estimação batelada. Fonte:	
	elaboração própria.	65
5.5	Variação temporal dos parâmetros detectada pelo estimador recursivo	
	com $\lambda = 0,9993$. (a), (c), (e) e (g) MIT passa da operação normal para a	
	operação com curto-circuito em 1,5% das espiras. (b), (d), (f) e (h)	
	Variação de carga. Fonte: elaboração própria.	69
5.6	Variação temporal dos parâmetros. (-, vermelho) Curto-circuito em	
	1,5% das espiras. (-, azul) Variação de carga. $\lambda = 0,9993$. (a) θ_1 , (b) θ_2 ,	
	(c) θ_3 e (d) θ_4 . Fonte: elaboração própria	70
5.7	Variação temporal dos parâmetros detectada pelo estimador recursivo	

	com $\lambda = 1$. (a), (c), (e) e (g) MIT passa da operação normal para a	
	operação com curto-circuito em 1,5% das espiras. (b), (d), (f) e (h)	
	Variação de carga. Fonte: elaboração própria	71
5.8	Variação temporal dos parâmetros. (-, vermelho) Curto-circuito em	
	1,5% das espiras. (-, azul) Variação de carga. $\lambda = 1$. (a) θ_1 , (b) θ_2 , (c)	
	θ_3 e (d) θ_4 . Fonte: elaboração própria	72
5.9	Variação temporal dos parâmetros detectada pelo estimador recursivo	
	$com \lambda = 0.9993$. (a), (c), (e) e (g) MIT passa da operação normal para a	
	operação com curto-circuito em 3% das espiras. (b), (d), (f) e (h)	
	Variação de carga. Fonte: elaboração própria.	74
5.10	Variação temporal dos parâmetros. (-, vermelho) Curto-circuito em 3%	
	das espiras. (-, azul) Variação de carga. $\lambda = 0.9993$. (a) θ_1 , (b) θ_2 , (c)	
	θ_3 e (d) θ_4 . Fonte: elaboração própria.	75
5.11	Variação temporal dos parâmetros detectada pelo estimador recursivo	
	causada pelo curto-circuito em 3% das espiras, $\lambda = 1$. (a) θ_1 , (b) θ_2 , (c)	
	θ_3 e (d) θ_4 . Fonte: elaboração própria	76
5.12	Variação temporal dos parâmetros. (-, vermelho) Curto-circuito em 3%	
	das espiras. (-, azul) Variação de carga. $\lambda = 1$. (a) θ_1 , (b) θ_2 , (c) θ_3 e (d)	
	θ_4 . Fonte: elaboração própria	76
5.13	Histograma das distribuições de frequências dos parâmetros, (a) θ_1 , (b)	
	θ_2 , (c) θ_3 e (d) θ_4 . (-, cinza) Parâmetros do MIT com operação normal.	
	(-, preto) Parâmetros do MIT operando com curto-circuito em 1,5% das	
	espiras. $\lambda = 1$. Dados experimentais reais. Estimação recursiva. Fonte:	
	elaboração própria.	78
5.14	Histograma das distribuições de frequências dos parâmetros, (a) θ_1 , (b)	
	θ_2 , (c) θ_3 e (d) θ_4 . (–, cinza) Parâmetros do MIT com operação normal.	
	(-, preto) Parâmetros do MIT operando com curto-circuito em 3% das	
	espiras. $\lambda = 1$. Dados experimentais reais. Estimação recursiva. Fonte:	
- 4 -		79
5.15	Histograma das distribuições de frequencias dos parametros, (a) θ_1 , (b)	
	θ_2 , (c) θ_3 e (d) θ_4 . (-, cinza) Parametros do MIT operando com $I = 1.24$ (-, proto) Derêmetros de MIT esperando com L (14, -)	
	4,12A. (-, preto) Parametros do Mili operando com $I = 6,1A$. $\lambda = 1$.	70
E 1C	Variação tomporal dos parâmetros (varmelho) Curto sircuito em	79
5.10	vanação temporar dos parametros. ($-$, vermemo) cuno-circuito em 1.5% das ospiras ($-$ azul) Variação do carga $\lambda = 1$ (a) A_{-} (b) A_{-} (c)	
	1,5% das espiras. (-, azur) variação de carga. $\pi = 1$. (a) v_1 , (b) v_2 , (c)	80
5 1 7	$V_3 \in (0) V_4$. For the elaboração propria	00
5.17	vanação temporar dos parametros. ($-$, vermemo) curto-circuito em 5% das espiras ($-$ azul) Variação de carga $\lambda = 1$ (a) A (b) A (c) A e (d)	
	θ Fonte: elaboração própria	81
5 18	Variação temporal dos parâmetros (- vermelho) Curto-circuito em	01
0.10	15% das espiras (- azul) Variação de carga $\lambda = 1$ (a) θ_{1} (b) θ_{2} (c)	
	$\theta_{2} = (d) \theta_{1}$. Fonte: elaboração própria	82
5 19	Variação temporal dos parâmetros (- vermelho) Curto-circuito em	02
0.10	15% das espiras (- azul) Variação de carga $\lambda = 1$ (a) θ_{c} (b) θ_{c} (c)	
	θ_2 e (d) θ_4 Fonte: elaboração própria	83
5.20	Variação temporal dos parâmetros (- vermelho) Curto-circuito em 3%	
	das espiras (- azul) Variação de carga $\lambda = 1$ (a) θ_1 (b) θ_2 (c) θ_2 e (d)	
	$ = (\alpha, \sigma_1, \alpha, \sigma_2, \alpha, \sigma_3, \sigma_4, \sigma_5, \sigma_2, \sigma_3, \sigma_4, \sigma_5, \sigma_5, \sigma_5, \sigma_5, \sigma_5, \sigma_5, \sigma_5, \sigma_5$	

	θ_4 . Fonte: elaboração própria	84
5.21	Variação temporal dos parâmetros. (-, vermelho) Curto-circuito em 3%	
	das espiras. (-, azul) Variação de carga. $\lambda = 1$. (a) θ_1 , (b) θ_2 , (c) θ_3 e (d)	
	θ_4 . Fonte: elaboração própria	84

LISTA DE SÍMBOLOS

$\phi_{\mathcal{Y}'\mathcal{Y}'}$	Função de Autocorrelação linear
$\phi_{y^{2'}y^{2'}}$	Função de Autocorrelação não linear
<i>E</i> [.]	Esperança Matemática
$ au_m$	Atraso da função de autocorrelação
T_s	Tempo de Amostragem
F^{ℓ}	Função genérica com grau de não linearidade ℓ
u(k-i)	Regressor de Entrada
y(k-j)	Regressor de Saída
e(k)	Incerteza Matemática
$\xi(k)$	Erro de Modelagem
n_y	Máximo atraso do regressor de saída
n_u	Máximo atraso do regressor de entrada
n_e	Máximo atraso do regressor de ruído
n_p	Número de termos de processo
d	Atraso puro de tempo
k	Tempo discreto
$\widehat{oldsymbol{ heta}}$	Vetor de parâmetros estimados
var.	Variância matemática
g_i	Parâmetro ortogonal
ω_i	Regressor ortogonal
J	Função custo genérica
Ψ	Matriz de Regressores
ν	Ruído branco
Σ_0	Termo constante
$\Sigma_{\mathcal{Y}} \overline{\mathcal{Y}}$	Termos lineares em y
$\Sigma_u \overline{u}$	Termos lineares em <i>u</i>
\widehat{K}	Ganho estático estimado

v(k-i) Vetor de ruído em um modelo NAR	MAX
--	-----

- *c_i* Parâmetros de ruído em um modelo NARMAX
- Ψ^* Matriz de regressores estendida
- θ^* Vetor de Parâmetros Estendidos
- *K_k* Matriz de ganho de Kalman
- P_k Matriz de covariância do vetor de parâmetros
- λ Fator de Esquecimento

LISTA DE ABREVIAÇÕES

MIT	Motor de Indução Trifásico				
ERR	Taxa de Redução de Erro				
AIC	Critério de Informação de Akaike				
MQ	Mínimos Quadrados Convencionais				
MQE	Mínimos Quadrados Estendidos				
NARMAX	Modelos Não Lineares Autorregressivos com Média Móvel e				
	Entrada Exógena				
NARX	Modelos Não Lineares Autorregressivos com Entrada Exógena				
ARMAX	Modelos Lineares Autorregressivos com Média Móvel e				
	Entrada Exógena				
ARX	Modelos Lineares Autorregressivos com Entrada Exógena				
RMSE	Raiz do Erro Médio Quadrático				

Capítulo 1

INTRODUÇÂO

1.1 Considerações Gerais

Os motores de indução trifásicos e monofásicos são as máquinas rotativas mais utilizadas atualmente, sendo responsáveis por aproximadamente 95% do total de motores instalados (MASSIRER, 2007). Suas características operacionais garantem confiabilidade, robustez, simplicidade de construção e baixo custo.

A importância dos motores de indução nas plantas industriais torna a confiabilidade da operação dessas máquinas um ponto crítico, devido aos altos custos de uma parada no processo produtivo, os quais podem representar de 15% a 40% do custo total de muitos produtos (BACCARINI, 2005).

Técnicas de manutenção preditiva permitem a detecção e até o diagnóstico de falhas que podem ocorrer na operação de equipamentos industriais. Dessa forma, o investimento em técnicas de manutenção mais eficientes evita eventuais paradas na produção, perdas de material, redução na qualidade e até mesmo acidentes envolvendo humanos (D'ÂNGELO et al., 2011).

Uma vez que é economicamente inviável manter máquinas sobressalentes, o monitoramento *on-line* das máquinas de indução é importante para uma operação segura e qualidade da produção (BACCARINI; MENEZES; CAMINHAS, 2010). O objetivo é interpretar precocemente a falha incipiente e definir um correto diagnóstico, para que não ocorra uma manutenção não programada e uma parada no processo produtivo e até mesmo a perda da máquina (SANTOS; SILVA; SUETAKE, 2012).

Para um bom diagnóstico, é necessário uma monitoração contínua e alarme rápido frente à ocorrência de uma falha (BACCARINI, 2005). Monitorar regularmente as condições de operação das máquinas e do seu rendimento, garantindo maior intervalo entre os reparos, é premissa da manutenção preditiva. Segundo Almeida (2010), um levantamento realizado pela *Plant Performance Group* (uma divisão da *Technology for Energy Corporation*) apresenta os impactos proporcionados pela inclusão da manutenção preditiva como parte da filosofia de manutenção em

1

indústrias. Dentre os resultados, podem-se destacar: redução de 50 a 80% nos custos de manutenção e redução de 50 a 60% nas falhas das máquinas.

1.2 Estado da Arte

Buscando minimizar os custos de manutenção, muitas técnicas têm sido implementadas para monitorar as condições de trabalho de motores de indução e diagnosticar falhas, aumentando o grau de confiabilidade e a vida útil do motor.

A redução do número de falhas e o gerenciamento de suas severidades garantem disponibilidade e confiabilidade das máquinas de indução, os quais fornecem, como benefício adicional, o aumento da segurança da planta (AZEVEDO; SOUZA; MARTINS, 2005).

Dentre os fatores que afetam o comportamento do motor, pode-se agrupá-los em problemas de origem magnética ou elétrica e problemas de origem mecânica. As falhas podem ser internas: barras quebradas e/ou trincadas, rolamentos danificados, curto-circuito entre espiras, excentricidade, desalinhamento, desbalanceamento de massa; ou externas: sobrecarga mecânica, desequilíbrio de fases, subtensão, sobretensão e presença de harmônicos (LAMIM FILHO, 2008).

De acordo com Thomson e Fenger (2001), os percentuais de falhas relacionados aos componentes dos motores de indução são de aproximadamente: 38% no estator, 10% no rotor, 40% nos rolamentos e 12% nos demais.

A exposição do MIT a uma ampla variedade de ambientes e ciclos de operações sujeita o enrolamento de estator às tensões induzidas por uma variedade de fatores, que incluem picos térmicos de sobrecarga, vibrações e picos de tensão, os quais podem causar deterioração do isolamento, propiciando a falha entre espiras, geralmente, envolvendo poucas voltas do enrolamento. No entanto, a falha de curto-circuito entre espiras possui evolução muito rápida e, se mantida essa situação, pode evoluir para uma falta para a terra, o que resultaria em danos irreversíveis ao núcleo da máquina (BOQIANG; HEMING; LILING, 2003).

Existem métodos diversificados para a detecção de falhas em motores de indução trifásicos, dentre os quais se destacam: análise do espectro de corrente, análise de vibração, análise térmica, análise de emissão acústica e análise química.

A análise de vibração tem sido usada por equipes da área de manutenção para detecção e diagnóstico de falhas em motores devido às suas potencialidades. No entanto, de acordo com Ye, Wu e Sadeghian (2003), a tarefa de distinguir as situações de falhas da situação normal de operação usando o espectro da FFT (Transformada Rápida de Fourier) é difícil.

O diagnóstico da falha de curto-circuito entre espiras, contudo, não é uma tarefa trivial, pois deve ser detectada no estágio inicial, ou seja, como uma falta incipiente, pois, dessa forma, o impacto sobre as demais características do motor é menor (BOQIANG; HEMING; LILING, 2003).

Atualmente, diversas técnicas são utilizadas para a detecção de curto-circuito nas espiras do estator, na área de manutenção preditiva, porém muitas delas se mostram de elevado custo/benefício, ineficazes ou mesmo de difícil aplicação em processos reais (AVELAR; BACCARINI; AMARAL, 2011). A detecção da baixa isolação, segundo Brito et al. (2012), pode ser realizada através de testes, como o teste de corrente contínua, o megômetro e o teste de impulso aplicado em motores (*Surge Test*), os quais necessitam do desligamento do motor para serem realizados.

Nos últimos anos, técnicas de inteligência artificial, como Redes Neurais Artificiais, Máquinas de Vetores Suporte, Lógica fuzzy, e outras, têm sido largamente utilizadas e possibilitam uma forma mais prática de análise, sendo, em muitos casos, desnecessária a ajuda de especialistas de manutenção (BRITO et al., 2012). Tais técnicas, juntamente com as análises espectrais das tensões e correntes, podem ser utilizadas no diagnóstico das falhas de motores de indução.

Um procedimento de diagnóstico ideal deve ter o mínimo de medições necessárias de uma máquina e extrair, por análise, informações do seu estado, indicando de forma clara as falhas incipientes em um tempo mínimo (Bellini et al., 2008). A resposta deve ser rápida quando ocorrem avarias no processo. No entanto, resposta rápida e desempenho tolerável durante a operação normal são duas metas conflitantes em sistemas de diagnóstico (WILLSKY, 1976).

O impacto de alguns tipos de falhas pode ser mascarado por ruídos e por mudanças nas condições de operação do acionamento. Além disso, desequilíbrios entre as tensões do sistema de alimentação do motor, que são inerentes a uma planta industrial, podem mascarar o sistema de diagnóstico de falhas de curtocircuito, provocando falso alarme ou a não detecção inicial da falha (GONÇALVES JÚNIOR, 2013).

Considerando os métodos não invasivos e que não necessitam do desligamento do motor, sistemas de diagnóstico de falhas têm sido desenvolvidos com base em modelos determinísticos. Nesse contexto, modelos matemáticos de sistemas dinâmicos permitem, dentre as diversas possibilidades, a detecção de falhas no sistema (MATKO; KARBA; ZUPANCIC, 1994). Tais modelos são capazes de considerar diferentes condições de operação e tipos de falhas (BELLINI et al., 2008).

Diferentes métodos de detecção de falhas baseados em modelos matemáticos foram desenvolvidos nas últimas décadas: Willsky (1976); Himmelblau (1978); Isermann (1984); Frank (1990); Gertler (1998); Chen e Patton (1999); Patton, Frank e Clark (2000); Isermann (2005). Por meio de sinais de entrada e saída da planta, os métodos de detecção baseados em modelos matemáticos geram resíduos, estimativas de parâmetros, estimativas de estados, entre outros, os quais são utilizados para realizar a comparação entre operação normal e operação com falha.

Os parâmetros aparecem no modelo matemático que representa a relação entre os sinais de entrada e saída da planta. À medida que os parâmetros são fisicamente definidos por coeficientes do processo (da planta), como rigidez, coeficientes de amortecimento, viscosidade, resistividade, entre outros, mudanças nesses coeficientes determinarão variações nos parâmetros do modelo, o que poderá ser utilizado para a detecção de falhas (ISERMANN, 1992).

Métodos de estimação de parâmetros de modelos adaptativos, que são aqueles em que apenas a estrutura do modelo é conhecida, são especialmente adequados para a detecção de falhas (ISERMANN, 2005). Portanto, os sistemas variantes no tempo, como os sistemas com falha, constituem uma forte razão para a utilização, na prática, de métodos recursivos de identificação, porque é necessário que o algoritmo de estimação acompanhe a variação temporal dos parâmetros (LEITE, 2004).

Neste trabalho, o algoritmo recursivo compõe o instrumento virtual, o qual se trata de um *software* que utiliza sinais medidos a fim de construir sinais de interesse,

no caso, os valores dos parâmetros do modelo dinâmico identificado ao longo do tempo. Instrumentos virtuais são muito úteis na substituição de sensores físicos e na detecção de falhas (HEREDIA; HOLLERO, 2010). Tal procedimento torna a detecção menos invasiva.

1.3 Objetivos

O presente trabalho considera o seguinte problema: de posse dos dados dinâmicos de entrada e saída de um Motor de Indução Trifásico e do uso de informação auxiliar, deseja-se identificar um modelo NARX polinomial que represente a característica de operação normal do MIT em diferentes pontos de operação. Ou seja, deseja-se que o modelo represente dinamicamente o MIT e, ao mesmo tempo, que informação auxiliar sobre a característica estática do sistema possa ser obtida, ajustando-se o ganho do modelo.

A informação auxiliar pode ser utilizada para estimar a curva estática a partir de dados dinâmicos, utilizando o conceito de agrupamento de termos. A identificação de modelos dinâmicos permite que a estrutura do modelo seja aplicada na estimação recursiva de parâmetros, a qual atualiza os valores dos parâmetros a cada período de amostragem. Neste trabalho, atualiza, também, a curva estática, ajustando o ganho do modelo a cada ponto de operação da máquina. A variação temporal dos parâmetros do modelo será utilizada para detectar a situação de falha incipiente no MIT.

1.4 Estrutura da Dissertação

Este trabalho apresenta de forma gradual os conceitos teóricos para a posterior compreensão dos resultados práticos apresentados.

No Capítulo 2 é realizada uma revisão bibliográfica, contendo de forma resumida e geral os conceitos da identificação de sistemas, em particular aplicada aos modelos NARX polinomiais.

O Capítulo 3 proporciona ao leitor os conceitos relacionados aos motores trifásicos de indução, modelos simétrico e assimétrico; a descrição da bancada de testes e, ainda, os aspectos relativos aos procedimentos de experimentação.

No Capítulo 4 são encontrados os resultados obtidos com a aplicação da estrutura de um modelo linear ARX na estimação recursiva de parâmetros. Foram testados diferentes pontos de operação do motor e falhas de curto-circuito em cerca de 1,5% e 3% das espiras de uma das fases do enrolamento do estator.

O Capítulo 5 apresenta os resultados obtidos com a aplicação da estrutura de um modelo não linear NARX polinomial, com ganho variável, na estimação recursiva de parâmetros considerando as mesmas condições analisadas no Capítulo 4.

No capítulo 6 são apresentadas as conclusões, considerações finais e principais contribuições deste trabalho e algumas propostas para futuras pesquisas e trabalhos.

Capítulo 2

IDENTIFICAÇÃO DE SISTEMAS

2.1 Introdução

Para se entender o comportamento de determinado sistema, é necessário o conhecimento de suas variáveis, bem como a maneira pela qual elas se relacionam. Dessa forma, é essencial a obtenção de um modelo para representar o sistema em questão (LJUNG, 1999). Dentre os diversos tipos de modelos, podem-se citar os modelos físicos, os mentais, os gráficos e os matemáticos ou analíticos.

A modelagem matemática, como ferramenta para a reprodução do comportamento aproximado de fenômenos físicos, vem se destacando nas últimas décadas (BARROSO, 2006). Modelos matemáticos de sistemas dinâmicos permitem analisar e predizer o comportamento do sistema e, ainda, ajustar o desempenho dele, caso os resultados obtidos não sejam satisfatórios (CASSINI, 1999).

Segundo Leite (2004), existem basicamente duas formas de se construir modelos matemáticos, analítica ou experimentalmente, ou seja, a modelagem matemática e a identificação de sistemas.

A modelagem matemática, pela física do processo, envolve um conjunto de parâmetros que contém significado físico, os quais são obtidos através do desenvolvimento das equações que regem a física do processo do sistema em estudo. No entanto, muitas vezes, os processos são tão complexos que a utilização das leis físicas para descrevê-los torna-se pouco atraente (POTTMANN; PEARSON, 1998), principalmente quando os valores dos parâmetros variam com o tempo.

A identificação de sistemas, por outro lado, é uma abordagem experimental, que consiste na utilização de dados, aos quais é ajustado um modelo matemático representativo, com parâmetros sem significado físico. Não exige conhecimento prévio, embora tal conhecimento possa ser utilizado, se disponível (CASSINI, 1999). A baixa complexidade dos modelos identificados e o reduzido número de parâmetros a serem estimados facilitam a estimação dos parâmetros em tempo real.

7

2.2 Identificação de Sistemas

A identificação de um sistema é realizada através dos dados de entrada, u(k), e dados de saída, y(k), desse sistema. A identificação se propõe a obter um modelo matemático que explique as características de interesse, ou seja, a relação de causa e efeito presente nos dados.

O modelador deve analisar quais variáveis do sistema são relevantes para a modelagem e se a estrutura do modelo escolhida é adequada.

Segundo Ljung (1999), o problema da identificação de sistemas pode ser dividido em cinco etapas:

- obtenção dos dados experimentais do sistema que se deseja modelar;
- aplicação de testes para detecção de não linearidades nos dados;
- escolha da estrutura que representará o sistema;
- estimação dos parâmetros do modelo;
- validação do modelo obtido.

2.3 Experimentação

Muitas vezes, os únicos dados disponíveis são os dados de operação normal do sistema. Em outras situações, será possível e desejável efetuar testes de forma a extrair informação dinâmica deste (AGUIRRE, 2007) ou, ainda, os dados serão obtidos através de simulações.

O procedimento de experimentação consiste na escolha do sinal de entrada do sistema a ser estudado, na escolha da taxa de amostragem e na coleta de dados, os quais deverão ser utilizados na detecção de não linearidades e na estimação dos parâmetros do modelo escolhido.

É desejável que os sinais de excitação tenham um espectro de frequências que venham a excitar persistentemente a dinâmica de interesse do sistema (BARROSO, 2001). Essa etapa é de extrema importância, uma vez que os resultados posteriores dependerão da qualidade da informação contida nos dados coletados. Um sinal muito utilizado em identificação de sistemas é o sinal PRBS (Sinal Binário Pseudoaleatório, do inglês *Pseudo Random Binary Signal*), o qual não é um sinal genuinamente aleatório, mas satisfaz à propriedade $r_{uu}(k) \approx 0, \forall k \neq 0$, ou seja, a autocorrelação da entrada é nula para atrasos diferentes de zero, a qual garante que a matriz de covariância de u(k) seja diagonal e traz vantagens numéricas na solução das equações (AGUIRRE, 2007). Acredita-se que esse sinal de excitação seja capaz de excitar o sistema nas mais diferentes componentes de frequências.

O processamento de um sinal em tempo contínuo pode ser realizado através de suas amostras, as quais devem ser coletadas utilizando uma taxa de amostragem que permite a reconstrução, com erro tolerável, do sinal original (LATHI, 2007). A escolha da taxa de amostragem exige critério, pois ela afetará diretamente na estrutura do modelo, na estimação dos parâmetros, ou seja, influencia na qualidade final do modelo (CASSINI, 1999).

Um dos procedimentos utilizados para a escolha da taxa de amostragem dos dados de identificação consiste na utilização da autocorrelação linear $\phi_{y'y'}$ (2.1) e da autocorrelação não linear $\phi_{y^{2'}y^{2'}}$ (2.2) do sinal de saída:

$$\phi_{y'y'} = E[(y(k) - \bar{y}(k))(y(k - \tau) - \bar{y}(k))], \qquad (2.1)$$

$$\phi_{y^{2'}y^{2'}} = E[(y^2(k) - \bar{y}^2(k))(y^2(k - \tau) - \bar{y}^2(k))], \qquad (2.2)$$

em que *E*[.] representa a esperança matemática, $\bar{y} \in \bar{y}^2$ representam os valores médios e o apóstrofo ('), nesse caso, indica que a média foi removida dos dados.

Com base nas funções de correlação acima, a seguinte constante de tempo é definida:

$$\tau_m = \min{\{\tau_{y'}, \tau_{y^{2'}}\}},\tag{2.3}$$

na qual $\tau_{y'}$ é o instante do primeiro mínimo de $\phi_{y'y'}$ e $\tau_{y^{2'}}$ é o instante de primeiro mínimo de $\phi_{y^{2'}y^{2'}}$.

O período de amostragem pode, então, ser determinado através da relação (2.4), (AGUIRRE, 2007):

$$\frac{\tau_m}{25} < T_s < \frac{\tau_m}{5}.\tag{2.4}$$

Dessa forma, se a taxa de amostragem dos dados coletados estiver dentro do período indicado pela equação (2.4), então os dados originais podem ser utilizados. No entanto, se o período de amostragem estiver abaixo do limite inferior, os dados estão superamostrados e devem ser decimados, satisfazendo a equação (2.4). Se a amostragem for realizada com uma taxa acima do limite superior, os dados estão subamostrados e um novo teste deve ser realizado.

2.4 Detecção de Não Linearidades

Um procedimento importante é determinar se os dados de identificação exibem características não lineares. A detecção de não linearidades verifica através da massa de dados, dentro de um limite pré-determinado, se o sistema exibe características não lineares.

A relação abaixo (BILLINGS; VOON, 1986):

$$\phi_{y^{2'}y^{2'}}(\tau) = E\left[(y^2(k) - \bar{y}^2(k))(y^2(k-\tau) - \bar{y}^2(k))\right] = 0 \ \forall \tau$$
(2.5)

é válida se o sistema for linear. Um intervalo delimita a região de confiança dentro da qual a função de correlação pode ser considerada nula. Os limites deste intervalo em 95% são dados por: $\pm 1,96/\sqrt{N}$, em que *N* é o comprimento do registro de dados disponíveis. Se a função de correlação (2.5) tiver resultados fora do intervalo de confiança, o sistema deverá ser representado por um modelo não linear.

2.5 Representações para Sistemas não lineares

Segundo Aguirre (2007), os sistemas dinâmicos encontrados na prática são, em última análise, não lineares. Embora, em certos casos, seja possível representar sistemas com modelos lineares por partes, ou seja, em torno de pontos de operação pré-definidos, em geral, um modelo não linear é mais adequado (AGUIRRE; CORRÊA; CASSINI, 2002), visto que tais modelos produzem certos regimes dinâmicos que os modelos lineares não conseguem representar.

Na modelagem, uma importante questão é a escolha da estrutura que deverá representar o comportamento de um sistema dinâmico. Existem na literatura várias representações matemáticas de sistemas reais. Algumas representações utilizadas na modelagem de sistemas não lineares são: redes neurais (XIE et al., 2013); (VÁŇA; PREISIG, 2012); representações NARX wavelets (MARTINS; NEPOMUCENO; FIGUEIREDO, 2011); modelos de Hammerstein e de Wiener (ABDALLA JÚNIOR et al., 2010; SANTOS et al., 2010); funções de base radial (ZHAO; CHEN; XU, 2009); equações diferenciais polinomiais (GOUESBET; LETELLIER, 1994); séries de Volterra (BILLINGS, 1980); representações NARMAX (CHEN; BILLINGS, 1989).

De acordo com Billings (1980), modelos NARX descrevem sistemas não lineares em equações de diferenças, relacionando a saída atual em combinação das saídas e entradas passadas.

A representação NARX polinomial possui pontos positivos, como o fato de permitir a incorporação de informações que se tem *a priori* do sistema no modelo, como curva e ganho estático, por exemplo, (MARTINS; NEPOMUCENO; FIGUEIREDO, 2011). Tal representação possui capacidade de recuperar a característica estática de um sistema a partir de dados dinâmicos de entrada e saída, resultando em uma relação analítica (AGUIRRE; CORRÊA; CASSINI, 2002). A utilização dessas informações pode acrescentar qualidade ao modelo e maior representatividade.

Na prática, testes para a obtenção de dados de identificação estão amarrados aos limites operacionais do sistema a ser modelado (BARROSO, 2001). Por exemplo, em plantas industriais não é desejável que a produção seja interrompida para se efetuarem testes para coletas de dados. Dessa forma, na maioria das vezes, o sinal de excitação é variado em uma pequena faixa de amplitude e frequência. Estrutura e parâmetros estimados a partir de dados com tais características serão capazes de representar o sistema na faixa de operação dos dados (AGUIRRE; DONOSCO-GARCIA; SANTOS-FILHO, 2000).

A definição da representação NARX polinomial constitui uma tentativa de se obter modelos mais representativos, numa faixa mais ampla de operação do sistema, mesmo que os dados dinâmicos estejam restritos a uma pequena faixa de operação.

2.6 Modelos NARX

Os modelos baseados em equações de diferença constituem uma das mais importantes classes de modelos matemáticos de sistemas lineares ou não lineares. O modelo NARMAX (do inglês, *Nonlinear AutoRegressive Moving Average with eXogenous inputs*), com estrutura monovariável e período de amostragem normalizado, segundo Aguirre (2007), é dado por:

$$y(k) = F^{\ell} \begin{bmatrix} y(k-1), \dots, y(k-n_y), u(k-d), \dots, u(k-d-n_u), \\ e(k-1), \dots, e(k-n_e) \end{bmatrix} + \xi(k),$$
(2.6)

sendo:

$$y(k) = \begin{bmatrix} y_1(k) \\ y_2(k) \\ \vdots \\ \vdots \\ y_m(k) \end{bmatrix}, \qquad u(k) = \begin{bmatrix} u_1(k) \\ u_2(k) \\ \vdots \\ \vdots \\ u_r(k) \end{bmatrix}, \qquad e(k) = \begin{bmatrix} e_1(k) \\ e_2(k) \\ \vdots \\ \vdots \\ e_m(k) \end{bmatrix},$$

em que y(k) é a saída, u(k) é a entrada exógena e e(k) é o sinal de ruído. A constante d é o atraso puro de tempo. $\xi(k)$ representa o erro de predição. n_y , n_u e n_e são os atrasos máximos da saída, entrada e da média móvel, respectivamente.

Um subconjunto do modelo NARMAX que contém apenas a sua parte determinística é denominado modelo NARX (do inglês, *Nonlinear AutoRegressive with eXogenous inputs*) e é representado por:

$$y(k) = F^{\ell}[y(k-1), \dots, y(k-n_y), u(k-d), \dots, u(k-n_u)] + e(k).$$
(2.7)

Neste trabalho, F^{ℓ} representa uma função polinomial não linear, com grau de não linearidade $\ell \in \mathbb{Z}^+$.

As funções não lineares polinomiais são lineares nos parâmetros, o que permite a utilização de algoritmos de estimação de parâmetros para sistemas lineares (CHEN; BILLINGS; LUO, 1989), como os algoritmos de mínimos quadrados.

É esperado que o modelo não somente se ajuste aos dados, mas que ele possa reproduzir, da forma mais aproximada possível, a dinâmica original do sistema.

2.7 Determinação da Estrutura

Um problema importante em identificação de sistemas é a determinação da estrutura do modelo. De acordo com Cassini (1999), modelos com mais termos que o necessário podem provocar efeitos espúrios e até instabilidade numérica. Efeitos espúrios podem, também, ser provocados por sobreparametrização em relação ao número de pontos fixos e à ordem do modelo. No entanto, modelos muito flexíveis causam generalização pobre. Em contrapartida, modelos menores possuem maior velocidade de processamento e simplicidade.

O grau de não linearidade de modelos está diretamente relacionado à dificuldade de determinação de estruturas. Isso pode ser observado, já que a expansão do espaço de busca é dada de modo exponencial, de acordo com o aumento do grau de não linearidade e da ordem máxima dos regressores (MARTINS; NEPOMUCENO; FIGUEIREDO, 2011).

Para evitar mau condicionamento da matriz de regressores, pode ser utilizado o critério de detecção de estrutura denominado ERR (taxa de redução de erro, do inglês *Error Reduction Ratio*) (MENDES; BILLINGS, 2001) e o número de regressores pode ser definido pelo Critério de Informação de Akaike (AKAIKE, 1974). A taxa de redução de erro e o critério de informação são complementares entre si (AGUIRRE, 2007).

2.7.1 Taxa de Redução de Erro

A taxa de redução de erro (ERR) pode ser usada na determinação dos regressores de um modelo. Esse critério baseia-se na redução do erro de predição de um passo à frente, (AGUIRRE, 2007), o qual associa a cada termo candidato um índice correspondente à contribuição na explicação da variância dos dados de saída $\xi(k)$:

$$\operatorname{var}\{\xi(k)\} = \lim_{N \to \infty} \frac{1}{N} \left[\mathbf{y}^T \mathbf{y} - \sum_{i=1}^N g_i^2 \omega_i^T \omega_i \right],$$
(2.8)

em que g_i indica os elementos do vetor de parâmetros g, ω_i indica os regressores ortogonais e y é o vetor contendo os dados de saída.

A cada termo acrescentado, a variância de $\xi(k)$ decresce de um fator igual a $\frac{1}{N}g_i^2\omega_i^T\omega_i$. A redução do valor da variância pode ser normalizada com relação ao erro quadrático médio do sinal de saída. Assim, o ERR de cada termo é definido como sendo:

$$[ERR] = \frac{g_i^2 \omega_i^T \omega_i}{\mathbf{y}^T \mathbf{y}}.$$
(2.9)

O ERR é amplamente utilizado na seleção de estrutura de modelos. Escolhese o número de termos desejados e considerando aqueles que possuírem os maiores valores de ERR (MENDES; BILLINGS, 2001). Esse critério evita mau condicionamento numérico, visto que termos linearmente dependentes e ou irrelevantes são descartados.

2.7.2 Critério de Informação de Akaike

Um procedimento utilizado para determinar o número de termos do modelo é o Critério de Informação de Akaike (AIC). De acordo com esse método, o número de termos do modelo deve minimizar a função custo *J*, apresentada a seguir:

$$J = N \log(var{\xi(k)}) + 2n_{\theta},$$
 (2.10)

sendo que *N* é o número de dados, $var{\xi(k)}$ é a variância do erro de modelagem (erro de predição de um passo à frente ou resíduos) e n_{θ} é o número de parâmetros do modelo. Esse critério estabelece o compromisso entre a qualidade do ajuste de identificação e o número de termos do modelo.

O número de termos determinados a partir do AIC minimiza a variância dos resíduos de identificação, partindo de uma estrutura previamente ajustada por um critério de seleção de estrutura. No entanto, não se pode afirmar que o número de termos selecionados torne o modelo capaz de reproduzir as propriedades dinâmicas do sistema original (AGUIRRE; BILLINGS, 1994). O resultado obtido pelo AIC pode ser visto como uma indicação do número "subótimo" de termos do modelo (NEPOMUCENO, 2002).

2.8 Agrupamentos de Termos

Em regime permanente, as entradas e saídas do modelo NARX polinomial representado pela equação (2.7) podem ser expressas como:

$$y(k-1) = y(k-2) = \dots = y(k-n_y),$$

$$u(k-1) = u(k-2) = \dots = u(k-n_u).$$
(2.11)

Dessa forma, a equação (2.7) pode ser reescrita como (AGUIRRE; BILLINGS, 1995):

$$y(k) = \sum_{n_1, n_m}^{n_y, n_u} c_{p, m-p}(n_1, \dots, n_m) \sum_{m=0}^{\ell} \sum_{p=0}^m y(k-1)^p u(k-1)^{m-p},$$
(2.12)

sendo o conjunto de termos $y(k-1)^{p}u(k-1)^{m-p}$ denominado de agrupamento de termos. As constantes $\sum_{n_1,n_m}^{n_{y,n_u}} c_{p,m-p}(n_1,...,n_m)$ são definidas como coeficientes de agrupamentos de termos. De acordo com Aguirre e Billings (1995), todos os termos pertinentes a um dado agrupamento explicam o mesmo tipo de não linearidade do modelo.

2.9 Pontos Fixos em Sistemas Autônomos

Pontos fixos de sistemas discretos autônomos são pontos de operação que apresentam a seguinte característica (AGUIRRE; CORRÊA; CASSINI, 2002):

$$y(k) = y(k+i), \forall i \in \mathbb{Z}^+.$$
 (2.13)

Sistemas dinâmicos lineares apresentam apenas um ponto fixo trivial. No entanto, em sistemas não lineares, o número de pontos fixos varia de acordo com o grau de não linearidade ℓ do sistema.

Os modelos NARX polinomiais possuem pontos fixos ou pontos de equilíbrio. Nesse contexto, o conceito de agrupamento de termos é adequado para determinar o número de pontos fixos dos modelos, sua localização e simetria. Essa informação será útil na recuperação de características estáticas do sistema original (AGUIRRE, 2007).

2.9.1 Pontos fixos em sistemas não autônomos

Um modelo NARX não autônomo, em estado estacionário e para uma entrada constante, pode ser escrito como:

$$y(k) = \sum_{n_1, n_{m\ell}}^{n_y, n_u} c_{p, m-p}(n_\ell, \dots, n_{m\ell}) \sum_{m\ell=0}^{\ell} \sum_{p=0}^{m\ell} y(k)^p u(k)^{m\ell-p},$$
(2.14)

sendo que $m\ell$ representa o grau de não linearidade de cada termo e está na faixa $1 \le m\ell \le \ell$. Cada termo de grau $m\ell$ pode conter um fator y(k) de ordem p, um fator u(k) de ordem $(m\ell - p)$ e um coeficiente $c_{p,m-p}(n_\ell, ..., n_{m\ell})$.

Pode-se notar que os valores dos pontos fixos dependem dos valores da entrada constante do sistema. Essas equações fazem o mapeamento levando as informações de \bar{u} para \bar{y} , caracterizando uma curva estática.

2.10 Estimação de Não Linearidades Estáticas

Segundo Aguirre, Corrêa e Cassini (2002), o conceito de agrupamento de termos e coeficiente de agrupamento pode ser utilizado para determinar a equação de ganho estático do sistema. Como visto na seção 2.9.1, o modelo NARX polinomial pode ser escrito da seguinte forma:

$$\bar{y} = \Sigma_0 + \Sigma_y \bar{y} + \Sigma_u \bar{u} + \sum_{m=1}^{\ell-1} \sum_{p=1}^{\ell-m} \Sigma_{y^p u^m} \bar{y}^p \bar{u}^m + \sum_{p=2}^{\ell} \Sigma_{y^p} \bar{y}^p + \sum_{m=2}^{\ell} \Sigma_{u^m} \bar{u}^m,$$
(2.15)

em que os termos de processo e seus respectivos parâmetros foram agrupados da seguinte maneira:

- termo constante: Σ_0 ;
- termos lineares em y: $\Sigma_y \overline{y}$;
- termos lineares em u: $\Sigma_u \overline{u}$;
- termos cruzados: $\sum_{m=1}^{\ell-1} \sum_{p=1}^{\ell-m} \Sigma_{y^p u^m} \overline{y}^p \overline{u}^m$;
- termos não lineares em $y: \sum_{i=1}^{\ell} \Sigma_{v^i} \bar{y}^i;$
- termos não lineares em $u: \sum_{i=1}^{\ell} \Sigma_{u^i} \bar{u}^i$.

A equação (2.15) mostra que a determinação da saída estacionária dependerá do valor da entrada estacionária do sistema, caracterizando uma curva estática, a qual pode ser estimada a partir de um modelo dinâmico.

Portanto, o ganho estático pode ser calculado por:

$$\widehat{K}(\bar{y},\bar{u}) = \frac{\bar{y}}{\bar{u}} = \frac{\frac{\Sigma_0}{\bar{u}} + \Sigma_u + \sum_{m=2}^{\ell} \Sigma_{u^m} \bar{u}^{m-1}}{1 - \Sigma_y - \sum_{m=1}^{\ell-1} \sum_{p=1}^{\ell-m} \Sigma_{y^p u^m} \bar{y}^{(p-1)} \bar{u}^m - \sum_{p=2}^{\ell} \Sigma_{y^p} \bar{y}^{(p-1)}}.$$
(2.16)

2.11 Estimação de Parâmetros

Uma vez determinada a estrutura do modelo, torna-se necessário a estimação dos parâmetros, de modo a quantificá-los. Várias técnicas podem ser empregadas,

sendo a técnica de mínimos quadrados (MQ) uma das mais conhecidas e estudadas.

2.11.1 O Estimador de Mínimos Quadrados (MQ)

Para a estimação dos parâmetros de um modelo polinomial como o apresentado na equação (2.7), é necessário que ele seja colocado na forma de regressão linear:

$$y(k) = \psi^T (k-1)\widehat{\boldsymbol{\theta}} + \xi(k), \qquad (2.17)$$

sendo $\psi^T(k-1)$ todos os regressores do modelo, tomados até o instante (k-1), $\hat{\theta}$ é o vetor de parâmetros a ser estimado e $\xi(k)$ são os resíduos de predição de um passo à frente.

Quando o modelo apresentado na equação (2.17) é obtido sobre uma massa de dados finita, ele pode ser expresso na forma matricial, como a seguir:

$$y = \Psi \widehat{\theta} + \xi, \tag{2.18}$$

sendo Ψ a matriz de regressores. O vetor de parâmetros que minimiza a função custo composta pelo erro quadrático de predição é dado por Aguirre (2007):

$$\widehat{\boldsymbol{\theta}}_{\boldsymbol{M}\boldsymbol{O}} = [\boldsymbol{\Psi}^T \boldsymbol{\Psi}]^{-1} \boldsymbol{\Psi}^T \boldsymbol{y}, \qquad (2.19)$$

em que y é o vetor de dados, $[\Psi^T \Psi]$ é a matriz de informação e $[\Psi^T \Psi]^{-1} \Psi^T$ é a matriz pseudoinversa.

Caso os parâmetros obtidos não sejam uma estimativa aproximada dos parâmetros reais do sistema, a estimativa é dita polarizada e os resíduos apresentam alguma dinâmica que não foi devidamente explicada pelo modelo. Matematicamente, tem-se:

$$E[\hat{\theta}_{MQ}] \neq \theta, \tag{2.20}$$

sendo *E* o operador esperança.

Para garantir a não polarização dos parâmetros, eles podem ser estimados utilizando o estimador de Mínimos Quadrados Estendidos (CHEN; BILLINGS; LUO,1989).

2.11.2 Estimador de Mínimos Quadrados Estendidos (MQE)

A polarização no estimador de mínimos quadrados surge do fato de existir correlação no vetor de resíduos e existirem regressores na forma y(k - i) no modelo (BARROSO, 2006). Este fato leva à correlação da matriz de regressores com e(k).

Para evitar esse efeito na estimação de parâmetros, pode-se utilizar o estimador de mínimos quadrados estendidos. Se os resíduos de identificação forem modelados como um processo de média móvel, do tipo:

$$e(k) = c_i v(k-i) + v(k),$$
(2.21)

sendo v(k) ruído branco, os termos v(k - i) podem ser incorporados à matriz de regressores e os seus respectivos parâmetros ao vetor de parâmetros do modelo, da seguinte forma:

$$\mathbf{y}^* = \Psi^* \mathbf{\theta}^* + \mathbf{e}^*, \tag{2.22}$$

em que $y^* = y$ e $e^* = [v(k) ... v(k + N - 1)]^T$,

	Γ	÷	v(k-1)	1
		÷	v(k)	l
$\Psi^* =$	Ψ	÷	v(k+1)	,
		÷	:	l
	L	÷	v(k+N-2)	

e $\theta^* = [\theta : c_i]^T$. Os regressores parametrizados por c_i , como na equação (2.17), foram incluídos na matriz de regressores Ψ^* . Dessa forma, e*, como apresentado na equação (2.21), é do tipo branco e não correlacionado com a matriz de regressores, a qual contém regressores de saída. Portanto, a estimativa (MQE):
$$\widehat{\boldsymbol{\theta}}^* = (\Psi^{*T}\Psi^*)^{-1}\Psi^{*T}\boldsymbol{y}, \qquad (2.23)$$

não apresentaria polarização, ou seja, $E[\boldsymbol{\theta}^*] = [\boldsymbol{\theta} : \boldsymbol{c}]^T$.

Deve-se notar que o ruído é modelado apenas com o intuito de evitar a polarização do modelo NARX polinomial. O modelo deve conter apenas termos de processo e a parte estocástica deve ser desprezada (BARROSO; TAKAHASHI; AGUIRRE, 2007).

2.12 Validação do Modelo

A validação do modelo é a etapa final no processo de identificação. Essa etapa consiste em verificar se o modelo estimado é capaz de recuperar as características de interesse do sistema em questão e se o modelo é não polarizado.

Faz-se necessário, então, o uso de um critério para verificar se o modelo responde às características que lhe são exigidas. Neste trabalho, foram considerados dois aspectos:

- Validação Dinâmica: predição do modelo infinitos passos à frente e índice RMSE (Erro Quadrático Médio, do inglês *Root Mean Square Error*);
- ii. Validação Estatística: uso de funções de correlação.

A validação dinâmica é a comparação do comportamento do sistema e do modelo identificado. A predição de infinitos passos à frente consiste na utilização de um conjunto de dados de validação do sistema, os quais são diferentes dos dados de identificação, e as predições passadas da saída da matriz de regressores. Um modelo polarizado pode ser capaz de predizer a resposta do sistema quando se usa a mesma massa de dados de identificação, mas o mesmo pode não ocorrer para uma massa de dados diferentes (BILLINGS; TAO, 1991).

O índice RMSE pode ser dado por:

$$RMSE = \frac{\sqrt{\sum_{k=1}^{N} (y(k) - \hat{y}(k))^2}}{\sqrt{\sum_{k=1}^{N} (y(k) - \bar{y})^2}},$$
(2.24)

sendo $\hat{y}(k)$ a simulação livre do sinal e \bar{y} o valor médio do sinal medido y(k). Neste trabalho serão considerados bons modelos aqueles que apresentarem índice RMSE menor que a unidade. Isto significa que, em média, o erro apresentado pelo modelo é menor do que o erro apresentado pela média da série temporal.

A validação estatística pode ser realizada por meio da análise dos resíduos, a qual informa se os parâmetros do modelo identificado foram ou não estimados corretamente. Os resíduos são a parte dos dados que o modelo não consegue explicar. Dessa forma, se a função de autocorrelação do vetor de resíduos $\xi(k)$ for nula para todos os valores de atraso maiores ou iguais a um, ou seja, $r_{\xi\xi}(k) = 0, \forall k \neq 0$, os resíduos de identificação são ruído branco (AGUIRRE, 2007). Outros testes são as correlações cruzadas lineares e não lineares, entre os resíduos e os dados de entrada e saída do sistema (LJUNG, 1999). Se os resíduos possuírem alguma correlação, o modelo será considerado polarizado, uma vez que existem evidências de dinâmicas não modeladas contidas nos resíduos.

2.13 Atualização Recursiva de Parâmetros

Enquanto os algoritmos de estimação em batelada processam as amostras da massa de dados simultaneamente, obtendo uma única estimativa dos parâmetros do modelo, os métodos de estimação recursiva processam os dados experimentais sequencialmente, atualizando os parâmetros do modelo a cada período de amostragem (LJUNG, 1999).

Para sistemas invariantes no tempo, tanto a identificação em batelada quanto a recursiva são utilizadas. No entanto, para sistemas variantes no tempo, a identificação recursiva, na maioria dos casos, é mais adequada (CASSINI, 1999).

Nas aplicações *on-line*, pode-se utilizar um algoritmo recursivo para atualizar os valores dos parâmetros de acordo com as variações no sistema, à medida que os dados são disponibilizados (LJUNG, 1999). No caso de sistemas invariantes no

tempo, a atualização recursiva pode ser utilizada para a detecção de falhas (CASSINI, 1999).

Seja um sistema dado por $y(k) = \psi^T \theta + e(k)$, no qual as propriedades estatísticas do ruído são E[e(k)] = 0 e cov[e(k)] = R, sendo $E[\cdot]$ a esperança matemática e $cov[\cdot]$ a covariância. De acordo com Aguirre (2007), um modelo para esse sistema pode ser escrito como na equação (2.17), na qual $\psi(k-1) \in \mathbb{R}^{n_{\theta}}$ é formado na iteração *k* com informação disponível até a iteração k - 1, além disso, a estrutura do vetor de regressores é previamente conhecida.

Na estimação recursiva, o vetor de parâmetros no instante k é expresso como uma combinação linear do seu valor no instante anterior e do valor da medição no instante k. Dessa forma, a nova estimativa do vetor de parâmetros deve conter informação atualizada, obtida da medição y(k) como:

$$\widehat{\boldsymbol{\theta}}_{k} = J_{k} \widehat{\boldsymbol{\theta}}_{k-1} + K_{k} y(k). \tag{2.25}$$

As matrizes J_k e K_k na equação (2.25) devem ser determinadas, garantindo que $\hat{\theta}_k$ seja uma boa estimativa, segundo os seguintes critérios:

- 1. $\hat{\theta}_k$ deve ser não polarizado;
- 2. $cov[\hat{\theta}_k]$ deve ser tão pequena quanto possível.

Considerando as restrições mencionadas acima, é possível derivar um algoritmo recursivo para a estimação do vetor $\hat{\theta}$ (AGUIRRE, 2007):

$$K_k = P_{k-1} \psi_k (\psi_k^T P_{k-1} \psi_k + R)^{-1}, \qquad (2.26)$$

$$\widehat{\boldsymbol{\theta}}_{k} = \widehat{\boldsymbol{\theta}}_{k-1} + K_{k}(y(k) - \boldsymbol{\psi}_{k}^{T}\widehat{\boldsymbol{\theta}}_{k-1}), \qquad (2.27)$$

$$P_{k} = (I - K_{k}\psi_{k}^{T})P_{k-1}(I - K_{k}\psi_{k}^{T})^{T} + K_{k}RK_{k}^{T},$$
(2.28)

em que ψ_k é o vetor de regressores, $\hat{\theta}_k$ é o vetor de parâmetros estimados, K_k é o *ganho de Kalman*, P_k é a matriz de covariância dos parâmetros, $P_k = cov[\hat{\theta}_k]$, e R é a matriz de covariância do ruído, R = cov[e(k)].

2.13.1 O Estimador Recursivo de Mínimos Quadrados com Fator de Esquecimento

O estimador recursivo de mínimos quadrados (RMQ) pondera de forma idêntica os erros cometidos pelo modelo, ou seja, a primeira observação tem o mesmo peso da última.

No entanto, nos sistemas com parâmetros variantes no tempo, os dados mais recentes precisam ser mais influentes na estimação dos parâmetros, pois a informação que eles contêm está mais atualizada. Dessa forma, é necessário ponderar de maneira diferenciada os dados disponíveis (AGUIRRE, 2007). Portanto, é inserida no estimador uma razão entre pesos consecutivos para os dados, o que é conhecido como fator de esquecimento λ (CASSINI, 1999).

A diferença básica do RMQ para o estimador recursivo apresentado na seção anterior está na forma com que a matriz P_k é determinada.

As equações utilizadas para implementar o estimador recursivo de mínimos quadrados com fator de esquecimento são apresentadas a seguir. Maiores detalhes podem ser encontrados em Aguirre (2007):

$$K_k = \frac{P_{k-1}\psi_k}{\psi_k^T P_{k-1}\psi_k + \lambda'},\tag{2.29}$$

$$\widehat{\boldsymbol{\theta}}_{k} = \widehat{\boldsymbol{\theta}}_{k-1} + K_{k} \big[y(k) - \boldsymbol{\psi}_{k}^{T} \widehat{\boldsymbol{\theta}}_{k-1} \big], \qquad (2.30)$$

$$P_{k} = \frac{1}{\lambda} \left(P_{k-1} - \frac{P_{k-1} \psi_{k} \psi_{k}^{T} P_{k-1}}{\psi_{k}^{T} P_{k-1} \psi_{k} + \lambda} \right),$$
(2.31)

em que o fator de esquecimento λ assume valores na faixa $0.95 \le \lambda \le 0.99$.

2.14 Conclusões do Capítulo

O presente capítulo teve como principal objetivo contextualizar o leitor com as principais etapas empregadas na identificação de sistemas, sendo dado um enfoque principal na modelagem por meio de modelos NARX polinomiais. Foi elucidado o conceito de informação auxiliar, exemplificado por meio dos conceitos de pontos fixos e curva estática não linear (ou ganho não linear), utilizados para agregar maior representatividade ao modelo.

Quanto à estimação recursiva de parâmetros, foi apresentada a maneira pela qual a variação temporal nos valores dos parâmetros do modelo dinâmico identificado será atualizada, de forma que os dados mais atuais tenham maior representatividade, através do fator de esquecimento.

Capítulo 3

O MOTOR DE INDUÇÃO TRIFÁSICO

3.1 Introdução

O monitoramento de motores elétricos para detecção e diagnóstico de falhas tem atraído o interesse de pesquisadores, devido a sua considerável influência nos processos industriais. Um diagnóstico correto e uma precoce detecção de falhas incipientes resultam numa manutenção não programada rápida e num curto tempo de inatividade do processo considerado (BELLINI et al., 2008).

As falhas nos enrolamentos de um motor de indução podem ser classificadas em: curto-circuito entre as espiras de uma mesma bobina, curto-circuito entre bobinas de uma mesma fase, curto-circuito entre bobinas de diferentes fases, curtocircuito entre uma fase e o terra e circuito aberto em uma fase (THOMSON; FENGER, 2001).

A falha de curto-circuito entre os enrolamentos de cobre causa um fluxo significativo de corrente na bobina, levando a uma rápida deterioração. A corrente de falta é aproximadamente duas vezes a corrente de rotor bloqueado e provoca aquecimento localizado, que rapidamente se estende para outras seções do enrolamento (TALLAM; HABETLER; HARLEY, 2002). Essa falha é muito destrutiva, pois envolve a queima do isolamento e fusões localizadas nos condutores (SANTOS; SILVA; SUETAKE, 2012). A proteção pode não funcionar ou o motor pode continuar trabalhando enquanto o aquecimento nas espiras em curto-circuito, em breve, causa ruptura crítica do isolamento (BELLINI et al., 2008).

As componentes de sequência negativa da corrente de linha contêm a assinatura da falha de curto-circuito no estator (TALLAM; HABETLER; HARLEY, 2002). O valor da sequência negativa dos sinais de tensão e corrente é constante num motor em condições saudáveis, dessa forma segundo Kohler, Sottile e Trutt (1992), um alarme deve ser disparado se o desvio da sequência for superior a 6%. No entanto, alimentação com tensões desequilibradas, saturação, assimetrias nos enrolamentos e excentricidade contribuem para a medição de sequência negativa na corrente, inviabilizando o diagnóstico da falha.

25

Diversos métodos não invasivos, baseados em medições e que não necessitam da interrupção do acionamento para a coleta de informações, podem ser utilizados para a detecção de falhas em MIT (GONÇALVES JÚNIOR, 2013). Considerando-se a disponibilidade das medições de corrente e tensão nas plantas industriais, métodos baseados nos espectros das tensões e correntes vêm sendo cada vez mais utilizados.

Dentre os métodos convencionais para monitorar as condições de uma máquina de indução utilizando as componentes espectrais das correntes de estator são: *Park's Vector Approach* (CARDOSO; CRUZ; FONSECA, 1999), *Extended Park's Vector Approach* (BARENDSE et al., 2009), *Support Vector Machine* (SVM) (RADHIKA et al., 2010), modelos dinâmicos (BACCARINI; MENEZES E CAMINHAS, 2010), Análise da Assinatura da Corrente do Motor (MCSA, do inglês *Motor Current Signature Analysis*) (THOMSON; FENGER, 2001).

Os métodos baseados na assinatura da corrente elétrica do motor (MCSA) não são invasivos e não requerem a interrupção da operação do sistema de acionamento para serem realizados (BENBOUZID, 2000). A medição é realizada por sensores comuns (TCs, transformadores de corrente) os quais, muitas vezes, já estão disponíveis no processo a ser monitorado. Tal método baseia-se na decomposição espectral da corrente de estator. Os espectros de frequências obtidos são analisados com o objetivo de identificar componentes específicas de frequências que indicam uma falha incipiente ou uma possível degradação da máquina (GONÇALVES JÚNIOR, 2013).

No entanto, segundo Joksimovic e Penman (2000), as componentes do espectro não são indicadores exatos para definir falhas no enrolamento do estator. O estator faltoso produz componentes espectrais que variam com a frequência da rede. As harmônicas do campo do entreferro induzidas na corrente do estator faltoso apresentam-se na mesma frequência que uma harmônica produzida por um motor saudável (GONÇALVES JÚNIOR, 2013). Segundo Santos, Silva e Suetake (2012), uma falha no enrolamento de estator pode mudar a amplitude das harmônicas da corrente, mas não produzir novas frequências no espectro de corrente.

Dessa forma, o acompanhamento das mudanças na amplitude da componente fundamental da corrente pode indicar a presença de curto-circuito. No entanto, essas mudanças são pequenas e de difícil percepção (GONÇALVES JÚNIOR, 2012)

Contudo, considerando o fato do curto-circuito no enrolamento do estator do MIT causar variações nos valores da resistência e da indutância do enrolamento, as modificações nos valores dos parâmetros do modelo dinâmico nominal do MIT serão utilizadas para detectar a situação de curto-circuito inicial nas espiras do estator.

3.2 Modelo Simétrico do MIT

O modelo dinâmico simétrico do motor de indução trifásico é bem conhecido da literatura e permite simular o comportamento do motor frente às diversas condições de operação, sua descrição detalhada encontra-se em Krause, Wasynczuk e Sudhoff (2002). Tal modelo utiliza a Transformada *Park* para simplificar as equações da máquina, sendo também conhecido como modelo simétrico *dq* do MIT.

Neste modelo, podem ser obtidas informações sobre as tensões de alimentação, correntes de estator, torque e a velocidade desenvolvida pela máquina em condições simétricas de operação, ou seja, ausência de falhas.

As tensões das fases *a*, *b* e *c* podem ser descritas pelas seguintes equações:

$$v_{abcs} = r_s i_{abcs} + \frac{d\lambda_{abcs}}{dt}$$
(3.2)

$$v_{abcr} = \mathbf{r}_r i_{abcr} + \frac{d\lambda_{abcr}}{dt}$$
(3.3)

em que *s* e *r* representam as variáveis relacionadas ao estator e rotor, respectivamente; $v, i \in \lambda$ representam tensão, corrente e enlace de fluxo. As matrizes $r_s \in r_r$ são matrizes diagonais.

Considerando o circuito magnético linear, o enlace de fluxo total produzido por cada fase pode ser expresso por:

$$\begin{bmatrix} \lambda_{abcs} \\ \lambda_{abcr} \end{bmatrix} = \begin{bmatrix} \mathbf{L}_s & \mathbf{L}_{sr} \\ (\mathbf{L}_{sr})^T & \mathbf{L}_r \end{bmatrix} \begin{bmatrix} i_{abcs} \\ i_{abcr} \end{bmatrix}$$
(3.4)

sendo:

$$L_{s} = \begin{bmatrix} L_{ls} + L_{ms} & -\frac{1}{2}L_{ms} & -\frac{1}{2}L_{ms} \\ -\frac{1}{2}L_{ms} & L_{ls} + L_{ms} & -\frac{1}{2}L_{ms} \\ -\frac{1}{2}L_{ms} & -\frac{1}{2}L_{ms} & L_{ls} + L_{ms} \end{bmatrix}$$
(3.5)
$$L_{r} = \begin{bmatrix} L_{lr} + L_{ms} & -\frac{1}{2}L_{ms} & -\frac{1}{2}L_{ms} \\ -\frac{1}{2}L_{ms} & L_{lr} + L_{ms} & -\frac{1}{2}L_{ms} \\ -\frac{1}{2}L_{ms} & -\frac{1}{2}L_{ms} & L_{lr} + L_{ms} \end{bmatrix}$$
(3.6)
$$L_{sr} = L_{ms} \begin{bmatrix} \cos\theta_{r} & \cos\left(\theta_{r} + \frac{2\pi}{3}\right) & \cos\left(\theta_{r} - \frac{2\pi}{3}\right) \\ \cos\left(\theta_{r} - \frac{2\pi}{3}\right) & \cos\theta_{r} & \sin\left(\theta_{r} + \frac{2\pi}{3}\right) \\ \cos\left(\theta_{r} + \frac{2\pi}{3}\right) & \cos\left(\theta_{r} - \frac{2\pi}{3}\right) & \cos\theta_{r} \end{bmatrix}$$
(3.7)

Nas equações (3.5), (3.6) e (3.7) os parâmetros L_{ls} , L_{lr} e L_{ms} representam, respectivamente, as indutâncias de dispersão do estator e do rotor e a indutância mútua.

As variáveis abc do estator e do rotor podem ser transformadas para o eixo dq0 através da seguinte matriz de transformação:

$$\begin{bmatrix} f_q \\ f_d \\ f_0 \end{bmatrix} = \frac{2}{3} \begin{bmatrix} \cos\theta & \cos\left(\theta - \frac{2\pi}{3}\right) & \cos\left(\theta + \frac{2\pi}{3}\right) \\ \sin\theta & \sin\left(\theta - \frac{2\pi}{3}\right) & \sin\left(\theta + \frac{2\pi}{3}\right) \\ \frac{1}{2} & \frac{1}{2} & \frac{1}{2} \end{bmatrix} \begin{bmatrix} f_a \\ f_b \\ f_c \end{bmatrix}$$
(3.8)

na qual:

 f_q e f_d representam tensão, corrente ou enlace de fluxo de eixo quadratura e de eixo direto;

 f_a , $f_b e f_c$ representam tensão, corrente ou enlace de fluxo da fase *a*, fase *b* e fase *c*; θ é o ângulo de defasamento entre os eixos *abc* e os eixos *dq*.

Assim, as equações de tensão (3.2) e (3.3) podem ser transformadas para os eixos dq, obtendo-se, v_{ds} , v_{qs} , v_{dr} e v_{qr} . Escolhendo os enlaces de fluxos de estator e de rotor e a velocidade do motor ω_r como variáveis de estado, têm-se as equações para a obtenção desses estados, sendo ω a velocidade do eixo dq, T_e o conjugado eletromagnético, T_{carga} e *J* o conjugado e o momento de inércia da carga.

$$\frac{d\lambda_{qs}}{dt} = v_{qs} - r_s i_{qs} - \omega \lambda_{ds}$$
(3.9)

$$\frac{d\lambda_{ds}}{dt} = v_{ds} - r_s i_{ds} - \omega \lambda_{qs}$$
(3.10)

$$\frac{d\lambda_{0s}}{dt} = v_{0s} - r_s i_{0s} \tag{3.11}$$

$$\frac{d\lambda_{qr}}{dt} = -r_r i_{qr} - (\omega - \omega_r)\lambda_{dr}$$
(3.12)

$$\frac{d\lambda_{dr}}{dt} = -r_r i_{dr} + (\omega - \omega_r)\lambda_{qr}$$
(3.13)

$$\frac{d\lambda_{0r}}{dt} = -r_s i_{0s} \tag{3.14}$$

$$\frac{d\omega_r}{dt} = \frac{(T_e - T_{carga})}{J}$$
(3.15)

Após a determinação dos enlaces de fluxo pode-se obter as correntes de estator e de rotor da seguinte maneira:

$$i_{qs} = \lambda_{qs} a_1 - \lambda_{qr} a_2 \tag{3.16}$$

$$i_{ds} = \lambda_{ds} a_1 - \lambda_{dr} a_2 \tag{3.17}$$

$$i_{0s} = \lambda_{0s} a_3 \tag{3.18}$$

$$i_{qr} = \lambda_{qr} a_4 - \lambda_{qs} a_2 \tag{3.19}$$

$$i_{dr} = \lambda_{dr} a_4 - \lambda_{ds} a_2 \tag{3.20}$$

$$i_{0s} = \lambda_{0r} a_5 \tag{3.21}$$

em que $a_0 = L_s L_r - L_m^2$; $a_1 = L_r/a_0$; $a_2 = L_m/a_0$; $a_3 = 1/L_{ls}$; $a_4 = L_s/a_0$; $a_5 = 1/L_{lr}$; $L_m = (\frac{3}{2})L_{ms}$; $L_s = L_{ls} + (\frac{3}{2})L_{ms}$ e $L_r = L_{lr} + (\frac{3}{2})L_{ms}$. A equação de conjugado pode ser expressa em termos de corrente de estator e componentes de enlace de fluxo de estator e de rotor, conforme expressões a seguir:

$$T_e = \frac{3p}{22} \left(\lambda_{ds} i_{qs} - \lambda_{qs} i_{ds} \right)$$
(3.22)

$$T_e = \frac{3}{2} \frac{p}{2} \left(\lambda_{dr} i_{qs} - \lambda_{qr} i_{ds} \right) \left(\frac{L_m}{L_r} \right)$$
(3.23)

3.3 Modelo Assimétrico do MIT

O modelo assimétrico proposto por Baccarini (2005) possibilita a simulação das principais falhas que podem ocorrer durante a operação do MIT. Esse modelo é derivado do modelo simétrico da máquina e, para a simulação de curto-circuito, são adotados os procedimentos a seguir.

Na **Figura 3.1**, estão representados os enrolamentos trifásicos concentrados de um motor de indução, o qual possui uma falha de curto-circuito, sendo n_{as_2} o número de espiras em curto, r_f a resistência de falha e $n_{as_1} + n_{as_2}$ o número total de espiras por fase.



Figura 3.1: Representação de um enrolamento trifásico do estator de uma máquina de indução, na qual n_{as_2} representa o número de espiras em curto-circuito e r_f a resistência de falha. Fonte: (BACCARINI, 2005).

O percentual de espiras em curto-circuito é obtido da seguinte maneira:

$$\mu = \frac{n_{as_2}}{n_{as_1} + n_{as_2}}.$$
(3.24)

Dessa forma, a matriz de resistência do estator depende do fator μ :

$$\mathbf{r}_{s}' = r_{s} \begin{bmatrix} 1 - \mu & 0 & 0 & 0 \\ 0 & \mu & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}.$$
 (3.25)

A estimativa utilizada para as indutâncias de dispersão é dada como proposto por Tallam, Habetler e Harley (2002):

$$\boldsymbol{L}_{ls}' = L_{ls} \begin{bmatrix} 1 - \mu & 0 & 0 & 0 \\ 0 & \mu & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}.$$
 (3.26)

As tensões V_{dq0} são dadas pelas equações a seguir:

$$v_{qs} + \frac{2}{3}\mu r_s i_f \cos\theta = r_s i_{qs} + \frac{d\lambda_{qs}}{dt} + \omega \lambda_{ds}, \qquad (3.27)$$

$$v_{ds} + \frac{2}{3}\mu r_s i_f sen\theta = r_s i_{ds} + \frac{d\lambda_{ds}}{dt} + \omega \lambda_{qs}, \qquad (3.28)$$

$$v_{0s} + \frac{1}{3}\mu r_s i_f = r_s i_{0s} + \frac{d\lambda_{0s}}{dt}.$$
(3.29)

As equações para a determinação dos enlaces de fluxo do estator e rotor nos eixos *dq* são as seguintes:

$$\lambda_{ds} = L_s i_{ds} + L_m i_{dr} - \frac{2}{3} \mu L_s i_f \cos\theta, \qquad (3.30)$$

$$\lambda_{qs} = L_s i_{qs} + L_m i_{qr} - \frac{2}{3} \mu L_s i_f sen\theta, \qquad (3.31)$$

$$\lambda_{0s} = L_s i_{qs} + L_m i_{qr} + \frac{1}{3} \mu L_{ls} i_f sen\theta, \qquad (3.32)$$

$$\lambda_{dr} = L_r i_{dr} + L_m i_{ds} - \frac{2}{3} \mu L_m i_f \cos\theta, \qquad (3.33)$$

$$\lambda_{qr} = L_r i_{qr} + L_m i_{qs} - \frac{2}{3} \mu L_m i_f sen\theta.$$
(3.34)

O conjugado em função das componentes de eixo dq é dado por:

$$T = \frac{3}{2} \frac{p}{2} L_m (i_{qs} i_{dr} - i_{ds} i_{qr}) + \frac{p}{2} \mu L_m i_f (i_{qr} sen\theta - i_{dr} cos\theta), \qquad (3.35)$$

em que i_f representa a corrente de falha, θ é o ângulo de defasamento entre os eixos *abc* e *dq*, L_m é a indutância mútua, L_l é a indutância de dispersão e p é o número de polos. Os subíndices *r* e *s* representam parâmetros do rotor e do estator, respectivamente.

3.4 Aquisição dos dados

Como descrito na seção 2.2, para realizar a identificação de um modelo dinâmico aproximado para o MIT, são necessários dados dinâmicos de entrada e saída do motor. Devido à dificuldade de realização de testes para coleta de dados numa planta industrial, os dados utilizados na identificação do modelo nominal foram obtidos simulando-se o modelo simétrico do MIT. Pois, para a coleta de dados reais, seria necessária a interrupção da operação da máquina, devido às características do sinal de excitação necessário para a coleta dos dados de identificação serem diferentes daquelas do sinal de excitação da operação normal do motor.

No entanto, a validação do instrumento virtual, o estimador recursivo, será realizada por meio de dados experimentais reais.

3.4.1 Coleta de dados simulados para a Identificação

O modelo simétrico do MIT apresentado na seção 3.3 foi simulado em um período de 4s, com um intervalo de integração de $500 \times 10^{-6}s$. No entanto, para respeitar os limites estabelecidos pela equação (2.4), os dados foram decimados por 4.

Os parâmetros do circuito equivalente do motor de indução utilizado nas simulações são os mesmos do motor utilizado nos testes experimentais e são apresentados na **Tabela 3.1**, sendo r_s a resistência do estator, X_{ls} a reatância de dispersão do estator, r_r a resistência do rotor, X_r a reatância de dispersão do rotor e X_m a reatância mútua. Com o uso desses parâmetros no modelo assimétrico, é possível obter dados de simulação equivalentes aos dados de operação do motor real do laboratório.

	$r_s(\Omega)$	$X_{ls}(\Omega)$	$r_r(\mathbf{\Omega})$	$X_r(\Omega)$	$X_m(\Omega)$
	2,9115	3,3928	1,6975	2,0357	71,0607
Fonte: (GONÇALVES JÚNIOR, 2013).					

 Tabela 3.1: Parâmetros do circuito equivalente do MIT utilizados nos testes, obtidos através de ensaios à vazio e rotor travado, em conformidade com a Norma NBR 5363.

Para realizar a identificação de um sistema, o sinal de entrada deve ser tal que excite a dinâmica da planta. Características dinâmicas que não forem excitadas não aparecerão nos dados e não poderão ser identificadas. A tensão de linha aplicada para a identificação foi, então, um sinal PRBS. A **Figura 3.2** apresenta o diagrama em blocos para a obtenção dos dados de identificação.



Figura 3.2: Diagrama em blocos que representa a simulação do modelo simétrico do MIT e obtenção dos dados dinâmicos de entrada e saída de identificação.

No entanto, os dados dinâmicos utilizados como entrada e saída na modelagem foram tensão e corrente de fase. As análises serão apresentadas para uma única fase do MIT. Dessa forma, a função de autocorrelação da tensão de fase utilizada na simulação do modelo simétrico do MIT é mostrada na **Figura 3.3**:



Figura 3.3: Autocorrelação do sinal de entrada u(k). Fonte: elaboração própria.

O intervalo apresentado na **Figura 3.3** delimita a região de confiança dentro da qual a função de correlação pode ser considerada nula, com 95% de certeza. Como os resultados da autocorrelação do sinal de entrada encontram-se dentro deste intervalo para todos os atrasos considerados, este sinal possui caráter aleatório.

Os dados de entrada e saída utilizados no processo de identificação são apresentados na **Figura 3.4**, os quais serão divididos em dois conjuntos de dados: sendo a primeira metade utilizada para a identificação do sistema e a segunda metade para a validação do modelo identificado.



Figura 3.4: Dados dinâmicos de identificação e validação. Dados dinâmicos de identificação (amostras 0:821) e dados de validação (amostras 822:1641), sendo: (a) sinal de entrada do sistema, tensão de fase; (b) sinal de saída do sistema, corrente de fase. Fonte: elaboração própria.

Os dados de identificação são utilizados para verificar se o sistema exibe não linearidades. Este teste é realizado como descrito na seção 2.4, através da correlação não linear do sinal de saída, o qual é apresentado na **Figura 3.5**, a qual mostra que a autocorrelação não linear do sinal de saída, y(k), apresenta resultados fora do intervalo de confiança de 95%, indicando que o MIT deverá ser representado por um modelo não linear.



Figura 3.5: Autocorrelação não linear do sinal de saída. Fonte: elaboração própria.

3.4.2 Coleta de dados experimentais para detecção de curto-circuito

Para a obtenção dos dados reais foi utilizada uma bancada de testes que está localizada no Departamento de Engenharia Elétrica da Universidade Federal de São João del-Rei - UFSJ (**Figura 3.6**). A bancada é constituída por um motor de indução, gerador de corrente contínua, sistema de aquisição de sinais, banco de resistências, banco de cargas resistivas, fonte simétrica, varivolt, chave faca, microcomputador e software LabView®. Esta bancada é a mesma utilizada em Baccarini (2005).

O motor de indução de 3cv, 220V, 9A, $I_p/I_n = 5,4$, $cos\phi = 0,84$, $\eta = 78\%$, 60Hz, 4 polos e rotor do tipo gaiola foi modificado para possibilitar o teste de falhas elétricas. Para simular curto-circuito entre espiras de uma mesma fase, dez derivações de duas bobinas estão disponíveis. Cada bobina é constituída por 33 espiras. Como cada fase é formada por 6 bobinas, tem-se o total de 198 espiras por fase. Essa configuração permite o curto-circuito entre, no mínimo, três espiras e, no máximo, trinta e três espiras. As derivações estão dispostas externamente em uma placa de bornes de modo a facilitar o controle da corrente de curto-circuito, o qual é fechado através da chave faca. Um banco de resistências tem a função de controlar a corrente de curto-circuito nas espiras, de forma que este não seja franco. E, ainda,

por meio do banco de cargas resistivas, é possível variar a carga do gerador CC, o qual é acoplado ao eixo do motor.

A obtenção dos dados experimentais utilizados na estimação recursiva de parâmetros foi realizada através do monitoramento das correntes I_a , I_b e I_c e das tensões de alimentação V_a , V_b e V_c , em condições de operação normal e de curtocircuito. Foi fechado o curto entre 3 e 6 espiras durante as simulações e a coleta de dados experimentais, equivalendo, respectivamente, a 1,5% $\left(\frac{3}{198}\right)$ e 3% $\left(\frac{6}{198}\right)$ do total de espiras de uma das fases.



Figura 3.6: Bancada de testes experimentais. Fonte: arquivo próprio.

Como o objetivo da metodologia proposta é realizar a detecção de curto-circuito incipiente no enrolamento de estator, mesmo quando ocorrer variação no carregamento do motor, foram realizados sete ensaios para cada condição de operação considerada:

 motor operando em regime permanente, corrente de linha I = 6,12A. Após aproximadamente 5s do início da coleta dos dados, um curto-circuito é fechado nas espiras do estator, com cerca de 1,5% das espiras em curtocircuito;

- motor operando em regime permanente, corrente de linha I = 6,12A. Após aproximadamente 5s do início da coleta dos dados, um curto-circuito é fechado nas espiras do estator, com cerca de 3% das espiras em curtocircuito;
- motor operando em regime permanente com uma corrente de linha de *I* = 4,12*A*. Após aproximadamente 5*s* do início da coleta dos dados, a carga é aumentada, tal que a corrente de linha solicitada muda para *I* = 6,12*A*.

Os dados de entrada e saída para cada um dos ensaios mencionados estão apresentados nas **Figuras 3.7**, **3.8** e **3.9**.



Figura 3.7: Dados coletados do ensaio de 1,5% das espiras em curto. (a) Tensão de fase. (b) Corrente de fase. Fonte: elaboração própria.



Figura 3.8: Dados coletados do ensaio de 3% das espiras em curto. (a) Tensão de fase. (b) Corrente de fase. Fonte: elaboração própria.



Figura 3.9: Dados coletados do ensaio de variação de carga. (a) Tensão de fase. (b) Corrente de fase. Fonte: elaboração própria.

A frequência de amostragem utilizada para a aquisição dos dados foi de 1000 *Hz*.

3.5 Conclusões do Capítulo

A detecção da falha inicial de curto-circuito entre espiras do estator do MIT pode ser realizada utilizando-se as medições das correntes e tensões de alimentação do motor. A falha de curto-circuito causa mudanças nos parâmetros físicos do motor. Dessa forma, estima-se que tais mudanças poderão ser detectadas através de variações nos parâmetros do modelo dinâmico do MIT.

Os dados simulados por meio do modelo simétrico do MIT foram divididos em um conjunto de dados utilizados para a identificação e outro para a validação do modelo.

A bancada de testes da seção 3.4.2 foi utilizada para gerar dados de condição normal de operação e curto-circuito, além de produzir diferentes pontos de operação. A estrutura do modelo dinâmico identificado para o MIT será utilizada na identificação recursiva de parâmetros, a qual será responsável pela detecção do curto-circuito através da variação temporal nos valores dos parâmetros.

Capítulo 4

DETECÇÃO DE CURTO-CIRCUITO EM MOTORES DE INDUÇÃO TRIFÁSICOS ATRAVÉS DE MODELO LINEAR IDENTIFICADO APLICADO NA ESTIMAÇÃO RECURSIVA DE PARÂMETROS

4.1 Introdução

O modelo matemático de um sistema dinâmico é definido como o conjunto de equações que representam razoavelmente bem a dinâmica do sistema (OGATA, 2011). Consequentemente, não existe o modelo do sistema, mas sim uma família de modelos com características e desempenhos variados (AGUIRRE, 2007). Uma vez que há diversas aplicações possíveis para um modelo, a sua identificação deve ser feita sempre com o objetivo final em mente (STOICA; JANSSEN; SÖDERTRÖM, 1986).

Os sistemas dinâmicos lineares representam idealizações dos reais processos encontrados (LJUNG, 1999). Uma importante idealização é a de se verificar o comportamento do sistema numa faixa relativamente estreita de operação. Com a operação normal do sistema em torno de um ponto de equilíbrio, é possível aproximar o sistema não linear por um sistema linear, o qual será considerado dentro de um conjunto limitado de operações, o que é chamado linearização. É importante notar que um modelo matemático particular pode representar com precisão a dinâmica de um sistema real para certas condições de operação, mas pode não ser preciso para outras condições (OGATA, 2011).

As equações que representam o comportamento das máquinas de indução são não lineares. No entanto, é possível linearizar estas equações através da restrição a pequenas excursões em torno de pontos de operação (KRAUSE; WASYNCZUK; SUDHOFF, 2002).

Na obtenção de um modelo matemático, deve-se estabelecer uma conciliação entre a simplicidade do modelo e a precisão dos resultados da análise (OGATA, 2011). Caso as propriedades ignoradas do sistema real tiverem efeitos pequenos na sua resposta, o modelo linear poderá obter uma boa aproximação. No entanto, se

39

análises mais precisas forem necessárias, um modelo matemático não linear mais completo poderá ser construído.

O diagrama em blocos que representa o processo de identificação está apresentado na Figura 4.1:



Figura 4.1: Diagrama em blocos que representa a detecção da estrutura do modelo dinâmico do MIT e a estimação de parâmetros em batelada.

Neste capítulo serão apresentados os resultados da identificação de um modelo linear para aproximar o comportamento dinâmico do motor de indução descrito na seção 3.4, por meio de dados de simulação do modelo simétrico do MIT, os quais serão utilizados em batelada. A estrutura do modelo identificada será aplicada na estimação recursiva de parâmetros, utilizando-se dados experimentais reais da bancada de testes e para as diferentes condições de operação do motor, ambas citadas na seção 3.4.2, com o objetivo de detectar a situação de falha incipiente de curto-circuito no MIT.

4.2 Modelo Linear do MIT estimado em batelada

Inicialmente, foi realizada a identificação de um modelo dinâmico linear para o MIT, objetivando verificar a eficácia de um modelo de maior simplicidade na detecção da falha no motor.

A representação escolhida foi a ARMAX (do inglês, *Autorregressive Moving Average with exogenous inputs*), a qual é tipicamente utilizada para descrever dinâmicas lineares de modelo discretos. Uma vez determinado o grau de não linearidade do modelo, ℓ , o número de termos foi sugerido pelo Critério de Akaike (AIC). Os atrasos do modelo, n_u , n_y e n_e , foram determinados empiricamente. Os termos de ruído foram utilizados de forma a minimizar a polarização dos parâmetros.

Dentre os modelos obtidos, foi selecionado o que apresentou o compromisso entre os resultados na validação, assim como, simplicidade e a detecção da falha através da variação dos valores dos parâmetros. Os dados mostrados na **Figura 3.4** correspondem às variáveis naturais do sistema. Para a obtenção dos modelos lineares, essas variáveis foram normalizadas com o propósito de limitá-las ao intervalo $\{-1,1\}$, dessa forma problemas como o mau condicionamento ou a singularidade de matrizes podem ser evitados.

Partindo-se do grau de não linearidade do modelo $\ell = 1$, o número de termos sugerido pelo Critério de Akaike foi $n_p = 3$, **Figura 4.2**. Os atrasos do modelo encontrados de forma empírica são $n_u = 2$, $n_y = 2$ e $n_e = 3$. O modelo ARMAX, obtido após ser eliminado o termo constante do conjunto de termos candidatos Ω_o , é então apresentado na equação (4.1):

$$y(k) = 0.5186u(k-1) + 0.1269y(k-2) - 0.0629u(k-2) + \sum_{i=1}^{n_e} \hat{\theta}_i \xi(k-i) + \xi(k),$$
(4.1)

em que $\theta_1 = 0,5186$, $\theta_2 = 0,1269$ e $\theta_3 = -0,0629$.

O modelo ARMAX da equação (4.1) possui índice RMSE = 0,7482 e sua simulação livre pode ser analisada na **Figura 4.3**. As validações estatísticas serão

realizadas por meio das análises de autocorrelação e correlação dos resíduos de predição do modelo e apresentada na **Figura 4.4**.



Figura 4.2: Critério de Akaike.

Observa-se, por meio da **Figura 4.3**, que as predições realizadas com o modelo ARMAX da equação (4.1) não são precisas nos pontos extremos da curva, sugerindo uma deficiência do modelo em representar parte da dinâmica do MIT. Para o índice RMSE, será adotado que valores menores que 1 são aceitáveis, sendo que quanto menor, melhor. Dessa forma, o índice RMSE do modelo da equação (4.1) é aceitável.



Figura 4.3: Validação dinâmica do modelo, infinitos passos à frente. (-) Dados validação. (--) Simulação livre. Fonte: elaboração própria.



Figura 4.4: Validação estatística para o modelo linear, eq. (4.1). (a) r_{ee} (b) r_{ue} (c) $r_{e(eu)}$ (d) r_{u^2e} (e) $r_{u^2e^2}$.

As validações estatísticas do modelo, **Figura 4.4**, mostram que existem correlações lineares e não lineares nos resíduos, pois para certos atrasos a função de correlação se encontra fora do intervalo de confiabilidade de 95%. Tal resultado

pode indicar que os parâmetros do modelo identificado possuem polarização e, ainda, que os resíduos de predição não são ruído branco, ou seja, certas dinâmicas, tanto lineares quanto não lineares, do MIT não foram aproximadas pelo modelo da equação (4.1).

Outra importante análise a ser feita é verificar se o modelo linear é capaz de distinguir a situação de operação normal da operação com falha. Como na estimação recursiva de parâmetros a estrutura do modelo será fixa e determinada pela parte determinística da equação (4.1), de acordo com o número de termos sugeridos pelo (AIC), e, ainda, esse modelo foi estimado com dados simulados através do modelo simétrico do MIT operando normal, dados que não representam essa condição de operação não resultarão no mesmo regime dinâmico observado na **Figura 4.3**. Dessa forma, estima-se que a inserção de dados de operação do MIT com falha no modelo da equação (4.1) resulte em mudanças nos valores dos parâmetros.

Portanto, foram utilizados dados simulados através do modelo assimétrico, descrito na seção 3.3 e desenvolvido por Baccarini (2005), simulando operação do MIT com 3% das espiras em curto-circuito. Como se trata de dados utilizados na identificação, o sinal de excitação, novamente, foi um sinal PRBS. O modelo identificado em batelada utilizando-se esses dados é apresentado na equação (4.2):

$$y(k) = 0,4673u(k-1) + 0,2150y(k-2) - 0,2164u(k-2)$$

$$+ \sum_{i=1}^{n_e} \hat{\theta}_i \xi(k-i) + \xi(k),$$
(4.2)

em que $\theta_1 = 0,4673$, $\theta_2 = 0,2150$ e $\theta_3 = -0,2164$.

A equação (4.2) mostra que a estrutura da parte determinística do modelo é a mesma apresentada na equação (4.1), a qual foi obtida utilizando-se dados de operação normal. No entanto, os parâmetros do modelo sofreram modificações quando dados com falha foram utilizados, dessa forma, mostra-se que é possível detectar a situação de falha através da variação nos valores dos parâmetros. Tal análise pode ser observada, também, na **Figura 4.5**, a qual se trata de um histograma construído com as distribuições de frequências dos valores dos

parâmetros. Foram aplicados dados de operação normal e com falha à estrutura da equação (4.1), utilizando 1000 realizações com ruído para cada condição.



Figura 4. 5: Histograma com as distribuições de frequências dos parâmetros, (a) θ_1 , (b) θ_2 e (c) θ_3 . (-, vermelho) Parâmetros do MIT com operação normal. (-, preto) Parâmetros do MIT operando com curto-circuito em 3% das espiras. Dados simulados. Estimação em batelada. Fonte: elaboração própria.

Esse resultado, juntamente com as validações dinâmica e estatística do modelo, **Figura 4.3** e **Figura 4.4** respectivamente, mostra que o modelo linear da equação (4.1) é uma representação possível e simples para o MIT, que possibilita, em batelada, observar variação nos valores dos parâmetros diante da situação de curto-circuito.

Portanto, a estrutura desse modelo linear será utilizada na estimação recursiva de parâmetros, objetivando demonstrar a possibilidade da detecção *on-line* do curto-circuito através do acompanhamento temporal da tendência dos parâmetros quando comparados à situação de operação normal do MIT. No entanto, esta análise será realizada com mudanças no ponto de operação do motor, cargas de diferentes valores acopladas ao eixo do motor, para verificar se estas mudanças influenciarão de forma significativa no comportamento dos parâmetros, de forma a dificultar a detecção do curto-circuito e, também, para representar de forma mais realística o que seria encontrado num ambiente industrial.

4.3 Detecção de curto-circuito inicial no MIT através da Estimação recursiva de Parâmetros utilizando modelo linear

As correntes de estator (I_a , I_b e I_c) e as tensões de alimentação do MIT (V_a , V_b e V_c) foram coletadas diante das condições citadas na seção 3.4.2. O objetivo deste trabalho é detectar falhas incipientes, ou seja, curtos-circuitos em poucas espiras, mesmo durante variações de carregamento do motor. A menor porcentagem de curto-circuito entre espiras possível para os testes, utilizando a bancada da **Figura 3.6**, é de 1,5%.

O diagrama em blocos que representa o processo de estimação recursiva de parâmetros e, consequente, detecção da falha está apresentado na **Figura 4.6**:



Figura 4.6: Diagrama em blocos do processo de estimação recursiva de parâmetros e detecção de falha de curto-circuito.

A parte determinística da estrutura do modelo identificado para o MIT e apresentado na equação (4.1) foi então utilizada na estimação recursiva de parâmetros, de forma a detectar a variação temporal nos valores dos parâmetros à medida que os dados de falha são inseridos sequencialmente no algoritmo recursivo. Nesse contexto, a influência do fator de esquecimento será analisada para a detecção do curto-circuito.

Neste Capítulo, os resultados apresentados são referentes somente à fase de ocorrência do curto-circuito, fase *a*.

4.3.1 Curto-Circuito em cerca de 1,5% das espiras do enrolamento de uma fase do estator do MIT

Como modelos de processo e de ruído podem, na prática, ser desacoplados (BILLINGS et al., 1989), a parte determinística do modelo estimado para o MIT da equação (4.1) é equivalente a um modelo ARX (do inglês, *Autorregressive With exogenous inputs*), o qual possui três parâmetros, dessa forma o algoritmo recursivo visa monitorar a variação temporal desses parâmetros.

Os valores dos fatores de esquecimento utilizados no algoritmo foram $\lambda = 0,999$ e $\lambda = 0,9993$, visto que valores menores que 0,999 dificultam a detecção do curto-circuito, devido à grande variância causada nos valores dos parâmetros mesmo durante a operação normal do MIT. A matriz de covariância foi inicializada com valores iguais a $10^3 \times I_{3\times3}$, em que $I_{3\times3}$ é uma matriz identidade de ordem três, e o vetor de parâmetros foi inicializado com os valores encontrados na estimação em batelada, $\theta = [0,5186 \quad 0,1269 \quad -0,0629]$, de forma a agilizar a convergência do algoritmo.

Como descrito na seção 3.4.2, para a detecção do curto-circuito, primeiramente, o motor opera normal, com carga e em regime permanente, quando o curto-circuito é inserido; e para a variação de carga, cargas de diferentes valores são acopladas ao eixo do motor. Como o fechamento do curto-circuito e a variação de carregamento do motor foram realizados de forma manual, para cada ensaio realizado, aproximadamente metade das amostras representa uma condição, enquanto a outra metade representa a outra condição analisada. Neste caso, será

analisada, separadamente, a situação de curto-circuito em cerca de 1,5% das espiras do estator e um aumento no carregamento do motor, objetivando verificar se a variação da carga interfere na detecção do curto-circuito.

Os resultados obtidos utilizando o fator de esquecimento $\lambda = 0,999$ são apresentados nas **Tabelas 4.1** e **4.2** e nas **Figuras 4.7** e **4.8**.



Figura 4.7: Variação temporal dos parâmetros detectada pelo estimador recursivo com λ = 0,999.
(a), (c) e (e) MIT passa da operação normal para a operação com curto-circuito em 1,5% das espiras.
(b), (d) e (f) Variação de carga. Fonte: elaboração própria.



Figura 4.8: Variação temporal dos parâmetros. (–, vermelho) Curto-circuito em 1,5% das espiras. (–, azul) Variação de carga. $\lambda = 0,999$. (a) θ_1 , (b) θ_2 e (c) θ_3 . Fonte: elaboração própria.

Tabela 4.1: Valores de média e variância dos parâmetros estimados recursivamente para os 7
ensaios realizados. Curto-circuito em 1,5% das espiras e $\lambda = 0,999$.

Parametro	Media	variancia
θ_1 (operação normal)	0,0380	3,4721 × 10 ⁻¹⁰
θ_1 (curto-circuito)	0,0384	$6,9692 \times 10^{-10}$
θ_2 (operação normal)	0,0129	$1,4893 \times 10^{-6}$
θ_2 (curto-circuito)	0,0220	$4,5741 \times 10^{-7}$
θ_3 (operação normal)	-0,0286	$2,1789 \times 10^{-11}$
θ_3 (curto-circuito)	-0,0292	$6,6804 \times 10^{-10}$

Fonte: elaboração própria.

Parâmetro	Média	Variância	
$\theta_1 \ (I = 4, 12A)$	0,0176	$5,3579 \times 10^{-9}$	
$\theta_1 I = 6,1A)$	0,0291	$1,1213 \times 10^{-6}$	
$\theta_2 \ (I=4,12A)$	0,3203	$1,5631 \times 10^{-4}$	
$\theta_2 \ (I=6,1A)$	0,5546	$3,000 \times 10^{-3}$	
$\theta_3 \left(I = 4,12A \right)$	-0,0108	$4,2746 \times 10^{-8}$	
$\theta_3 \ (I=6,1A)$	-0,0282	$1,1622 \times 10^{-7}$	

Tabela 4.2: Valores de média e variância dos parâmetros estimados recursivamente
para os 7 ensaios realizados. Variação de carga e $\lambda = 0,999$.

Fonte: elaboração própria.

Os resultados obtidos utilizando o fator de esquecimento $\lambda = 0,9993$ são apresentados nas **Tabelas 4.3** e **4.4** e nas **Figuras 4.9** e **4.10**.

Tabela 4.3: Valores de média e variância dos parâmetros estimados recursivamente para os 7 ensaios realizados. Curto-circuito em 1,5% das espiras e $\lambda = 0,9993$.

Parâmetro	Média	Variância	
θ_1 (operação normal)	0,0380	$2,9619 \times 10^{-10}$	
θ_1 (curto-circuito)	0,0384	$1,4571 \times 10^{-9}$	
θ_2 (operação normal)	0,0126	$1,1576 \times 10^{-6}$	
θ_2 (curto-circuito)	0,0233	$2,3490 \times 10^{-7}$	
θ_3 (operação normal)	-0,0286	$1,4819 \times 10^{-11}$	
θ_3 (curto-circuito)	-0,0292	$1,3027 \times 10^{-9}$	

Fonte: elaboração própria.

Tabela 4.4: Valores de média e variância dos parâmetros estimados recursivamente para os 7
ensaios realizados. Variação de carga e $\lambda = 0,9993$.

Parâmetro	Média	Variância
$\theta_1 \ (I = 4, 12A)$	0,0176	$4,1828 \times 10^{-9}$
$\theta_1 I = 6,1A$)	0,0274	$5,2182 \times 10^{-7}$
$\theta_2 \ (I=4,12A)$	0,3196	$1,3090 \times 10^{-4}$
$\theta_2 \ (I=6,1A)$	0,6377	$6,3104 \times 10^{-4}$
$\theta_3 \left(I = 4,12A \right)$	-0,0108	$3,4358 \times 10^{-8}$
$\theta_3 \ (I=6,1A)$	-0,0274	$2,9996 \times 10^{-7}$

Fonte: elaboração própria.



Figura 4.9: Variação temporal dos parâmetros detectada pelo estimador recursivo com $\lambda = 0,9993$. (a), (c) e (e) MIT passa da operação normal para a operação com curto-circuito em 1,5% das espiras. (b), (d) e (f) Variação de carga. Fonte: elaboração própria.



Figura 4.10: Variação temporal dos parâmetros. (–, vermelho) Curto-circuito em 1,5% das espiras. (–, azul) Variação de carga. $\lambda = 0,9993$. (a) θ_1 , (b) θ_2 e (c) θ_3 . Fonte: elaboração própria.

Analisando-se da **Figura 4.7** à **4.10** e da **Tabela 4.1** à **4.4**, conclui-se que na média o parâmetro que sofreu as maiores variações durante o curto-circuito em 1,5% das espiras foi θ_2 , para todos os fatores de esquecimento testados. Tal variação foi maior utilizando-se o fator de esquecimento $\lambda = 0,9993$. O parâmetro θ_2 é relacionado ao termo y(k-2) do modelo da equação (4.1). Este resultado apresenta o fato do curto-circuito influenciar minimamente na tensão de alimentação, u(k), possuindo maior influência na corrente, y(k), visto que a fonte de tensão é ligada ao sistema elétrico de potência, o qual é caracterizado como um barramento infinito, no qual tensão e frequência são mantidas constantes. No entanto, o instante do curto-circuito, aproximadamente amostra 5000, é mais visível nos parâmetros θ_1 e θ_3 , pois a variância nestes parâmetros é menor.

Novamente, para o caso de variação de carga, o parâmetro que sofreu as maiores variações foi θ_2 e para o fator de esquecimento $\lambda = 0,9993$.

As comparações gráficas entre o comportamento dos parâmetros quando o motor opera com curto-circuito em 1,5% das espiras e a variação de carregamento analisada são apresentadas nas **Figuras 4.8** e **4.10**. Verifica-se, então, que não existe uma impossibilidade de se fazer uma detecção *on-line* do curto-circuito de 1,5%, através do acompanhamento da tendência dos parâmetros, utilizando o modelo linear da equação (4.1) na estimação recursiva de parâmetros, quando o motor não aciona uma carga constante. Tal fato é devido à variação dos parâmetros durante a mudança de carga do motor ser maior que durante o curto-circuito de 1,5%.

4.3.2 Curto-Circuito em cerca de 3% das espiras do enrolamento de uma fase do estator do MIT

O mesmo procedimento da seção 4.3.1 foi realizado para o caso de curtocircuito em 3% das espiras.

Os resultados obtidos para o curto-circuito em 3% das espiras utilizando o fator de esquecimento $\lambda = 0,999$ são apresentados na **Tabela 4.5** e nas **Figuras 4.11** e **4.12**.

Parâmetro	Média	Variância
θ_1 (operação normal)	0,0353	$2,0993 \times 10^{-9}$
θ_1 (curto-circuito)	0,0364	$4,7868 \times 10^{-8}$
θ_2 (operação normal)	0,1545	$1,6079 \times 10^{-5}$
θ_2 (curto-circuito)	0,1896	$8,9320 \times 10^{-5}$
θ_3 (operação normal)	-0,0286	$5,1298 \times 10^{-10}$
θ_3 (curto-circuito)	-0,0304	$5,5367 \times 10^{-9}$

Tabela 4.5: Valores de média e variância dos parâmetros estimados recursivamente para os 7
ensaios realizados. Curto-circuito em 3% das espiras e $\lambda = 0,999$.

Fonte: elaboração própria.



Figura 4.11: Variação temporal dos parâmetros causada pelo curto-circuito em 3% das espiras detectada pelo estimador recursivo com $\lambda = 0,999$. (a) θ_1 , (b) θ_2 e (c) θ_3 . Fonte: elaboração própria.



Figura 4.12: Variação temporal dos parâmetros. (–, vermelho) Curto-circuito em 3% das espiras. (–, azul) Variação de carga. $\lambda = 0,999$. (a) θ_1 , (b) θ_2 e (c) θ_3 . Fonte: elaboração própria.

Os resultados obtidos para o curto-circuito em 3% das espiras utilizando o fator de esquecimento $\lambda = 0,9993$ são apresentados na **Tabela 4.6** e nas **Figuras 4.13** e **4.14**.

Parâmetro	Média	Variância
θ_1 (operação normal)	0,0353	$1,3192 \times 10^{-9}$
θ_1 (curto-circuito)	0,0360	$6,2734 \times 10^{-8}$
θ_2 (operação normal)	0,1546	$9,7956 \times 10^{-6}$
θ_2 (curto-circuito)	0,2035	$9,5841 \times 10^{-5}$
θ_3 (operação normal)	-0,0286	$3,0261 \times 10^{-10}$
θ_3 (curto-circuito)	-0,0302	$1,1019 \times 10^{-8}$

Tabela 4.6: Valores de média e variância dos parâmetros estimados recursivamente para os 7 ensaios realizados. Curto-circuito em 3% das espiras e $\lambda = 0,9993$.



Fonte: elaboração própria.

Figura 4.13: Variação temporal dos parâmetros causada pelo curto-circuito em 3% das espiras detectada pelo estimador recursivo com $\lambda = 0,9993$. (a) θ_1 , (b) θ_2 e (c) θ_3 . Fonte: elaboração própria.


Figura 4. 14: Variação temporal dos parâmetros. (–, vermelho) Curto-circuito em 3% das espiras. (–, azul) Variação de carga. $\lambda = 0.9993$. (a) θ_1 , (b) θ_2 e (c) θ_3 . Fonte: elaboração própria.

Analisando-se da **Figura 4.11** à **4.14** e as **Tabelas 4.5** e **4.6**, conclui-se que o parâmetro que sofreu as maiores variações durante o curto-circuito de 3% foi, novamente, θ_2 , para todos os fatores de esquecimento testados. Tal variação foi maior utilizando-se o fator de esquecimento $\lambda = 0,9993$.

As comparações gráficas entre o comportamento dos parâmetros, quando o motor opera com curto-circuito em 3% das espiras e variação de carregamento, são apresentadas nas **Figuras 4.12** e **4.14**. Verifica-se, então, que as variações nos valores dos parâmetros, quando existe variação do carregamento do MIT, dificultam a detecção da falha.

4.4 Análise Estatística dos parâmetros estimados recursivamente

Histogramas foram construídos com as distribuições de frequências dos valores dos parâmetros diante de cada situação investigada, 2000 dados para cada

condição. Como as maiores variações nos valores dos parâmetros diante do curtocircuito aconteceram quando $\lambda = 0,9993$, os resultados apresentados a seguir foram obtidos utilizando esse fator de esquecimento na estimação recursiva de parâmetros e são apresentadas nas **Figuras 4.15**, **4.16** e **4.17**.

A **Figura 4.15** mostra que existe uma sobreposição das distribuições de frequências do parâmetro θ_2 , quando o MIT opera normal e com curto-circuito em 1,5% das espiras. No entanto, a **Figura 4.16** mostra que para o caso de curto circuito em 3% das espiras e operação normal do MIT as distribuições de frequências praticamente não se sobrepõem. Para o caso de variação de carga, as distribuições de frequências dos parâmetros não se sobrepõem para as duas situações de carregamento, **Figura 4.17**.



Figura 4.15: Histograma das distribuições de frequências dos parâmetros, (a) θ_1 , (b) θ_2 e (c) θ_3 . (-, cinza) Parâmetros do MIT com operação normal. (-, preto) Parâmetros do MIT operando com curto-circuito em 1,5% das espiras. $\lambda = 0,9993$. Dados experimentais reais. Estimação recursiva. Fonte: elaboração própria.



Figura 4. 16: Histograma das distribuições de frequências dos parâmetros, (a) θ_1 , (b) θ_2 e (c) θ_3 . (-, cinza) Parâmetros do MIT com operação normal. (-, preto) Parâmetros do MIT operando com curto-circuito em 3% das espiras. $\lambda = 0,9993$. Dados experimentais reais. Estimação Recursiva. Fonte: elaboração própria.

No entanto, os resultados apresentados na seção 4.3 mostram que, mesmo para o curto-circuito de 3%, a detecção da falha utilizando a estrutura do modelo linear da equação (4.1) na estimação recursiva de parâmetros fica impossibilitada quando houver variação de carga no motor.



Figura 4.17: Histograma das distribuições de frequências dos parâmetros, (a) θ_1 , (b) θ_2 e (c) θ_3 . (-, cinza) Parâmetros do MIT operando com I = 4,12A. (-, preto) Parâmetros do MIT operando com I = 6,1A. $\lambda = 0,9993$. Dados experimentais reais. Estimação Recursiva. Fonte: elaboração própria.

4.5 Conclusões do Capítulo

O modelo linear da equação (4.1) é uma representação simplificada da dinâmica do MIT, o que pode ser verificado através da sua validação, pelas **Figuras 4.3** e **4.4**, que mostram a incapacidade do modelo em representar certas dinâmicas da máquina. No entanto, tal modelo possibilitou detectar variação nos valores dos parâmetros em batelada diante da situação de falha, análise apresentada na equação (4.2) e **Figura 4.5**.

Contudo, a utilização de um modelo linear na identificação recursiva de parâmetros aplicada na detecção de curto-circuito incipiente no MIT mostrou-se muito restritiva. Tal resultado deve-se ao fato de o modelo linear ser aplicável somente a determinado ponto de operação, com pequenas variações em torno dele. Dessa forma, a sensibilidade ao curto-circuito é muito baixa e a variação de

carregamento no motor dificulta a detecção *on-line* da falha através do acompanhamento das tendências dos valores dos parâmetros.

Os resultados apresentados na seção 4.3.1 mostram certa dificuldade na detecção do curto-circuito em 1,5% das espiras através do modelo da equação (4.1). Tal fato deve-se à variação dos parâmetros causada pelo curto-circuito ser muito sutil, o que impossibilita sua detecção *on-line* através de uma tendência, quando comparada à tendência ocasionada pela mudança de carga.

Analisando-se da **Tabela 4.1** à **4.6**, verifica-se que as tendências apresentadas da **Figura 4.7** à **4.14**, para um dos ensaios realizados, são próximas quando utilizada a média dos resultados obtidos para os sete ensaios realizados.

No entanto, o objetivo deste trabalho é a identificação de um modelo menos restritivo, que seja utilizado na estimação recursiva de parâmetros e que seja eficaz na detecção de curto-circuito incipiente no MIT, a partir de 1,5% das espiras em curto-circuito, mesmo durante variações de carregamento do motor. Para atender a esse objetivo, deve-se, então, proceder à identificação de um modelo mais representativo, dessa forma procedeu-se à identificação de um modelo não linear, o qual será apresentado no Capítulo 5.

DETECÇÃO DE CURTO-CIRCUITO EM MOTORES DE INDUÇÃO TRIFÁSICOS ATRAVÉS DE MODELO NÃO LINEAR IDENTIFICADO APLICADO NA ESTIMAÇÃO RECURSIVA DE PARÂMETROS

5.1 Introdução

Em virtude dos resultados encontrados no Capítulo 4 não terem alcançado o objetivo deste trabalho, outro conjunto de modelos foi identificado para representar a operação normal do MIT, buscando uma maior representatividade de sua dinâmica. Portanto, devido ao fato de modelos não lineares conseguirem explicar dinâmicas que modelos lineares não conseguem (AGUIRRE, 2007), um modelo não linear mostra-se mais adequado. Além disso, o teste de detecção de não linearidades, aplicado ao sinal de saída utilizado na identificação do modelo e apresentado na **Figura 3.5**, mostra a necessidade da identificação de um modelo não linear.

Se a estrutura escolhida para o modelo for adequada, é possível estimar a característica estática de interesse. Nesse contexto, a representação NARX polinomial possibilita a utilização de informação auxiliar, como o fato de permitir o cálculo do ganho estático através do modelo dinâmico, utilizando o conceito de agrupamentos de termos, apresentado nas seções 2.8, 2.9 e 2.10.

A utilização de informação auxiliar na identificação de sistemas é denominada identificação caixa-cinza, a qual permite obter modelos de abrangência mais global, mesmo com dados limitados a certa região de operação (FUNKQUIST, 1997).

Como objetiva-se que o modelo represente os diversos pontos de operação do MIT, diferentes solicitações de carga, sua característica estática variará em função do tempo. Dessa forma, o ganho estático deverá ser estimado recursivamente, juntamente com os parâmetros do modelo, de acordo com a equação (2.16).

Neste capítulo serão apresentados os resultados da identificação em batelada de um modelo NARMAX polinomial para aproximar as características dinâmicas do motor de indução descrito na seção 3.4, cuja estrutura da parte determinística será

utilizada na estimação recursiva dos parâmetros e do ganho estático, por meio dos mesmos dados utilizados no Capítulo 4.

5.2 Modelo Não Linear do MIT estimado em batelada

Novamente, a primeira metade dos dados de entrada e saída do MIT, u(k) e y(k), representados na **Figura 3.4**, foi usada na identificação. Determinou-se o grau de não linearidade do modelo $\ell = 2$ para a representação NARMAX polinomial. O número de termos do modelo foi sugerido pelo Critério de Akaike como $n_p = 4$, **Figura 5.1**, e a estrutura foi determinada utilizando a taxa de redução de erro (ERR). Os atrasos do modelo foram encontrados empiricamente e são $n_u = 2$, $n_y = 2$ e $n_e = 4$. A utilização dos termos de ruído objetiva a minimização da polarização dos parâmetros.



Figura 5.1: Critério de Akaike.

Dentre os modelos identificados, o modelo NARMAX que apresentou um compromisso entre os resultados na validação, baixa complexidade e a detecção em batelada do curto-circuito, obtido após ser eliminado o termo constante do conjunto de termos candidatos Ω_{o} , é então apresentado na equação (5.1):

$$y(k) = 0,0756u(k-1) + 0,2976y(k-2) - 0,0113u(k-2)$$

$$+ 0,0004u(k-1)y(k-1) + \sum_{i=1}^{n_e} \hat{\theta}_i \xi(k-i) + \xi(k)$$
(5.1)

em que $\theta_1 = 0,0756$, $\theta_2 = 0,2976$, $\theta_3 = -0,0113$ e $\theta_4 = 0,0004$.

O modelo NARMAX da equação (5.1) possui índice RMSE = 0,5860 e sua simulação livre pode ser analisada na **Figura 5.2**. As validações estatísticas são apresentadas na **Figura 5.3**.

Uma análise da **Figura 5.2** mostra que as predições realizadas com o modelo NARMAX da equação (5.1) são mais precisas que as realizadas com o modelo ARMAX da equação (4.1), incluindo os pontos extremos da curva, sugerindo uma capacidade do modelo em representar a dinâmica do MIT. O índice RMSE do modelo da equação (5.1) é cerca de 22% menor do que do modelo da equação (4.1).

As validações estatísticas do modelo da equação (5.1), **Figura 5.3**, mostram que os resíduos de predição do modelo encontram-se dentro do intervalo de confiabilidade de 95% para as correlações lineares. No entanto, para alguns atrasos, as correlações não lineares estão fora do intervalo. Tal resultado indica que este modelo consegue explicar toda a linearidade contida nos dados e grande parte das não linearidades. Dessa forma, o modelo não linear, equação (5.1), consegue tanto aproximar a dinâmica do MIT quanto explicar a variância contida nos dados de melhor forma do que o modelo linear, equação (4.1).



Figura 5.2: Validação dinâmica do modelo, infinitos passos à frente. (–) Dados validação. (– –) Simulação livre. Fonte: elaboração própria.



Figura 5.3: Validação estatística para o modelo não linear, eq. (5.1). (a) r_{ee} (b) r_{ue} (c) $r_{e(eu)}$ (d) r_{u^2e} (e) $r_{u^2e^2}$.

Para mostrar que o modelo da equação (5.1) diferencia a situação de operação normal da operação com falha, os mesmo dados simulados com falha da seção 4.2 foram utilizados na identificação do modelo não linear em batelada. O resultado da identificação é apresentado na equação (5.2):

$$y(k) = 0,107u(k-1) + 0,4914y(k-2) - 0,0292u(k-2)$$
(5.2)

$$+0,0000(k-1)y(k-1) + \sum_{i=1}^{n_e} \hat{\theta}_i \xi(k-i) + \xi(k)$$

em que $\theta_1 = 0,1070$, $\theta_2 = 0,4914$, $\theta_3 = -0,0292$ e $\theta_4 = 0,0000$.

Um histograma foi construído com as distribuições de frequências dos valores dos parâmetros. Foram aplicados dados de operação normal e com falha à estrutura da equação (5.1), utilizando 1000 realizações com ruído. O resultado é apresentado na **Figura 5.4**.



Figura 5.4: Histograma com as distribuições de frequências dos parâmetros, (a) θ_1 , (b) θ_2 , (c) θ_3 e (d) θ_4 . (-, vermelho) Parâmetros do MIT com operação normal. (-, preto) Parâmetros do MIT operando com curto-circuito em 3% das espiras. Dados simulados. Estimação batelada. Fonte: elaboração própria.

A equação (5.2) mostra que a estrutura da parte determinística do modelo é a mesma apresentada na equação (5.1), no entanto, os parâmetros do modelo sofreram modificações quando dados com falha foram utilizados na identificação, mesma análise apresentada na **Figura 5.4.** Dessa forma, mostra-se que é possível detectar a situação de falha através da variação nos valores dos parâmetros da equação (5.1).

5.3 Estimação de não linearidades estáticas

A parte determinística do modelo estimado para o MIT, equação (5.1), contém o número de termos sugerido pelo (AIC) e é equivalente a um modelo NARX polinomial, possuindo quatro parâmetros. Dessa forma, a estimação recursiva visa monitorar os valores desses parâmetros ao longo do tempo.

No entanto, como o MIT pode operar em várias condições de operação, o ganho do modelo da equação (5.1) deve ser variável, como descrito na seção 2.9, de forma que os valores dos parâmetros acompanhem as mudanças nas condições de operação.

Como os agrupamentos $\Sigma_{y^2} = 0$, $\Sigma_{u^2} = 0$ e $\Sigma_0 = 0$, existirá somente um ponto fixo determinado pela equação (5.2):

$$\bar{y} = \frac{\Sigma_u u}{1 - \Sigma_y - \Sigma_{yu} u},\tag{5.2}$$

em que $\Sigma_u = \theta_1 - \theta_3$, $\Sigma_y = \theta_2$ e $\Sigma_{yu} = \theta_4$.

A curva estática é, então, obtida recursivamente de acordo com a equação (5.3):

$$\bar{y}_{k} = \frac{(\hat{\theta}_{1_{k-1}} - \hat{\theta}_{3_{k-1}}).u(k)}{1 - \hat{\theta}_{2_{k-1}} - \hat{\theta}_{4_{k-1}}u(k)},$$
(5.3)

na qual \bar{y}_k representa o valor da saída estática encontrada recursivamente a partir da entrada u(k) e dos parâmetros, também, estimados recursivamente; $\hat{\theta}_n$ representa os parâmetros estimados recursivamente, n = 1, ..., 4; k e k - 1representam a iteração do algoritmo recursivo.

Portanto, o ganho inserido no algoritmo será a divisão da saída estimada recursivamente, \bar{y}_k , pela saída medida, y(k):

$$\overline{K}_k = \frac{\overline{y}_k}{y(k)},\tag{5.4}$$

o qual será multiplicado pela entrada u(k), de forma a se ajustar o ponto de operação do MIT e estimar recursivamente os parâmetros de acordo com o descrito na seção 2.12.

A cada período de amostragem, o algoritmo recursivo atualiza o vetor de parâmetros, os quais são utilizados para atualizar o ganho estático da equação (5.4).

5.4 Detecção de curto-circuito inicial no MIT através da Estimação recursiva de Parâmetros utilizando modelo não linear

A estimação recursiva foi aplicada para atualizar os valores dos parâmetros e da curva estática não linear, de forma a detectar o curto-circuito. Novamente, será analisada a influência do fator de esquecimento na detecção do curto-circuito. Os dados experimentais são os mesmos utilizados no Capítulo 4.

Nas seções 5.4, 5.5 e 5.6 serão apresentados os resultados para a fase a, fase de ocorrência do curto-circuito. A seção 5.7 se dedica à apresentação dos resultados para as fases b e c.

5.4.1 Curto-Circuito em cerca de 1,5% das espiras do enrolamento de uma fase do estator do MIT

Os valores de fatores de esquecimento utilizados no algoritmo foram $\lambda = 0,9993$ e $\lambda = 1$, pois para fatores menores houve uma grande variância nos valores dos parâmetros. A matriz de covariância foi inicializada com valores iguais a $10^3 \times I_{4\times4}$, sendo $I_{4\times4}$ uma matriz identidade de ordem quatro; e o vetor de parâmetros foi inicializado com os valores encontrados na estimação em batelada, $\theta = [0,0756 \quad 0,2976 \quad -0,0113 \quad 0,0004]$.

Os resultados encontrados utilizando o fator de esquecimento $\lambda = 0,9993$ para o curto-circuito em 1,5% das espiras e variação de carga são apresentados nas **Tabelas 5.1** e **5.2** e nas **Figuras 5.5** e **5.6**.

Parâmetro	Média	Variância
θ_1 (operação normal)	0,0035	8,5930 × 10 ⁻⁶
θ_1 (curto-circuito)	0,0018	$2,7633 \times 10^{-6}$
θ_2 (operação normal)	0,2328	$4,0000 \times 10^{-3}$
θ_2 (curto-circuito)	-0,1182	$7,5464 \times 10^{-4}$
θ_3 (operação normal)	-0,0025	$5,1260 \times 10^{-6}$
θ_3 (curto-circuito)	-0,0012	$1,6784 \times 10^{-6}$
$ heta_4$ (operação normal)	$7,2140 \times 10^{-5}$	$2,7315 \times 10^{-10}$
θ_4 (curto-circuito)	$-5,1570 \times 10^{-5}$	$2,7309 \times 10^{-10}$

Tabela 5.1: Valores de média e variância dos parâmetros estimados recursivamente para os 7
ensaios realizados. Curto-circuito em 1,5% das espiras e $\lambda = 0,9993$.

Fonte: elaboração própria.

Tabela 5.2: Valores de média e variância dos parâmetros estimados recursivamente para os 7 ensaios realizados. Variação de carga e $\lambda = 0,9993$.

Parâmetro	Média	Variância
$\theta_1(I=4,12A)$	-0,0043	$8,9971 \times 10^{-8}$
$\theta_1(I=6,1A)$	-0,0013	$2,0655 \times 10^{-8}$
$\theta_2 \ (I=4,12A)$	0,4734	$3,1003 \times 10^{-5}$
$\theta_2(I=6,1A)$	0,7176	$4,1752 \times 10^{-6}$
$\theta_3 \ (I=4,12A)$	0,0010	$3,8067 \times 10^{-9}$
$\theta_3 \left(I = 6, 1A \right)$	$9,0995 \times 10^{-4}$	$2,7046 \times 10^{-8}$
$\theta_4 \ (I = 4,12A)$	$-8,0311 \times 10^{-4}$	$2,6558 \times 10^{-9}$
$\theta_4 \ (I=6,1A)$	$-4,2850 \times 10^{-5}$	$1,1414 \times 10^{-10}$

Fonte: elaboração própria.



(g) (h)
 Figura 5.5: Variação temporal dos parâmetros detectada pelo estimador recursivo com λ = 0,9993.
 (a), (c), (e) e (g) MIT passa da operação normal para a operação com curto-circuito em 1,5% das espiras. (b), (d), (f) e (h) Variação de carga. Fonte: elaboração própria.



Figura 5.6: Variação temporal dos parâmetros. (–, vermelho) Curto-circuito em 1,5% das espiras. (–, azul) Variação de carga. $\lambda = 0,9993$. (a) θ_1 , (b) θ_2 , (c) θ_3 e (d) θ_4 . Fonte: elaboração própria.

Os resultados obtidos utilizando o fator de esquecimento $\lambda = 1$ são apresentados nas **Tabelas 5.3** e **5.4** e nas **Figuras 5.7** e **5.8**.

Parâmetro	Média	Variância
θ_1 (operação normal)	0,0056	$2,1995 \times 10^{-7}$
θ_1 (curto-circuito)	0,0053	$3,5749 \times 10^{-7}$
θ_2 (operação normal)	0,4038	$7,9245 \times 10^{-4}$
θ_2 (curto-circuito)	0,2897	$3,5131 \times 10^{-5}$
θ_3 (operação normal)	-0,0042	$1,2687 \times 10^{-7}$
θ_3 (curto-circuito)	-0,0039	$2,1257 \times 10^{-7}$
θ_4 (operação normal)	$-1,0592 \times 10^{-4}$	$1,2523 \times 10^{-10}$
θ_4 (curto-circuito)	$-6,2075 \times 10^{-5}$	$2,7134 \times 10^{-11}$

Tabela 5.3: Valores de média e variância dos parâmetros estimados recursivamente para os 7
ensaios realizados. Curto-circuito em 1,5% das espiras e $\lambda = 1$.

Fonte: elaboração própria.



Figura 5.7: Variação temporal dos parâmetros detectada pelo estimador recursivo com $\lambda = 1$. (a), (c), (e) e (g) MIT passa da operação normal para a operação com curto-circuito em 1,5% das espiras. (b), (d), (f) e (h) Variação de carga. Fonte: elaboração própria.



Figura 5.8: Variação temporal dos parâmetros. (–, vermelho) Curto-circuito em 1,5% das espiras. (–, azul) Variação de carga. $\lambda = 1$. (a) θ_1 , (b) θ_2 , (c) θ_3 e (d) θ_4 . Fonte: elaboração própria.

Média	Variância
-0,0040	$1,5749 \times 10^{-8}$
-0,0011	$2,9711 \times 10^{-8}$
0,4939	$9,4049 \times 10^{-6}$
0,6992	$5,2618 \times 10^{-5}$
$8,9857 \times 10^{-4}$	$1,1724 \times 10^{-9}$
$5,4671 \times 10^{-4}$	$6,9184 \times 10^{-10}$
$-8,0440 \times 10^{-4}$	$1,2081 \times 10^{-9}$
$-4,0779 \times 10^{-5}$	$5,7100 \times 10^{-10}$
	Média $-0,0040$ $-0,0011$ $0,4939$ $0,6992$ $8,9857 \times 10^{-4}$ $5,4671 \times 10^{-4}$ $-8,0440 \times 10^{-4}$ $-4,0779 \times 10^{-5}$

Tabela 5.4: Valores de média e variância dos parâmetros estimados recursivamente para os 7 ensaios realizados. Variação de carga e $\lambda = 1$.

Fonte: elaboração própria.

Os resultados apresentados da Figura 5.5 à 5.8 mostram que é possível detectar o curto-circuito de 1,5% através do acompanhamento temporal dos

parâmetros do modelo não linear da equação (5.1). Além disso, o estimador recursivo consegue detectar, aproximadamente, o instante da ocorrência da falha, em torno da amostra 5000.

As **Figuras 5.6** e **5.8** mostram que os efeitos sobre os parâmetros são claramente diferentes da situação de curto-circuito de 1,5% para a variação de carregamento considerada. Os parâmetros $\theta_1 e \theta_2$ tendem ao crescimento durante o curto circuito, enquanto sofrem uma pequena mudança de patamar na variação de carga. O parâmetro θ_3 tende ao decrescimento durante o curto circuito, enquanto, novamente, sofre uma pequena mudança de patamar na variação de Carga do MIT. O parâmetro θ_4 pode ser considerado insensível à falha do MIT.

As **Tabelas 5.1, 5.2, 5.3** e **5.4** mostram que os resultados apresentados nas Figuras, relativos a somente um ensaio, são próximos quando se considera a média dos parâmetros obtidos recursivamente para os sete ensaios realizados. As **Tabelas 5.2** e **5.4** mostram que o parâmetro menos sensível à variação de carga é θ_3 , dessa forma este parâmetro realizará a detecção do curto-circuito de forma mais eficaz.

Os parâmetros estimados recursivamente com o fator de esquecimento $\lambda = 0,9993$ possuem uma maior variância do que aqueles estimados com $\lambda = 1$, como pode ser visto nas **Tabelas 5.1, 5.2, 5.3** e **5.4**.

Com os resultados obtidos com o modelo não linear da equação (5.1) aplicado na estimação recursiva de parâmetros para a detecção de curto-circuito em 1,5% nas espiras do enrolamento de estator do MIT, é possível afirmar que a detecção pode ser realizada de forma *on-line,* acompanhando-se a tendência dos parâmetros θ_1 , θ_2 e θ_3 do modelo da equação (5.1), mesmo com diferentes solicitações de carga.

5.4.2 Curto-Circuito em cerca de 3% das espiras do enrolamento de uma fase do estator do MIT

Novamente, os valores de fatores de esquecimento utilizados no algoritmo recursivo para a situação de curto-circuito de 3% foram $\lambda = 0,9993$ e $\lambda = 1$. A matriz de covariância foi inicializada com valores iguais a $10^3 \times I_{4\times4}$ e o vetor de parâmetros foi inicializado com os valores encontrados na estimação em batelada.

Os resultados obtidos utilizando o fator de esquecimento $\lambda = 0,9993$ são apresentados na **Tabela 5.5** e nas **Figuras 5.9 e 5.10**.

Parâmetro	Média	Variância
θ_1 (operação normal)	-0,0506	$5,1632 \times 10^{-6}$
θ_1 (curto-circuito)	-0,0426	$1,1974 \times 10^{-5}$
θ_2 (operação normal)	-0,1360	$7,5000 \times 10^{-3}$
θ_2 (curto-circuito)	-0,2376	$4,7000 \times 10^{-3}$
θ_3 (operação normal)	0,0394	$3,2357 \times 10^{-6}$
θ_3 (curto-circuito)	0,0336	7,6695 × 10 ⁻⁶
$ heta_4$ (operação normal)	$-1,2147 \times 10^{-4}$	$6,0569 \times 10^{-10}$
θ_4 (curto-circuito)	$-4,5650 \times 10^{-5}$	$2,3492 \times 10^{-10}$

Tabela 5.5: Valores de média e variância dos parâmetros estimados recursivamente para os 7
ensaios realizados. Curto-circuito em 3% das espiras e $\lambda = 0,9993$.

Fonte: elaboração própria.



Figura 5.9: Variação temporal dos parâmetros causada pelo curto-circuito em 3% das espiras detectada pelo estimador recursivo com $\lambda = 0,9993$. (a) θ_1 , (b) θ_2 , (c) θ_3 e (d) θ_4 . Fonte: elaboração própria.



Figura 5.10: Variação temporal dos parâmetros. (–, vermelho) Curto-circuito em 3% das espiras. (–, azul) Variação de carga. $\lambda = 0,9993$. (a) θ_1 , (b) θ_2 , (c) θ_3 e (d) θ_4 . Fonte: elaboração própria.

Os resultados obtidos utilizando o fator de esquecimento $\lambda = 1$ são apresentados na **Tabela 5.6** e nas **Figuras 5.11** e **5.12**.

Parâmetro	Média	Variância
θ_1 (operação normal)	-0,0427	$2,3555 \times 10^{-6}$
θ_1 (curto-circuito)	-0,0324	$5,3109 \times 10^{-7}$
θ_2 (operação normal)	0,0625	$1,3000 \times 10^{-3}$
θ_2 (curto-circuito)	0,1589	$1,4515 \times 10^{-4}$
θ_3 (operação normal)	0,0333	$1,4986 \times 10^{-6}$
θ_3 (curto-circuito)	0,0254	$2,9364 \times 10^{-7}$
θ_4 (operação normal)	$-7,4298 \times 10^{-5}$	$3,8060 \times 10^{-10}$
θ_4 (curto-circuito)	-3.2758×10^{-5}	$1,8279 \times 10^{-10}$

Tabela 5.6: Valores de média e variância dos parâmetros estimados recursivamente para os 7 ensaios realizados. Curto-circuito em 3% das espiras e $\lambda = 1$.

Fonte: elaboração própria.



Figura 5.11: Variação temporal dos parâmetros detectada pelo estimador recursivo causada pelo curto-circuito em 3% das espiras, $\lambda = 1$. (a) θ_1 , (b) θ_2 , (c) θ_3 e (d) θ_4 . Fonte: elaboração própria.



Figura 5.12: Variação temporal dos parâmetros. (–, vermelho) Curto-circuito em 3% das espiras. (–, azul) Variação de carga. $\lambda = 1$. (a) θ_1 , (b) θ_2 , (c) θ_3 e (d) θ_4 . Fonte: elaboração própria.

Os resultados apresentados da **Figura 5.9** à **Figura 5.12** mostram que os efeitos sobre os valores dos parâmetros causados pelo curto-circuito de 3% e a variação de carregamento do MIT considerada, novamente, são distintos. Durante o curto-circuito, $\theta_1 \in \theta_2$ tendem ao crescimento, enquanto θ_3 ao decrescimento. No entanto, esses parâmetros sofrem pequenas transições entre patamares na variação de carga. Com relação ao parâmetro θ_4 , sua mínima variação durante o curto-circuito não permite que este seja usado na detecção da falha.

É importante notar que o uso do fator de esquecimento $\lambda = 0,9993$ resulta numa maior variância nos valores dos parâmetros, o que dificulta distinguir operação normal e operação com falha.

Analisando-se da **Tabela 5.5** à **5.7**, verifica-se que os resultados apresentados da **Figura 5.9** à **5.12**, para um dos ensaios realizados, possuem características semelhantes quando utilizada a média dos resultados obtidos para os sete ensaios realizados. Novamente, a detecção do curto-circuito será mais eficaz com o acompanhamento do parâmetro θ_3 , devido a sua menor sensibilidade à variação de carregamento do motor.

É importante notar que acontece certo atraso na detecção do curto-circuito quando se diminui a influência do fator de esquecimento, aumentando o seu valor. Pode se perceber por meio das **Figura 5.9** à **5.12** que a detecção do curto-circuito acontece após cerca de 1,2*s* após sua ocorrência, o que não é crítico, devido ao valor mínimo de percentual de espiras em curto-circuito. A diminuição do valor do fator de esquecimento aumenta a sensibilidade do algoritmo e a velocidade de detecção, no entanto aumenta a variância dos valores dos parâmetros.

Dessa forma, é possível afirmar que os parâmetros θ_1 , θ_2 ou θ_3 do modelo da equação (5.1) podem ser utilizados na detecção *on-line* de curto-circuito incipiente no MIT, de 3%, acompanhando-se a tendência dos valores desses parâmetros.

5.5 Análise Estatística dos parâmetros estimados recursivamente

Histogramas foram construídos com as distribuições de frequências dos valores dos parâmetros diante de cada situação investigada, 2000 dados para cada condição. Foi utilizado o fator de esquecimento para o qual a variância dos

parâmetros foi menor, $\lambda = 1$. Os resultados são apresentados nas **Figuras 5.13**, **5.14** e **5.15**.

Estes histogramas sugerem que o modelo não linear permite a detecção da falha de curto-circuito incipiente no MIT, pois as distribuições de frequências dos parâmetros diante da operação normal e com curto-circuito são diferentes, havendo uma mínima sobreposição para o curto-circuito de 1,5%, **Figura 5.13**.

A **Figura 5.14** mostra que para o curto-circuito em 3% das espiras não há nenhuma sobreposição das distribuições de frequências. Esta análise estatística, juntamente com os resultados apresentados na seção 5.4, mostra a possibilidade da detecção das falhas de curto-circuito incipientes através dos parâmetros θ_1 , θ_2 ou θ_3 , mesmo havendo a variação de carregamento analisada no MIT.



Figura 5.13: Histograma das distribuições de frequências dos parâmetros, (a) θ_1 , (b) θ_2 , (c) θ_3 e (d) θ_4 . (-, cinza) Parâmetros do MIT com operação normal. (-, preto) Parâmetros do MIT operando com curto-circuito em 1,5% das espiras. $\lambda = 1$. Fonte: elaboração própria.



Figura 5.14: Histograma das distribuições de frequências dos parâmetros, (a) θ_1 , (b) θ_2 , (c) θ_3 e (d) θ_4 . (-, cinza) Parâmetros do MIT com operação normal. (-, preto) Parâmetros do MIT operando com curto-circuito em 3% das espiras. $\lambda = 1$. Fonte: elaboração própria.



Figura 5.15: Histograma das distribuições de frequências dos parâmetros, (a) θ_1 , (b) θ_2 , (c) θ_3 e (d) θ_4 . (-, cinza) Parâmetros do MIT operando com I = 4,12A. (-, preto) Parâmetros do MIT operando com I = 6,1A. $\lambda = 1$. Fonte: elaboração própria.

5.6 Influência do Ganho Estático não Linear na Detecção da Falha

Para mostrar como o ganho estático não linear influencia na detecção da falha, serão apresentados resultados obtidos com a aplicação da estrutura do modelo NARX polinomial, parte determinística da equação (5.1), na estimação recursiva de parâmetros sem a aplicação do ganho para o ajuste do ponto de operação do modelo.

Os resultados obtidos para o curto circuito em 1,5% e 3% das espiras, considerando a mudança de carga analisada, são apresentados nas **Figuras 5.16** e **5.17**, respectivamente. Ambos foram obtidos utilizando o fator de esquecimento $\lambda = 1$.



Figura 5.16: Variação temporal dos parâmetros. (–, vermelho) Curto-circuito em 1,5% das espiras. (–, azul) Variação de carga. $\lambda = 1$. (a) θ_1 , (b) θ_2 , (c) θ_3 e (d) θ_4 . Fonte: elaboração própria.



Figura 5.17: Variação temporal dos parâmetros. (–, vermelho) Curto-circuito em 3% das espiras. (–, azul) Variação de carga. $\lambda = 1$. (a) θ_1 , (b) θ_2 , (c) θ_3 e (d) θ_4 . Fonte: elaboração própria.

As **Figuras 5.16** e **5.17** mostram que a utilização do modelo NARX polinomial na estimação recursiva de parâmetros sem o ajuste do ganho, assim como o modelo linear da equação (4.1), torna o algoritmo recursivo insensível à falha em 1,5% das espiras e dificulta a detecção do curto de 3% diante da variação de carregamento considerada.

5.7 Detecção do curto-circuito através do acompanhamento das correntes e tensões das fases sem falha do MIT

Os resultados apresentados nas seções 5.4, 5.5 e 5.6 foram obtidos utilizando a corrente e a tensão da fase na qual ocorreu o curto-circuito, fase *a*. Dessa forma, esta seção se dedica a apresentar os resultados obtidos na estimação recursiva de parâmetros quando os dados utilizados são os dados das fases nas quais as espiras não estão em curto-circuito.

O fator de esquecimento utilizado será $\lambda = 1$, pois para este fator a detecção do curto-circuito foi mais eficaz, de acordo com os resultados apresentados na seção 5.4.

5.7.1 Detecção do curto-circuito em 1,5% das espiras utilizando os dados das fases $b \in c$

A estimação recursiva de parâmetros realizada utilizando os dados da fase b, V_b e I_b , quando 1,5% das espiras da fase a se encontram em curto-circuito, resultou nos parâmetros com as características apresentadas na **Figura 5.18**. Os resultados obtidos com dados da fase c, V_c e I_c , são apresentados na **Figura 5.19**.

As **Figuras 5.18** e **5.19** mostram que os parâmetros obtidos utilizando os dados das fases c e b não conseguem mostrar de forma clara a diferença entre operação normal e operação com curto-circuito.



Figura 5.18: Variação temporal dos parâmetros. (–, vermelho) Curto-circuito em 1,5% das espiras. (–, azul) Variação de carga. $\lambda = 1$. (a) θ_1 , (b) θ_2 , (c) θ_3 e (d) θ_4 . Fonte: elaboração própria.



Figura 5.19: Variação temporal dos parâmetros. (–, vermelho) Curto-circuito em 1,5% das espiras. (–, azul) Variação de carga. $\lambda = 1$. (a) θ_1 , (b) θ_2 , (c) θ_3 e (d) θ_4 . Fonte: elaboração própria.

5.7.1 Detecção do curto-circuito em 3% das espiras utilizando os dados das fases $b \in c$

A estimação recursiva de parâmetros realizada utilizando os dados da fase b, V_b e I_b , quando 3% das espiras da fase a se encontram em curto-circuito, resultou nos parâmetros com as características apresentadas na **Figura 5.20**. Os resultados obtidos com dados da fase c, V_c e I_c , são apresentados na **Figura 5.21**.

As **Figuras 5.20** e **5.21** mostram, novamente, que a detecção realizada com os dados das fases b e c é inexpressiva e indicam a dificuldade da detecção do curto-circuito nas espiras da fase a, quando os dados aplicados na estimação recursiva de parâmetros são referentes às fases b e c.



Figura 5.20: Variação temporal dos parâmetros. (–, vermelho) Curto-circuito em 3% das espiras. (–, azul) Variação de carga. $\lambda = 1$. (a) θ_1 , (b) θ_2 , (c) θ_3 e (d) θ_4 . Fonte: elaboração própria.



Figura 5.21: Variação temporal dos parâmetros. (–, vermelho) Curto-circuito em 3% das espiras. (–, azul) Variação de carga. $\lambda = 1$. (a) θ_1 , (b) θ_2 , (c) θ_3 e (d) θ_4 . Fonte: elaboração própria.

5.8 Conclusões do Capítulo

Os resultados obtidos com o modelo não linear da equação (5.1) não foram restritivos como os resultados obtidos com o modelo linear da equação (4.1). O acréscimo na complexidade do modelo trouxe maior representatividade da dinâmica do MIT, como apresentado na seção 5.2, e maior eficácia na detecção dos curtos-circuitos incipientes.

O comportamento do MIT avaliado pelo algoritmo recursivo na ocorrência de um curto-circuito ou na mudança de carga é claramente diferente, principalmente quando os dados utilizados na estimação são os dados da fase de ocorrência da falha. Dessa forma, para a correta detecção da falha de curto-circuito as três fases do MIT devem ser monitoradas.

Contudo, é possível afirmar que o modelo da equação (5.1) ganha maior representatividade quando o ganho não linear do modelo, equação (5.4), é ajustado recursivamente de acordo com cada ponto de operação do MIT. Esse modelo pode ser utilizado para a detecção *on-line* de curtos-circuitos incipientes, seja em 1,5% ou 3% das espiras, através do acompanhamento das tendências dos parâmetros θ_1 , θ_2 ou θ_3 , mesmo quando houver variação de carregamento do MIT. No entanto, a variação causada pelo curto-circuito é ainda mais clara no parâmetro θ_3 .

A utilização de um modelo não linear na identificação recursiva de parâmetros aplicada na detecção de curto-circuito incipiente no MIT mostrou-se aplicável, também, às faltas de 1,5%. Esse resultado é considerado expressivo, pois mesmo com um percentual considerável de espiras em curto-circuito o MIT pode continuar operando. Segundo Thomson e Fenger (2001), apesar de possuir um percentual de 20% das espiras em curto-circuito o motor por eles estudado funcionou durante 20 minutos antes da perda total do mesmo.

Um ponto importante a se observar é que os fatores de esquecimento que possibilitam a detecção da falha utilizando o modelo não linear são diferentes daqueles que foram utilizados para o modelo linear. Para a detecção da falha utilizando a estrutura do modelo não linear da equação (5.1) com o ganho ajustado como na seção 5.3, o fator de esquecimento dever ser $\lambda = 1$, ou seja, sem sua influência na estimação recursiva, pois para fatores menores a variância dos

parâmetros pode dificultar a distinção entre operação normal e com curto-circuito. No entanto, esta escolha causa um atraso na detecção do curto-circuito.

Uma escolha mal realizada para o fator de esquecimento pode impossibilitar a detecção da falha ou até acusar uma mudança de carregamento na máquina como um curto-circuito. Dessa forma, o usuário que for manipular esta metodologia de detecção de curto-circuito deverá escolher cuidadosamente o fator de esquecimento, o qual pode ser ajustado utilizando-se dados de simulação do modelo assimétrico do MIT, da seção 3.3, antes de se aplicar o estimador recursivo aos dados de operação real do MIT.

Capítulo 6

CONCLUSÃO

6.1 Considerações Gerais

Este trabalho apresentou uma metodologia para a obtenção de modelos dinâmicos identificados, os quais puderam ter suas estruturas utilizadas na estimação recursiva de parâmetros, possibilitando a detecção de falhas incipientes de curto-circuito nas espiras do estator de um motor de indução trifásico.

Tal metodologia aplicou modelos discretos aos dados amostrados para a implementação de um algoritmo em um microcomputador, o instrumento virtual. Essa técnica pode ser implementada com relativa facilidade em ambientes industriais, por fazer uso de dispositivos geralmente encontrados nesses locais.

A identificação dos modelos dinâmicos foi realizada utilizando dados simulados através do modelo proposto por Baccarini (2005). O emprego de dados simulados não exige o desligamento da máquina, ou seja, o processo produtivo da planta industrial não sofre nenhuma interrupção.

No entanto, como o objetivo deste trabalho é que o procedimento proposto seja aplicável aos processos reais, para a detecção da falha realizada pelo estimador recursivo utilizaram-se dados reais, coletados da bancada descrita na seção 3.4.2. Os dados experimentais reais continham informações de curtoscircuitos incipientes em cerca de 1,5% e 3% das espiras de uma das fases do estator e variações de carregamento do motor, cerca de 48,5% de variação.

O primeiro passo foi a identificação de um conjunto de modelos dinâmicos lineares ARMAX, dos quais aquele que apresentou os melhores resultados de validação, simplicidade e capacidade de detecção da falha foi apresentado no Capítulo 4. Mostrou-se que o modelo linear possui alguma deficiência em representar certas dinâmicas do MIT. No entanto ele foi capaz de detectar a situação de curto-circuito através da variação nos valores dos parâmetros, quando dados contendo esta informação foram utilizados na identificação do modelo em batelada. Dessa forma, a parte determinística da estrutura do modelo linear foi aplicada na estimação recursiva de parâmetros, resultando num modelo ARX de três parâmetros. Esses parâmetros foram atualizados pelo estimador recursivo, o qual utiliza os dados de forma sequencial, diante das condições de curto-circuito e

87

variação de carga avaliada. Os resultados mostraram-se restritivos, pois a variação de carregamento provocou importante variação nos valores dos parâmetros, o que dificulta a detecção da falha através do acompanhamento da tendência dos parâmetros em tempo real.

Objetivando a identificação de um modelo mais representativo, procedeu-se à identificação de modelos dinâmicos NARMAX polinomiais, dos quais aquele apresentado no Capítulo 5 estabeleceu o compromisso entre os resultados na validação, baixa complexidade e, também, conseguiu detectar em batelada a presença do curto-circuito. Novamente, a parte determinística do modelo foi utilizada na estimação recursiva de parâmetros, resultando em um modelo NARX polinomial de quatro parâmetros. O maior ganho na aplicação dessa representação é a possibilidade da utilização de informação auxiliar na construção da curva estática utilizando dados dinâmicos, através do conceito de agrupamento de termos. O ajuste da curva estática possibilitou o ajuste do ganho não linear do modelo, o qual adaptou o ponto de operação deste. Dessa forma, a variação nos valores dos parâmetros diante da variação de carregamento do motor foi mínima, quando comparada àquela sofrida pelos parâmetros diante do curto-circuito.

Durante o processo de estimação recursiva de parâmetros, vários fatores de esquecimento foram testados. Os resultados mostraram que este parâmetro possui grande influência na detecção da falha, sendo importante o seu ajuste, de forma a melhorar a sensibilidade do algoritmo.

6.2 Trabalhos Futuros

Com base nos estudos realizados neste trabalho, podem-se apontar algumas sugestões para trabalhos e pesquisas futuras:

- obter modelos para dados de motores em operação com inversores de frequência;
- considerar a análise de outros tipos de falhas no MIT, incluindo falhas mecânicas;

- construir uma interface homem-máquina para a detecção das falhas, de forma a deixar o método mais operacional no meio industrial.
- aplicar a metodologia desenvolvida para análise de falhas em outros sistemas.

REFERÊNCIAS BIBLIOGRÁFICAS

ABDALLA JÚNIOR, M. A.; SANTOS, A. P. L.; PADUA, C. E.; BARBOSA, A. M.; BARROSO, M. F. S. Identificação e Controle não linear de um processo térmico. In: **Congresso Brasileiro de Automática,** Bonito, 2010.

AGUIRRE, L. A. Introdução à Identificação de Sistemas, Técnicas Lineares e Não-Lineares Aplicadas a Sistemas Reais, 3. ed., UFMG, 2007.

AGUIRRE, L. A.; BILLINGS, S. A. Improved structure selection for nonlinear models based on term clustering. **International Journal of Control**, v. 62, n. 3, p. 569-587, 1995.

AGUIRRE, L. A.; BILLINGS, S. A. Validating Identified nonlinear models with chaotic dynamics. **International Journal of Bifurcation and Chaos**, v.4, n. 1, p. 109-125, 1994.

AGUIRRE, L.; CORREA, M.; CASSINI, C. C. S. Nonlinearities in NARX polynomial models: representation and estimation Control Theory and Applications, **IEE Proceedings**, n. 149, p. 343-348, 2002.

AGUIRRE, L. A.; DONOSCO-GARCIA, F.; SANTOS-FILHO, R. Use of *a* prior information in the identification of a global nonlinear models – a case study using a buck converter. **IEEE Transactions on Circuits and Systems – I**: Fundamental Theory and Applications, v. 47, n. 7, p. 1081-1085, 2000.

AKAIKE, H. A new look at the statistical model identification. **Automatic Control**, **IEEE Transactions on**, n. 19, p. 716-723, 1974.

ALMEIDA, M. T. **Manutenção preditiva**: benefícios e lucratividade. Relatório, Professor da Escola Federal de Engenharia de Itajubá. Consultor em Monitoramento de Máquinas pela MTA, 2010.

AVELAR, V. S.; BACCARINI, L. M. R.; AMARAL, G. F. V. Desenvolvimento de um sistema inteligente para diagnóstico de falhas nos enrolamentos do estator de motores de indução. **X SBAI – Simpósio Brasileiro de Automação Inteligente**, 2011.

AZEVEDO, H. R. T. de; SOUZA, S. P. S. de; MARTINS, F. R. S. Sistema para diagnóstico automático de falhas: Dificuldades e soluções para obtenção de resultados. **Artigo do XX congresso brasileiro de manutenção**. Belo Horizonte, 2005.

BACCARINI, L. M. R. **Detecção e Diagnóstico de Falhas em Motores de Indução**. Tese de Doutorado, Universidade Federal de Minas Gerais, Programa de Pós-Graduação em Engenharia Elétrica, 2005. BACCARINI, L. M. R.; MENEZES, B. R. de; CAMINHAS, W. M. Fault induction dynamic model, suitable for computer simulation: Simulation results and experimental validation. **Mechanical Systems and Signal Processing**, n. 21, p. 300-311, 2010.

BARENDSE, P. S.; HERNDLER, B., KHAN, M. A.; PILLAY, P. The application of wavelets for the detection of inter-turns faults in induction machines. **Proc. IEE** International Electric Machines and Drives Conference, p. 1401-1407, 2009.

BARROSO, M. F. S. **Métodos de Otimização Mono-Objetivo Aplicados à Identificação Caixa-Cinza de Sistemas Não-Lineares**. Dissertação de Mestrado, Universidade Federal de Minas Gerais, 2001.

BARROSO, M. F. S. **Otimização bi-objetivo aplicada à estimação de parâmetros de modelos não-lineares: caracterização e tomada de decisão**. Tese de Doutorado, Universidade Federal de Minas Gerais, 2006.

BARROSO, M. F. S.; TAKAHASHI, R.; AGUIRRE, L. Multi-objective parameter estimation via minimal correlation criterion. **Journal of Process Control**, v. 17, n. 4, p. 321-332, 2007.

BELLINI, A.; FILIPPETTI, F.; TASSONI, C.; CAPOLINO, G. A. Advances in Diagnostic Techniques for Induction Machines. **Industrial Electronics, IEEE Transactions on**, n. 55, p. 4109-4126, 2008.

BENBOUZID, M. E. H. A review of induction motors signature analysis as a medium for faults detection. **IEEE Transactions on Industrial Electronics**, n. 47, p. 984-993, 2000.

BILLINGS, S. Identification of nonlinear systems - a survey. **Control Theory and Applications, IEE Proceedings D**, n. 127, p. 272-285, 1980.

BILLINGS, S. A.; CHEN, S.; KORENBERG, M. J. Identification of mimo non-linear systems using a forward-regression orthogonal estimator. **International Journal of Control**, v. 59, n. 6, p. 2157-2189.

BILLINGS, S. A.; TAO, Q. H. Model validation and tests for nonlinear signal processing applications. **Int. J. Control**, n. 54, p. 157-194, 1991.

BILLINGS, S. A.; VOON, W., F., S. Correlation model validity tests for nonlinear models. **International Journal of Control**, v. 44, n. 1, p. 235-244.

BOQIANG, X.; HEMING, L.; LILING, S. Apparent impedance angle based detection of stator winding inter-turn short circuit fault in induction motors. Industry Applications Conference, 2003. **38th IAS Annual Meeting,** v. 2, n. 2, p. 1118-1125, 2003.

BRITO, J.; LAMIM FILHO, P. C. M.; SILVA, V. A. D.; PEDERIVA, R. Estudo comparativo entre técnica tradicional e técnica moderna para detecção de baixa
isolação em motores de indução trifásicos. **CONEM - VII Congresso Nacional de Engenharia Mecânica**, 2012.

CASSINI, C. C. S. **Estimação recursiva de características estáticas não lineares utilizando modelos polinomiais NARMAX**. Dissertação de Mestrado, Universidade Federal de Minas Gerais, 1999.

CHEN, S.; BILLINGS, S. A. Representations of non-linear systems the NARMAX model, *nt.* **J. Control**, v. 49, n. 3, p. 1013-1032, 1989.

CHEN, S.; BILLINGS, S. A.; LUO, W. Orthogonal least squares methods and their application to non-linear system identification. **International Journal of Control, Taylor & Francis**, n. 50, p. 1873-1896, 1989.

CHEN, J.; PATTON, R. J. Robust model-based fault diagnosis for dynamic systems. Boston: Kluwer, 1999.

D'ANGELO, M.; CAMINHAS, W.; MAIA, R.; PALHARES, R.; TAKAHASHI, R.; LEMOS, A. Detecção de falhas: Uma revisão com aplicações. **Tutoriais do XVIII CBA - Congresso Brasileiro de Automática**, p.1-47, 2011.

FILIPPETTI, F.; FRANCESCHINI, G.; TASSONI, C.; VAS, P. AI techniques in induction machines diagnosis including the speed ripple effect. **Industry Applications, IEEE Transactions on**, v. 34, n.1, p. 98-108, 1998.

FRANK, P. M. Fault diagnosis in dynamic systems using analytical and knowledge-based redundancy. **Automatica**, n. 26, p. 459-474, 1990.

FUNKQUIST, J. Grey-box Identification of a continuous digester – a distributed parameter process. **Control Eng. Practice**, v. 5, n. 7, p. 913-919, 1997.

GERTLER, J. Fault-detection and diagnosis in engineering systems. New York: Marcel Dekker, 1998.

GONÇALVES JÚNIOR, A. Sistema Especialista baseado em Superfícies de Resposta e Algoritmos Genéticos para diagnóstico de falhas em motores elétricos de indução. Dissertação de Mestrado, Universidade Federal de São João del-Rei, 2013.

GOUESBET, G., LETELLIER, C. Global vector Field reconstruction by using a multivariate polynomial l_2 approximation on nets. **Phys. Rev**. **E**, v. 49, n. 6, p. 4955-4972, 1994.

HEREDIA, G.; OLLERO, A. Virtual Sensor for Failure Detection, Identification and Recovery in the Transition Phase of a Morphing Aircraft. **Sensors**, n. 10, p. 2188-2201, 2010.

HIMMELBLAU, D. M. Fault-detection and diagnosis in chemical and petrochemical processes. Amsterdam: Elsevier, 1978.

ISERMANN, R. Estimation of physical parameters for dynamic processes with application to an industrial robot. **International Journal of Control**, n. 55, p. 1287-1298, 1992.

ISERMANN, R. Model-based fault-detection and diagnosis - status and applications. **Annual Reviews in Control**, n. 29, p. 71-85, 2005.

ISERMANN, R. Process fault-detection based on modelling and estimation methods – a survey. **Automatica**, n. 20, p. 387-404, 1984.

JOKSIMOVIC, G.; PENMAN, J. The detection of inter-turn short circuits in the stator windings of operating motors. **IEEE Transactions on Industrial Electronics**, n. 47, p. 1078-1084, 2000.

KOHLER, J. L.; SOTTILE, J.; TRUTT, F. C. Alternatives for assessing the electrical integrity of induction motor. **IEE Transactions on Industry Applications**, v. 38, n. 5, p. 1109-1117, 1992.

KRAUSE, Paul C.; WASYNCZUK, Oleg; SUDHOFF, Scott D. **Analysis of Electric Machinery and Drive Systems**. 2nd ed. Piscataway, NJ: IEEE Press, 2002.

LAMIM FILHO, P. C. M. Acompanhamento preditivo de motores de indução trifásicos através da análise de fluxo magnético. Tese de Doutorado. Universidade Estadual de Campinas, 2008.

LATHI, B. Sinais e Sistemas Lineares. 2. Ed. Bookman Companhia, 2007.

LEITE, A. V. T. Estimação de estados, parâmetros e velocidade do motor de indução trifásico com metodologias de identificação em tempo real. Dissertação de Mestrado, Faculdade de Engenharia da Universidade do Porto, 2004.

LJUNG, L. System Identification - Theory For the User. 2nd ed. Prentice Hall, 1999.

CARDOSO, A. J. M.; CRUZ, S. M. A.; FONSECA, D. S. B. Inter-turn stator winding fault diagnosis in three-phase induction motors, by Park's vector approach. **IEEE Transactions on Energy Convertion**, v. 14, n. 3, p. 595-598, 1999.

MARTINS, S. A. M.; NEPOMUCENO, E. G.; FIGUEIREDO, J. P. Detecção de estruturas de modelos narmax polinomiais: uma abordagem inteligente multiobjetivo. **X SBAI – Simpósio Brasileiro de Automação Inteligente**, 2011.

MASSIRER, D. A. Sistema especialista protótipo para auxílio à verificação da estrutura de produto de motores elétricos. Universidade Federal de Santa Catarina, 2007.

MATKO, D.; KARBA, R.; ZUPANCIC, B. Simulation and modelling of continuous systems: A case study approach. **Automatica**, n. 30, p. 1808-1810, 1994.

MENDES, E. M. A. M.; BILLINGS, S. A. An alternative solution to the model structure selection problem, **IEEE Trans. Man Cybernetics** – Part A, v. 36, n. 21, p. 597-608, 2001.

NEPOMUCENO, E. G. **Identificação multiobjetivo de sistemas não lineares**. Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais, 2002.

OGATA, K. Engenharia de Controle Moderno, 5. ed. Pearson Pretice Hall, 2011.

PATTON, R. J.; FRANK, P. M.; CLARK, P. N. (Eds.). Issues of fault diagnosis for dynamic systems. Berlin: Springer, 2000.

POTTMAN, M.; PEARSON, R. Block-oriented NARMAX models with output multiplicities. **AICHE Journal**, v. 44; n.1, p. 131-149, 1998.

RADHIKA, S.; SABAREESH, G.; JAGADANAND, G.; SUGUMARAN, V. Precise wavelet for current signature in 3 im. **Expert Systems with Applications: An International Journal**, n. 37, p. 450-455, 2010.

SANTOS, A. P. L.; MILAGRES, N. L.; CAMPOS, A. A.; MARGOT, L.; AMARAL, G. F. V.; BARROSO, M. F. S. Aplicação de representações em blocos interconectados em identificação caixa-cinza de sistemas dinâmicos não lineares. In: **Congresso Brasileiro de Automática**, Bonito, 2010.

SANTOS, F. M. D. C.; SILVA, I. N. D.; SUETAKE, M. Sobre a aplicação de sistemas inteligentes para diagnóstico de falhas em máquinas de indução - uma visão geral. **Sba: Controle & Automação, Sociedade Brasileira de Automatica**, n. 23, p. 553-569, 2012.

STOICA, P.; JANSSEN, P.; SÖDERTRÖM, T. Model-structure seletion by cross-validation. International J. Control, v. 43, n. 6, p. 1841-1878, 1986.

TALLAM, R.; HABETLER, T.; HARLEY, R. Transient model for induction machines with stator winding turn faults. **Industry Applications, IEE Transactions on, Conference, 2000. Conference Record of the 2000 IEEE**, v. 38, n. 3, p. 632-637, 2002.

THOMSON, W.; FENGER, M. Current signature analysis to detect induction motor faults. **Industry Applications Magazine, IEEE**, n. 7, p. 26-34, 2001.

VÁNA, Z.; PREISIG, H. A. System identification in frequency domain using wavelets: Conceptual remarks. **Systems & Control Letters**, n. 61, p. 1041-1051, 2012. WILLSKY, A. S. A survey of design methods for failure detection in dynamic systems. **Automatica**, n. 12, p. 601-611, 1976.

XIE, S.; ZHANG, Y.; CHEN, C.; ZHANG, X. Identification of nonlinear hysteretic systems by artificial neural network. **Mechanical Systems and Signal Processing**, n. 34, p. 76-87, 2013.

YE, Zhongming; WU, Bin; SADEGHIAN, A. Current signature analysis of induction motor mechanical faults by wavelet packet decomposition. **Industrial Electronics**, **IEEE Transactions on**, v. 50, n. 6, p. 1217-1228, 2003.

ZHAO, J.; CHEN, W.; XU, W. Nonlinear System Identification Based on Radial Basis Function Neural Network Using Improved Particle Swarm Optimization. **Natural Computation. Fifth International Conference on**, n. 2, p. 409-413, 2009.