

**ANÁLISE DE COMPENSAÇÃO DE FALTA EM
SENSORES APLICADA EM CONTROLE DE
MOTORES**

LUIGI GALOTTO JUNIOR

CAMPO GRANDE

2006

UNIVERSIDADE FEDERAL DO MATO GROSSO DO SUL
PROGRAMA DE PÓS-GRADUAÇÃO
EM ENGENHARIA ELÉTRICA

ANÁLISE DE COMPENSAÇÃO DE FALTA EM
SENSORES APLICADA EM CONTROLE DE
MOTORES

Dissertação submetida à
Universidade Federal de Mato Grosso do Sul
como parte dos requisitos para a
obtenção do grau de Mestre em Engenharia Elétrica.

LUIGI GALOTTO JUNIOR

Campo Grande, 1 de setembro de 2006.

ANÁLISE DE COMPENSAÇÃO DE FALTA EM SENSORES APLICADA EM CONTROLE DE MOTORES

Luigi Galotto Junior

‘Esta Dissertação foi julgada adequada para obtenção do Título de Mestre em Engenharia Elétrica, Área de Concentração em *Energia Elétrica*, e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Campo Grande.’

Professora Luciana Cambraia Leite, Doutora
Orientadora

Professor João Onofre Pereira Pinto, Doutor
Coordenador do Programa de Pós-Graduação em Engenharia Elétrica

Banca Examinadora:

Professor Luiz Eduardo Borges da Silva, Doutor

Professor Milton Ernesto Romero Romero, Doutor

A Deus e a minha família

AGRADECIMENTOS

Agradeço primeiramente àqueles a quem dedico este trabalho: a Deus pela força e inspiração que me mantêm prosseguindo na busca pelo conhecimento e pela melhoria da vida das pessoas; e a minha família pelo apoio e compreensão nos momentos necessários de minha ausência.

Aos meus professores que me ensinaram e me direcionaram, em especial, aos meus orientadores: professora Luciana, pelo acompanhamento e auxílio nas correções do trabalho; e professor João Onofre pelas valiosas contribuições na forma e no conteúdo sem as quais o trabalho não teria a mesma qualidade.

Ao professor Milton pela experiência e conhecimento nas teorias de tolerância à falta e ao professor Luís pela experiência com controle de motores, pelo bom humor e estímulo de me fazer vestir formalmente para a apresentação (exceto pela gravata, que faltou... ou falhou).

Ao professor Hines, embora não entenda português, pela recepção na Universidade do Tennessee onde pude iniciar o desenvolvimento deste trabalho e pelo aprendizado durante as suas aulas de verão que me deram a base essencial para a compreensão dos modelos baseados em dados.

Aos colegas e professores participantes do Batlab por compartilharem os bons momentos e aprendizados e pelo trabalho perseverante que já nos fez crescer tanto e que a cada dia nos aproxima mais de nos tornarmos um grande centro de pesquisa.

E a todos aqueles que de alguma forma contribuíram para a minha formação.

Resumo da Dissertação apresentada à UFMS como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia Elétrica.

ANÁLISE DE COMPENSAÇÃO DE FALTA EM SENSORES APLICADA EM CONTROLE DE MOTORES

Luigi Galotto Junior

Março/2006

Orientador: Professora Luciana Cambraia Leite, Doutora.

Área de Concentração: *Energia Elétrica*.

Palavras-chave: Falta de Sensores, Sistemas de Controle, Tolerância à falta, Modelos Auto-Associativos.

Número de Páginas: 162

RESUMO: Atualmente, existem diversas aplicações críticas onde a confiabilidade é extremamente importante para manter a segurança, a organização e a economia. No passado, os sistemas eram projetados para serem livres de falta, mas isso é irrealista já que as faltas são inevitáveis. Por essa razão, surgiu o estudo de sistemas tolerantes à falta que tem crescido rapidamente nas últimas décadas. Em sistemas de controle e automação, muitos trabalhos têm sido feitos para torná-los tolerantes à falta. Contudo, pouco se tem feito com relação aos sensores, que também são suscetíveis à faltas e têm muita importância para o bom funcionamento do sistema. Esse trabalho explora o uso de modelos na realimentação dos sistemas de controle para superar este problema. Em comparação com outras técnicas existentes, a metodologia apresentada mostrou generalização da detecção e compensação de faltas em sensores. Os resultados apresentados mostram as conseqüências da aplicação desta metodologia no controle vetorial de motores de indução. Uma técnica chamada de modelos parciais para o aperfeiçoamento das estimações também foi desenvolvida neste trabalho. A compensação dos sensores de corrente foi avaliada com o uso de dois a seis sensores de corrente para cada um dos modelos. Os modelos parciais se mostraram muito superiores em

relação aos demais, com uma compensação quase perfeita a partir de cinco sensores de corrente. Com menos sensores, eles são semelhantes aos modelos lineares.

Abstract of Dissertation presented to UFMS as a partial fulfillment of the requirements for the degree of Master in Electrical Engineering.

SENSORS FAULT COMPENSATION ANALYSIS APPLIED IN MOTOR CONTROL

Luigi Galotto Junior

March / 2006

Advisor: Professor Luciana Cambraia Leite, Ph.D.

Area of Concentration: Electrical Energy.

Keywords: Sensors Fault, Control Systems, Fault Tolerance, Auto-Associative Models.

Number of Pages: 162

ABSTRACT: Nowadays, there are several critical applications where reliability is extremely important for safety, organization and economy. In the past, systems used to be designed to be fault free, but it is unrealistic because faults are inevitable. For that reason, it has raised the study of fault tolerant systems that has grown fast in the latest decades. In automation and control systems, much work has already been done in order to make them fault tolerant. However, few things have been done related with sensors, which are also susceptible to faults and are essential for the good operation of the system. This work explores the use of models in the feedback in order to overcome this problem. In comparison with other existent techniques, the presented methodology showed generalization of sensors fault detection and compensation. A technique called partial models to improve the estimations has also been developed in this work. The results show the consequences of applying this methodology in induction motor vector control. In addition, an example of application in motor control is presented and explored for evaluation of the proposed techniques. The compensation of current sensors was evaluated using from two to six current sensors for each model. The partial models have shown to be very superior in relation to the other, with an almost perfect compensation starting from five current sensors. They are similar to the linear models with fewer sensors.

SUMÁRIO

1.	Introdução.....	1
1.1.	Importância da Confiabilidade	1
1.1.1.	Atributos	3
1.1.2.	Ameaças.....	4
1.1.3.	Meios.....	5
1.1.4.	Considerações Gerais	7
1.2.	Sistemas de Controle Tolerantes à Falta	8
1.2.1.	Sistema de Controle Tolerante à Falta Passivo.....	9
1.2.2.	Sistema de Controle Tolerante a Falta Ativo.....	9
1.2.3.	Falta em Sistemas Dinâmicos	10
1.2.4.	Detecção de Falta e Isolamento.....	11
1.3.	O Problema da Falta em Sensores	12
1.3.1.	Falta nos Sensores em Controle de Motores.....	14
1.4.	Organização e Objetivos do Trabalho	16
2.	Metodologia.....	17
2.1.	Considerações Iniciais	17
2.2.	Controle Vetorial de Máquinas de Indução	18
2.2.1.	Analogia com o Controle de Motor de Corrente Contínua	18
2.2.2.	Transformação d-q.....	20
2.3.	Realimentação de Estimações	21
2.3.1.	Análise da Resposta Dinâmica.....	23
2.3.2.	Comparação com os Observadores de Estado	25
2.3.3.	Melhoria da Confiabilidade.....	26
2.4.	Utilizações da Redundância.....	26
2.5.	Etapas de Desenvolvimento do Trabalho.....	28
3.	Técnicas de Modelagem	29
3.1.	Convenções	29
3.2.	Medidas de Desempenho.....	31
3.2.1.	Erro Quadrático Médio.....	32

3.2.2.	Sensibilidade.....	32
3.2.3.	Filtragem.....	33
3.2.4.	Meta de Desempenho	33
3.3.	Regressão Linear.....	34
3.3.1.	Regularização e Regressão Ridge	35
3.3.2.	Sensibilidade do Modelo Linear	36
3.4.	Regressão Kernel	37
3.4.1.	Influência da Largura de Banda nas Estimacões	38
3.5.	Técnica de Estimacão de Estado Multivariável	39
3.5.1.	Operador Similaridade	40
3.5.2.	Formulacão	40
3.6.	Redes Neurais Auto-associativas	42
4.	Modelos Parciais	44
4.1.	Introdução.....	44
4.2.	Particionamento dos modelos.....	46
4.3.	Sinais de Teste.....	48
4.4.	Desempenho.....	52
4.5.	Detecção de Falta	55
5.	Compensacão de Sensores em Controle de Motores	58
5.1.	Introdução.....	58
5.2.	Redundância nas Medidas de Corrente	62
5.3.	Resultados com Três Sensores de Corrente	63
5.4.	Resultados com Quatro Sensores de Corrente	69
5.5.	Resultados com Cinco Sensores de Corrente.....	75
5.6.	Resultados com Seis Sensores de Corrente.....	80
5.7.	Comparacão dos Resultados.....	86
6.	Conclusões.....	89

LISTA DE FIGURAS

<i>Número</i>	<i>Página</i>
Figura 1.1. Atributos da Confiabilidade.....	4
Figura 1.2. Ameaças da Confiabilidade.....	4
Figura 1.3. Meios de Obter Confiabilidade.....	6
Figura 1.4. Definições Gerais da Confiabilidade.....	8
Figura 1.5. Classificação de Sistemas de Controle Tolerantes à Falta.....	9
Figura 1.6. Sistema de Controle Tolerante à Falta Ativo.....	10
Figura 1.7. Potenciais Locais de Falhas.....	11
Figura 1.8. Procedimento de Detecção de Falta.....	12
Figura 1.9. Prioridades de um Sistema de Controle Realimentado.....	13
Figura 2.1. Eixos de um Motor de Corrente Contínua.....	19
Figura 2.2. Equivalência entre os Eixos Trifásicos e os Eixos d-q.....	20
Figura 2.3. Controle Realimentado com Estimações usando Sensores Redundantes.....	23
Figura 2.4. Modelo Básico.....	27
Figura 3.1. Representação dos Modelos Utilizados.....	29
Figura 3.2. Notação Utilizada.....	30
Figura 3.3. Ilustração de um Modelo Instável.....	35
Figura 3.4. Funcionamento da Regressão Kernel.....	37
Figura 3.5. Estimações para uma Grande Largura de Banda.....	38
Figura 3.6. Estimações para uma Pequena Largura de Banda.....	39
Figura 3.7. Arquitetura Geral de uma Rede Neural Auto-Associativa.....	42
Figura 4.1. Exemplo de Votação da Maioria.....	45
Figura 4.2. Diagrama dos Modelos Parciais.....	46
Figura 4.3. Ilustração da Estimação de um Triângulo com um Modelo Convencional.....	47
Figura 4.4. Ilustração da Estimação de um Triângulo com Modelos Parciais.....	47
Figura 4.5. Sinais de Entrada.....	48
Figura 4.6. Sinais de Entrada com Falta Simulada.....	49
Figura 4.7. Modelos Parciais Lineares.....	50
Figura 4.8. Modelos Parciais Kernel.....	51

Figura 4.9. Modelos Parciais com MSET	51
Figura 4.10. Modelos Parciais com RNAA	52
Figura 4.11. Performance com Regressão Linear	53
Figura 4.12. Performance com RKAA	53
Figura 4.13. Performance com MSET	54
Figura 4.14. Performance com RNAA	54
Figura 4.15. Detecção de Falhas e Alarmes Falsos com Modelos Lineares.....	56
Figura 4.16. Detecção de Falhas e Alarmes Falsos com RKAA	56
Figura 4.17. Detecção de Falhas e Alarmes Falsos com MSET	57
Figura 4.18. Detecção de Falhas e Alarmes Falsos com RNAA	57
Figura 5.1. Efeitos na Velocidade da Falta no Sensor de Corrente.....	59
Figura 5.2. Correntes de Alimentação Reais e Medidas	60
Figura 5.3. Correntes do Eixo Direto e em Quadratura Com Falta e Sem Falta	61
Figura 5.4. Torque Com Falta e Sem Falta.....	62
Figura 5.5. Resposta da Velocidade Utilizando um Modelo Linear com Três Sensores	64
Figura 5.6. Resposta de Velocidade com o Modelo Kernel com Três Sensores	66
Figura 5.7. Resposta de Velocidade com o Modelo MSET com Três Sensores	67
Figura 5.8. Resposta de Velocidade com o Modelo RNAA com Três Sensores	68
Figura 5.9. Resposta com o Modelo Parcial Linear com Três Sensores.....	69
Figura 5.10. Resposta com Modelo Linear com Quatro Sensores de Corrente.....	70
Figura 5.11. Resposta com o Modelo Kernel com Quatro Sensores de Corrente	71
Figura 5.12. Resposta com o Modelo MSET com Quatro Sensores de Corrente	72
Figura 5.13. Resposta com o Modelo RNAA com Quatro Sensores.....	73
Figura 5.14. Resposta com o Modelo Parcial Linear com Quatro Sensores	74
Figura 5.15. Resposta com Modelo Linear com Cinco Sensores	75
Figura 5.16. Resposta com Modelo Kernel com Cinco Sensores	76
Figura 5.17. Resposta com o Modelo MSET com Cinco Sensores	77
Figura 5.18. Resposta com o Modelo RNAA com Cinco Sensores	78
Figura 5.19. Resposta com o Modelo Parcial Linear com Cinco Sensores	79
Figura 5.20. Resposta com o Modelo Linear com Seis Sensores	81
Figura 5.21. Resposta com o Modelo Kernel com Seis Sensores	82
Figura 5.22. Resposta com o Modelo MSET com Seis Sensores	83

Figura 5.23. Resposta com o Modelo RNAA com Seis Sensores	84
Figura 5.24. Resposta com o Modelo Parcial Linear com Seis Sensores	85
Figura 5.25. Resumo dos Erros Propagados Totais Percentuais	86
Figura 5.26. Resumo dos Ruídos Propagados Totais Percentuais	88
Figura A1.1. Sistema de Controle Vetorial com Motor de Indução	97
Figura A1.2. Detalhe do Controle Vetorial.....	98
Figura A1.3. Detalhe do Motor de Indução	98
Figura A1.4. Aplicação do Erro	99
Figura A1.5. Detalhe do Bloco de Aplicação do Erro.....	100
Figura A2.1. Dados Utilizados para a Memória dos Modelos	103
Figura A2.2. Modelo Parcial Linear com Três Sensores de Corrente	104
Figura A2.3. Modelo Parcial Linear com Seis Sensores de Corrente.....	104
Figura A3.1. Correntes de Linha Utilizando um Modelo Linear com 3 Sensores	106
Figura A3.2. Correntes d-q Utilizando um Modelo Linear com 3 Sensores	107
Figura A3.3. Torque Utilizando um Modelo Linear com 3 Sensores.....	107
Figura A3.4. Correntes de Linha com o Modelo Kernel com 3 Sensores	108
Figura A3.5. Correntes d-q com o Modelo Kernel com 3 Sensores	109
Figura A3.6. Torque com o Modelo Kernel com 3 Sensores.....	110
Figura A3.7. Correntes de Linha com o Modelo MSET com 3 Sensores	111
Figura A3.8. Correntes d-q com o Modelo MSET com Três Sensores	112
Figura A3.9. Torque com o Modelo MSET com 3 Sensores.....	112
Figura A3.10. Correntes de Linha com o Modelo RNAA com 3 Sensores.....	113
Figura A3.11. Correntes d-q com o Modelo RNAA com 3 Sensores.....	114
Figura A3.12. Torque com o Modelo RNAA com 3 Sensores	114
Figura A3.13. Correntes de Linha com o Modelo Parcial Linear com 3 Sensores	115
Figura A3.14. Correntes d-q com o Modelo Parcial Linear com 3 Sensores	116
Figura A3.15. Torque com o Modelo Parcial Linear com 3 Sensores.....	116
Figura A3.16. Correntes de Linha com o Modelo Linear com 4 Sensores.....	117
Figura A3.17. Correntes d-q com o Modelo Linear com 4 Sensores.....	118
Figura A3.18. Torque com o Modelo Linear com 4 Sensores	118
Figura A3.19. Correntes de Linha com o Modelo Kernel com 4 Sensores	119
Figura A3.20. Correntes d-q com o Modelo Kernel com 4 Sensores	120

Figura A3.21. Torque com o Modelo Kernel com 4 Sensores.....	120
Figura A3.22. Correntes de Linha com o Modelo MSET com 4 Sensores	121
Figura A3.23. Correntes d-q com o Modelo MSET com 4 Sensores	122
Figura A3.24. Torque com o Modelo MSET com 4 Sensores.....	122
Figura A3.25. Correntes de Linha com o Modelo RNAA com 4 Sensores.....	123
Figura A3.26. Correntes d-q com o Modelo RNAA com 4 Sensores.....	124
Figura A3.27. Torque com o Modelo RNAA com 4 Sensores	124
Figura A3.28. Correntes de Linha com o Modelo Parcial Linear com 4 Sensores	125
Figura A3.29. Correntes d-q com o Modelo Parcial Linear com 4 Sensores	126
Figura A3.30. Torque com o Modelo Parcial Linear com 4 Sensores.....	126
Figura A3.31. Correntes de Linha com o Modelo Linear com 5 Sensores.....	127
Figura A3.32. Correntes d-q com o Modelo Linear com 5 Sensores.....	128
Figura A3.33. Torque com o Modelo Linear com 5 Sensores	128
Figura A3.34. Correntes de Linha com o Modelo Kernel com 5 Sensores	129
Figura A3.35. Correntes d-q com o Modelo Kernel com 5 Sensores	130
Figura A3.36. Torque com o Modelo Kernel com 5 Sensores.....	130
Figura A3.37. Correntes de linha com o Modelo MSET com 5 Sensores.....	131
Figura A3.38. Correntes d-q com o modelo MSET com 5 Sensores.....	132
Figura A3.39. Torque com o Modelo MSET com 5 Sensores.....	132
Figura A3.40. Correntes de Linha com o Modelo RNAA com 5 Sensores.....	133
Figura A3.41. Correntes d-q com o Modelo RNAA com 5 Sensores.....	134
Figura A3.42. Torque com o Modelo RNAA com 5 Sensores	134
Figura A3.43. Correntes de Linha com o Modelo Parcial Linear com 5 Sensores	135
Figura A3.44. Correntes d-q com o Modelo Parcial Linear com 5 Sensores	136
Figura A3.45. Torque com o Modelo Parcial Linear com 5 Sensores.....	136
Figura A3.46. Correntes de Linha com o Modelo Linear com 6 Sensores.....	137
Figura A3.47. Correntes d-q com o Modelo Linear com 6 Sensores.....	138
Figura A3.48. Torque com o Modelo Linear com 6 Sensores	138
Figura A3.49. Correntes de Linha com o Modelo Kernel com 6 Sensores	139
Figura A3.50. Correntes d-q com o Modelo Kernel com 6 Sensores	140
Figura A3.51. Torque com o Modelo Kernel com 6 Sensores.....	140
Figura A3.52. Correntes de Linha com o Modelo MSET com 6 Sensores	141

Figura A3.53. Correntes d-q com o Modelo MSET com 6 Sensores	142
Figura A3.54. Torque com o Modelo MSET com 6 Sensores.....	142
Figura A3.55. Correntes de Linha com o Modelo RNAA com 6 Sensores.....	143
Figura A3.56. Correntes d-q com o Modelo RNAA com 6 Sensores.....	144
Figura A3.57. Torque com o Modelo RNAA com 6 Sensores	144
Figura A3.58. Correntes de Linha com o Modelo Parcial Linear com 6 Sensores	145
Figura A3.59. Correntes d-q com o Modelo Parcial Linear com 6 Sensores	146
Figura A3.60. Torque com o Modelo Parcial Linear com 6 Sensores.....	146

LISTA DE TABELAS

<i>Número</i>	<i>Página</i>
Tabela 4.I. Melhoria da qualidade com o uso de modelos parciais	55
Tabela 5.I. Redundância em relação ao número de sensores	63
Tabela 5.II. Sensibilidade do modelo linear com 3 sensores	65
Tabela 5.III. Sensibilidade do modelo kernel com 3 sensores	66
Tabela 5.IV. Sensibilidade do modelo MSET com 3 sensores	67
Tabela 5.V. Sensibilidade do modelo RNAA com 3 sensores.....	68
Tabela 5.VI. Sensibilidade do modelo parcial linear com 3 sensores.....	69
Tabela 5.VII. Sensibilidade do modelo linear com 4 sensores	71
Tabela 5.VIII. Sensibilidade do modelo kernel com 4 sensores	72
Tabela 5.IX. Sensibilidade do modelo MSET com 4 sensores	72
Tabela 5.X. Sensibilidade do modelo RNAA com 4 sensores.....	73
Tabela 5.XI. Sensibilidade do modelo parcial linear com 4 sensores.....	74
Tabela 5.XII. Sensibilidade do modelo linear com 5 sensores	76
Tabela 5.XIII. Sensibilidade do modelo kernel com 5 sensores	77
Tabela 5.XIV. Sensibilidade do modelo MSET com 5 sensores	78
Tabela 5.XV. Sensibilidade do modelo RNAA com 5 sensores.....	79
Tabela 5.XVI. Sensibilidade do modelo parcial linear com 5 sensores.....	80
Tabela 5.XVII. Sensibilidade do modelo linear com 6 sensores	81
Tabela 5.XVIII. Sensibilidade do modelo kernel com 6 sensores	82
Tabela 5.XIX. Sensibilidade do modelo MSET com 6 sensores	83
Tabela 5.XX. Sensibilidade do modelo RNAA com 6 sensores.....	84
Tabela 5.XXI. Sensibilidade do modelo parcial linear com 6 sensores.....	85
Tabela 5.XXII. Erros propagados pelos modelos.....	86
Tabela 5.XXIII. Erro quadrático médio dos modelos	87
Tabela 5.XXIV. Filtragem dos modelos	88
Tabela 5.XXV. Dados do motor utilizado na simulação.....	99

1. INTRODUÇÃO

Não há nada indestrutível ou cem por cento confiável. Entretanto, o aumento da confiabilidade das máquinas, dos equipamentos e dos sistemas é possível e necessário conforme a criticidade dos mesmos. Existem diversas maneiras para aumentar a confiabilidade, mas constantemente são elaboradas alternativas para atingir a máxima confiabilidade com o mínimo custo.

Neste capítulo serão apresentados os fundamentos dos estudos que classificam e buscam a confiabilidade. Os objetivos e a organização deste trabalho serão detalhados no final deste capítulo.

1.1. IMPORTÂNCIA DA CONFIABILIDADE

Certamente, a necessidade da confiabilidade é mais antiga do que se tem conhecimento na literatura. Os homens do passado precisavam de barcos mais seguros, ferramentas mais duradouras, muros mais resistentes e trabalhavam com este afincamento ainda que não criassem definições ou metodologias para isto. Com o avanço da humanidade, a necessidade de rigor do estudo da confiabilidade se tornou imprescindível. Diversos estudos com o objetivo de melhorar a confiabilidade de sistemas têm sido feitos recentemente devido ao crescente número de aplicações críticas. Processos industriais, usinas nucleares, robôs cirúrgicos são alguns exemplos dessas aplicações. Para tais aplicações, as consequências de uma falta podem ser catastróficas e a confiabilidade se torna mais importante do que o custo.

As aplicações críticas podem ser classificadas como: sistemas de segurança crítica (reatores nucleares [1], aviões [2], sistemas de guia de mísseis), sistema de custo crítico (grandes estruturas espaciais, veículos espaciais, veículos submarinos autônomos), e sistemas de volume crítico (linhas de montagem em indústrias automobilísticas, redes de

comunicação móvel, rodovias automatizadas). Em outras palavras, esses sistemas podem levar a perda de muitas vidas (segurança), a perda de objetos muito caros (custo) ou ao caos em grandes sistemas (volume).

Para aplicações tão delicadas e de conseqüências tão severas em caso de falha, estudos minuciosos são feitos de modo a evitar essas conseqüências. Ainda há a possibilidade da diminuição do custo de sistemas com alta confiabilidade viabilizando o uso destes em outras aplicações não-críticas. Visto que a confiabilidade sempre é desejável a todos os sistemas, mas para altos custos ela se justifica somente com a gravidade das aplicações.

Um trabalho de 1834 [3], reimpresso em 1961, apresenta os conceitos fundamentais da computação confiável. Deste modo, esses conceitos começaram a ser definidos inicialmente para sistemas computacionais. No final dos anos 60, surgiu a definição de *survivability* no meio militar como sendo a probabilidade de sobreviver à missão designada [4]. Em outubro de 1980, uma assembléia geral do IFIP (*International Federation for Information Processing*) pelo comitê técnico 10 (TC-10) estabeleceu o grupo de trabalho 10.4 (WG 10.4) que foi revisado em 1988 e define *dependable* como “[...] *the trustworthiness of a computing system which allows reliance to be justifiably placed on the service it delivers [...]*” [5]. Acrescentando também os atributos desta propriedade como: *reliability*, *availability*, *safety* e *security*. Em alguns trabalhos, *trustworthiness* também é definida separadamente de maneira semelhante a *survivability* e a *dependability*, mas de maneira geral as três palavras procuram definir a mesma qualidade. A *survivability* apenas enfatiza a segurança como o principal atributo, supondo que o sistema sofre ataques freqüentes e severos como é típico de situações militares. Em trabalhos mais recentes [4, 6], outros atributos como *maintainability*, *integrity* e *confidentiality* são apresentados e o *security* é considerado como um conjunto dos dois últimos.

Como pode ser notado, um conceito final e genérico da confiabilidade ainda não está bem definido. Muitas vezes, essas definições são específicas para a computação. Além disso, a escolha das palavras e a tradução para a língua portuguesa ainda ficam em aberto. Embora as palavras se diferenciem, os sentidos são muito coincidentes entre os diversos trabalhos.

Assim as palavras que apresentam os melhores significados e que possibilitam a generalização deste conceito foram sugeridas como mostra a seção seguinte.

A confiabilidade é normalmente estudada com relação a três diferentes aspectos: os atributos, as ameaças e os meios. Os atributos são as qualidades da confiabilidade. As ameaças são os fatores que levam a perda da confiabilidade. E os meios são os fatores que levam ao aumento da confiabilidade.

1.1.1. Atributos

Houve a necessidade de se criar uma palavra que englobasse todos os atributos definidos, a princípio *reliability* era a palavra mais adequada, mas *dependability* foi escolhido por já haver um atributo com o nome *reliability*. Para o português isso é difícil já que a palavra “dependabilidade” não existe. Até mesmo para o inglês, é difícil afirmar que *reliability* é um atributo de *dependability*, pois o oposto também poderia ser afirmado. É interessante que de maneira geral *reliability* é dito na literatura como a probabilidade do sistema permanecer em funcionamento ou a continuidade do serviço correto. Assim, a partir do significado, *reliability* pode ser modificado para *continuity*. Desta maneira, *dependability* poderia continuar sendo utilizada com a opção de utilizar *reliability*, *survivability* e *trustworthiness* como sinônimos.

Para tornar a definição genérica, a palavra *maintainability* pode ser substituída por *repairability*, que não restringiria a máquinas ou equipamentos.

Em resumo *dependability* [3-7] é utilizada como confiabilidade, como já deve ter sido observado, e seus atributos apresentados na Figura 1.1 são: disponibilidade (*availability*), continuidade (*reliability*), segurança (*safety*), reparabilidade (*maintainability*), integridade (*integrity*) e confidencialidade (*confidentiality*).

A disponibilidade é a prontidão para o uso, a continuidade é a capacidade de se manter em funcionamento, a segurança é a ausência de consequências catastróficas ao homem e ao ambiente, a reparabilidade é a característica de permitir reparos e modificações, a

integridade é a ausência de alterações impróprias e a confidencialidade é a ausência de acesso não autorizado.




Figura 1.1. Atributos da Confiabilidade

1.1.2. Ameaças

As ameaças da confiabilidade são as faltas, os erros e as falhas. Na maioria das referências como em [8, 9, 10], uma *falta* é definida como um desvio anormal de pelo menos uma das propriedades ou parâmetros característicos do sistema do comportamento aceitável. Com a presença das faltas, surgem os *erros* que são mensuráveis e utilizados para a detecção das faltas. Estes podem ser aditivos ou multiplicativos. A *falha* é uma interrupção permanente da habilidade do sistema de executar uma função requerida sob uma especificada condição de operação. A falta é um estado que pode levar a falha ou ao mau funcionamento do sistema. Em [4], é afirmado que a falta leva a um erro que leva a uma falha que pode gerar nova falta fechando o ciclo ilustrado na Figura 1.2.




Figura 1.2. Ameaças da Confiabilidade

Veja que a falta é caracterizada como uma mudança que não é diretamente percebida. O erro é a medição da consequência da falta. A falha é o impacto que gera transtornos e por isso é desejável que seja evitado. Em computação, a falta está no hardware, o erro ocorre

no universo da informação e a falha vai para o universo do usuário. Em um sistema de controle, a falta pode ser a mudança de um dos parâmetros da planta como a constante de tempo, o erro surgirá na resposta transitória ou no regime permanente da planta e a falha pode ser a destruição da planta devido a regimes de operação intoleráveis.

1.1.3. Meios

Assim como os atributos, não há uma definição comum com relação aos meios de se obter confiabilidade. Existem muitos tipos de manutenção que surgiram provavelmente por razões comerciais como manutenção baseada em condição, manutenção centrada em confiabilidade e outras. Em [4-7] estão alguns exemplos das diferentes classificações. Para simplificar, este trabalho considera os meios com relação ao instante no qual a medida é tomada, que são apenas dois: preventivo (antes da falta) e corretivo (depois da falta). A maior parte das classificações dos meios poderia ser dita como preventiva. A remoção de falta durante a fase de projeto, a resistência à falta durante a construção e a tolerância à falta durante a operação são exemplos de métodos preventivos.

A Figura 1.3 ilustra uma comparação ao longo do tempo entre cada uma das estratégias. O desenvolvimento é a fase de criação do processo, do sistema de controle e de todas as estratégias de confiabilidade. Durante a operação o sistema convencional falha após o surgimento de uma falta. Com as estratégias para o aumento da confiabilidade é possível adiar o aparecimento da falha.




Figura 1.3. Meios de Obter Confiabilidade

Métodos corretivos para a remoção de falhas são sem dúvida bastante desejados. A falta pode ser removida antes de causar a falha, mas a correção também pode ser feita após a falha como um sistema de extinção de incêndio minimizando as conseqüências. Esses métodos de remoção de falhas podem melhorar a segurança e manter a integridade do sistema impedindo que ele seja destruído em conseqüência de uma falha. Contudo, a remoção de falhas pode não auxiliar na continuidade. Por exemplo, um acidente na turbina de um avião pode ter a falta removida para impedir uma explosão e a destruição do avião, mas, além disso, é essencial que esse avião possa continuar voando até o aeroporto mais próximo.

A prevenção de falhas pode ser feita durante o projeto e a implementação do sistema utilizando materiais e componentes de alta qualidade e durabilidade. Manutenções periódicas também podem ser realizadas para amenizar o desgaste com o tempo. Contudo, a degradação do sistema é inevitável não somente pelo uso e envelhecimento, mas também por erros humanos e outros acidentes imprevisíveis.

Diante dessas situações, surgiu o princípio da tolerância a falta, que se baseia no fato de que lidar com as faltas é mais fácil do que evitá-las. Observe que na ilustração da figura, o sistema continua operando com a presença de faltas sem que elas levem a uma falha no primeiro momento. Como não é possível alcançar uma tolerância absoluta à falta, uma falha acaba surgindo.

A combinação dos meios apresentados também pode ser uma boa estratégia. A determinação da melhor opção é complicada devido à dificuldade da quantificação da confiabilidade, que é probabilística. Assim, muitas vezes a decisão pela estratégia depende do bom senso e da experiência do projetista.

1.1.4. Considerações Gerais

A confiabilidade pode ser definida como mostra a Figura 1.4, considerando as características mais genéricas e as mais comuns entre os autores. Com essas classificações é possível avaliar e projetar os sistemas adequadamente de acordo com os seus requisitos. Por exemplo, sistemas bancários via internet exigem alta confidencialidade, aviões necessitam de muita segurança, enquanto satélites necessitam de continuidade. No caso de satélites, a reparabilidade é muito pequena pelo fato de operar distante da Terra, o que impede a realização de manutenções periódicas. Neste caso, a tolerância à falta é bastante desejável.

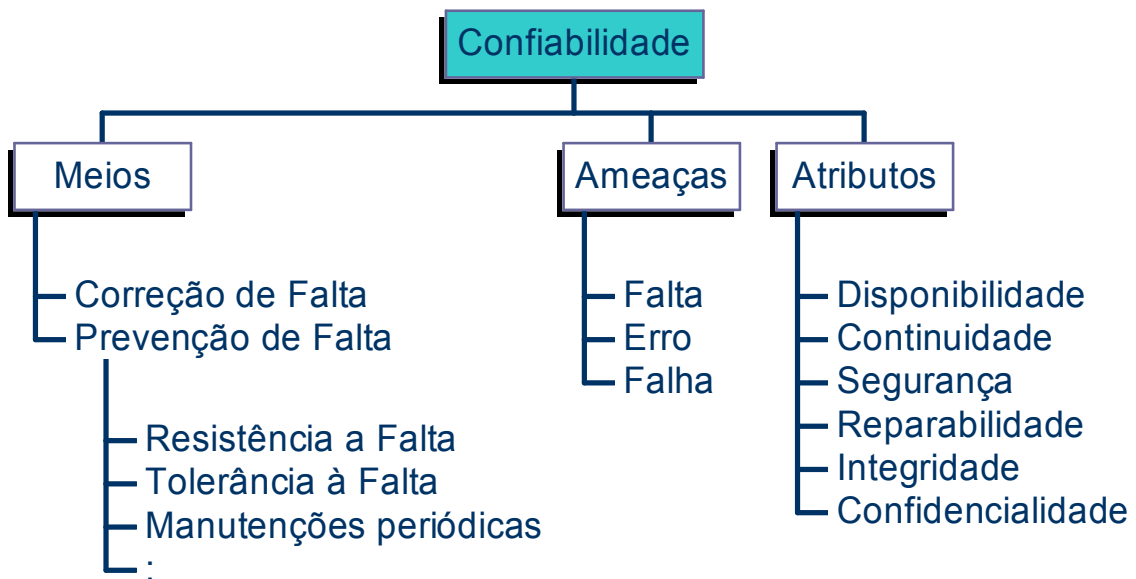


Figura 1.4. Definições Gerais da Confiabilidade

1.2. SISTEMAS DE CONTROLE TOLERANTES À FALTA

Nos últimos anos, os estudos de sistemas de controle têm se tornado muito importante para a sociedade contemporânea devido ao contínuo crescimento dos processos automáticos. A teoria de sistemas de controle é a base de tais processos; a confiabilidade dos processos é diretamente relacionada com a confiabilidade dos sistemas de controle. Portanto, os sistemas de controle também precisam ser projetados para ter alta confiabilidade. O princípio de sistemas tolerantes a falta aplicado em sistemas de controle é conhecido como Sistemas de Controle Tolerantes a Falta - SCTF (*Fault Tolerant Control Systems - FTCS*) [8]. SCTF também melhora a reparabilidade, aumentando o tempo entre as ações de manutenção e permitindo o uso de simples procedimentos de reparo. Os SCTF atuais são divididos em passivo (SCTFP) e ativo (SCTFA) [8] como mostrado na Figura 1.5. Cada um destes SCTF será discutido nas subseções a seguir.

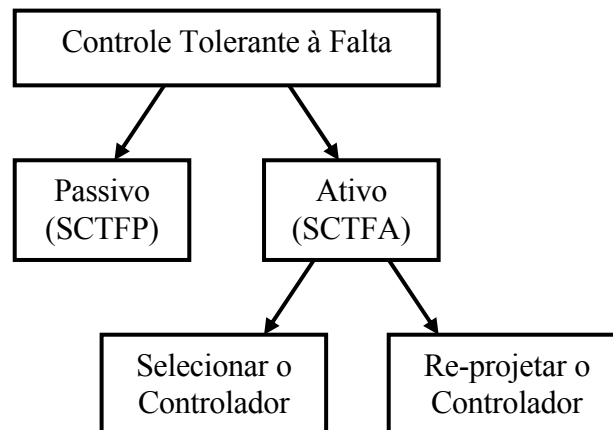


Figura 1.5. Classificação de Sistemas de Controle Tolerantes à Falta

1.2.1. Sistema de Controle Tolerante à Falta Passivo

O Sistema de Controle Tolerante à Falta Passivo (SCTFP) permite a tolerância à falta sem necessidade de modificar o controlador, por essa razão são chamados de passivos. Para SCTFP, um sistema pode tolerar um menor número de faltas que são assumidas como previamente conhecidas para o projeto do controlador. Portanto, um SCTFP tem uma capacidade muito pequena de tolerância à falta. Apesar de ser robusto às faltas presumidas, o procedimento passivo não é tão confiável quanto o ativo.

Geralmente eles necessitam de redundância física para operar. Por exemplo, um sistema de controle pode ter dois atuadores. Se um falhar o outro pode ser utilizado como substituto.

1.2.2. Sistema de Controle Tolerante a Falta Ativo

Em alguns casos, o sistema pode ter uma redundância física muito limitada e não é viável aumentá-la. Nestes casos, um SCTFA poderia ser uma boa opção.

Por convenção, os controladores são projetados para sistemas livres de falta. Se uma falta ocorrer, o comportamento dinâmico dos sistemas provavelmente será mudado. Com a dinâmica diferente, o controlador anterior poderá levar o sistema a instabilidade. Então, a solução ideal é ajustar o controlador para o sistema modificado. SCTFA compensam a

falta selecionando um controlador pré-calculado ou sintetizando um novo controlador em tempo real como mostra a Figura 1.5.

O sistema ativo precisa de um algoritmo de Detecção e Isolamento de Falta - DIF (*Fault Detection and Isolation* - FDI) [8, 11, 12, 13], porque o controlador deve ser alterado com base na falta. O modo de como o controlador deve ser mudado é guiado por um mecanismo de reconfiguração, como mostra a Figura 1.6. Por exemplo, o controlador pode ser reconfigurado para saturar a sua saída em um nível mais baixo para “aliviar” a planta no caso de falta. Em algumas referências, o mecanismo de reconfiguração pode também modificar os sensores, os atuadores e até mesmo o DIF.

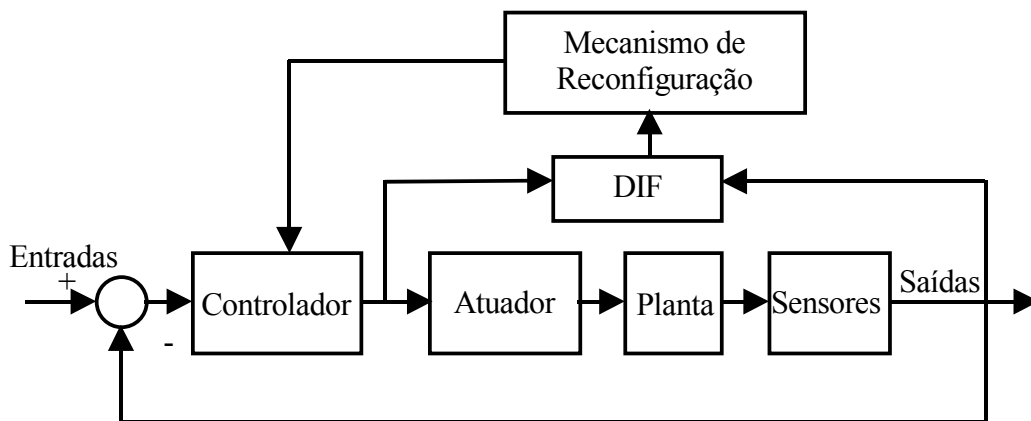


Figura 1.6. Sistema de Controle Tolerante à Falta Ativo

1.2.3. Falta em Sistemas Dinâmicos

Para o estudo de sistemas de controle, há três locais potenciais onde as faltas são consideradas: atuador, planta (ou processo) e sensores [8], como indica a Figura 1.7.

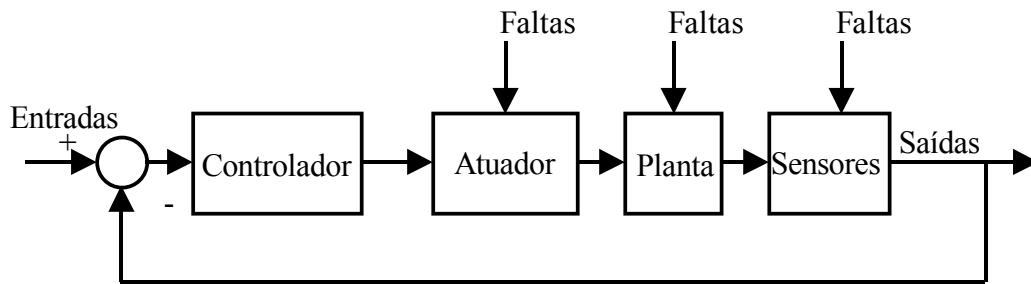


Figura 1.7. Potenciais Locais de Faltas

As faltas nos atuadores podem levar a perda completa ou parcial da capacidade do sistema de realizar a tarefa designada. Uma boa solução para aumentar a confiabilidade dos atuadores seria a redundância física. Contudo, algumas vezes os atuadores são de alta potência e alto custo. Com SCTFA os atuadores com perdas parciais poderiam ainda ser utilizados com mudanças nas leis de controle. Assim, a redundância física não é necessariamente obrigatória.

Faltas em sensores implicam em medidas incorretas devido ao mau funcionamento dos transdutores e dos elementos do circuito do sensor. No caso de sensores, a redundância de hardware pode ser uma boa solução, porque os sensores geralmente não são tão caros quanto os atuadores. Porém, sempre é desejável evitar a redundância de hardware para reduzir o custo e a complexidade.

A falta nos componentes da planta pode mudar o relacionamento dinâmico entre as variáveis e também os limites operacionais.

1.2.4. Detecção de Falta e Isolamento

Muitas aplicações de DIF já foram desenvolvidas. Em geral, essas aplicações podem ser baseadas em sinais ou baseadas em modelos [8]. Métodos baseados em sinais detectam faltas testando propriedades específicas dos sinais medidos. Filtros passa-banda e análise espectral são alguns exemplos entre as diversas técnicas aplicadas em métodos baseados em sinais.

Os métodos baseados em modelo têm grande alcance de aplicações e são normalmente executados em dois passos: geração de resíduo ou detecção de mudanças [11, 12, 13] e avaliação dos resíduos (tomada de decisão). A Figura 1.8 mostra o resíduo gerado pela comparação entre o comportamento esperado, obtido de um modelo do sistema, e o comportamento medido.




Figura 1.8. Procedimento de Detecção de Falta

1.3. O PROBLEMA DA FALTA EM SENSORES

Os sensores são muito importantes em sistemas de controle realimentados. A pirâmide na Figura 1.9 representa os graus de importância de cada parte de um sistema de controle realimentado. O controlador é a base da pirâmide, pois sem ele nada funcionaria, mas como normalmente ele é um computador, esse estudo vai além da engenharia de controle. Felizmente, muitos esforços têm sido feitos relacionados com a computação confiável. O sensor é a segunda base do sistema de controle realimentado, porque todas as decisões tomadas pelo controlador são baseadas nos valores medidos. Sem o atuador, o controlador não poderia agir sobre a planta e sem a planta não poderia ser realizada a tarefa designada ao sistema de controle.

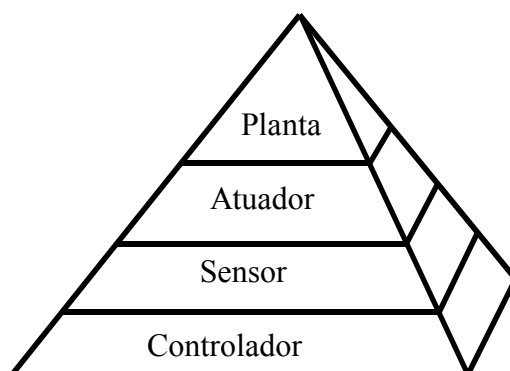


Figura 1.9. Prioridades de um Sistema de Controle Realimentado

Muitos trabalhos já foram feitos com o objetivo de fazer plantas e atuadores de alta confiabilidade, mas só recentemente têm surgido trabalhos que tratam da confiabilidade dos sensores, que normalmente são presumidos livres de falta [8]. Os algoritmos de DIF dos SCTF também são baseados nas medidas e se os sensores estiverem danificados então o SCTF não funcionará corretamente. Assim, sensores tolerantes à falta tornam-se um pré-requisito para os SCTF.

O controle em malha aberta não necessita do uso de sensores como no controle realimentado (em malha fechada), mas o controle em malha aberta não é propriamente uma solução para o problema dos sensores no controle em malha fechada. O controle em malha fechada possui vantagens bem conhecidas em relação ao controle em malha aberta. Muitas vezes o controle em malha aberta não é aplicável, por isso a falta nos sensores deve ser compensada ao invés de desprezar o uso dos sensores.

Com o objetivo de resolver o problema da falta nos sensores, alguns processos usam muitos sensores medindo a mesma grandeza (redundância física ou de hardware) e manutenções periódicas (preventivas) são feitas para aumentar a probabilidade de operarem corretamente [14 e 15]. Recentemente, novas técnicas têm sido desenvolvidas para evitar as manutenções desnecessárias e, conseqüentemente, desgastes dos sensores devido às próprias ações de manutenção (também chamada de Manutenção Baseada em Condição). Essas técnicas são baseadas nas estimações das medições. Com as estimativas corretas é possível detectar possíveis desvios nos sensores, de modo que um sensor pode

ser enviado para a manutenção somente quando uma falta é detectada. Uma característica interessante dessas técnicas é que o processo pode se manter funcionando enquanto um sensor está em manutenção, porque o valor estimado é utilizado para substituir as medidas do sensor defeituoso.

1.3.1. Falta nos Sensores em Controle de Motores

Motores elétricos são essenciais na indústria moderna. Há muitos tipos de controladores e atuadores (*motor drives*) para diferentes tipos de motores e aplicações [16]. Alguns controles são feitos em malha aberta, porém, eles apresentam baixo desempenho. Assim, quando a aplicação exige alto desempenho, o controle em malha fechada é a única opção. Nestes casos, as medidas mais comuns são as das correntes de cada fase. Além delas, para algumas estratégias de controle, também são medidas a tensão no link DC, o campo e a velocidade (ou posição). O controle sem sensores de velocidade e/ou campo, também é chamado de controle sem sensores (*sensorless*). Neste caso, os sensores de tensão são adicionados para a estimação da velocidade.

Apesar de medidas corretas serem fundamentais para uma boa performance dos controladores de motores e para evitar danos aos motores (planta) e aos inversores (atuadores), esse assunto é bastante recente e poucos trabalhos foram publicados sobre a falta em sensores e sua compensação em controle de motores [17-19]. Há numerosos estudos sobre controle de motor tolerante a falta [20-23], mas a maioria é focada em faltas nos semicondutores de potência do inversor e em faltas nos enrolamentos do motor.

O erro de escala (multiplicativos) na corrente causa oscilações no torque do motor à frequência elétrica do estator e erros de *off-set* (aditivos) na corrente causam oscilações de torque com o dobro dessa frequência [17]. Faltas em um sensor de posição do rotor podem resultar em sobre-correntes imediatas do sistema em carga pesada ou em alta velocidade de operação devido à falha do desacoplamento entre os eixos d- e q- dos controladores de corrente. Em carga leve e baixa velocidade a linearidade do torque não seria mantida e as faltas podem levar a sobre-correntes [18]. O erro em sensores de tensão

resulta na má sintonia dos controladores PI e no termo de desacoplamento da força contra-eletromotriz no controlador de corrente [18].

Em [17], os sensores de corrente são compensados usando uma estimação do erro de offset ou escala baseada na medição da velocidade. Os erros da corrente são bem compensados, mas o sensor de velocidade também é suscetível à faltas.

Em [18], os sensores de corrente, tensão e velocidade (*encoder*) são considerados. Todo sensor é estimado em relação aos outros e se o *encoder* é danificado o controle é modificado para o modo *sensorless*, em que a velocidade é estimada baseada em outras medições.

Em [19], a detecção de falta é feita pela avaliação da soma das três correntes. Se for diferente de zero, o sensor com o valor de pico diferindo dos outros com mais de dez por cento é desconectado e o valor da sua corrente é substituído pela estimação. Além disso, o mesmo procedimento é aplicado para sensores de tensão.

É importante notar que a compensação é mais desejável do que a detecção e o isolamento dos sensores. Isolar o sensor sempre implicará no controle em malha aberta a menos que sua medição seja redundante. As compensações dos erros de medição encontradas na literatura sempre são feitas baseadas nas próprias medições. Compensar um erro na medição de corrente com a medição da velocidade pode ser muito pouco confiável, já que o sensor de velocidade também é sujeito à faltas (provavelmente, até mais do que o sensor de corrente). Assim, como o sensor de corrente não pode seguramente compensar o de velocidade ou o de tensão. Este é o maior desafio da compensação: compensar os sensores danificados utilizando eles próprios. Isso só é possível com o uso da redundância, que torna as medições menos dependentes do bom funcionamento de um único sensor.

1.4. ORGANIZAÇÃO E OBJETIVOS DO TRABALHO

Como força motriz da indústria contemporânea, os motores elétricos determinam a qualidade da produção, consumo de energia, manutenções e outras implicações que causam economia ou prejuízos da ordem de milhões conforme a precisão do controle. Uma falha nos sensores envolvidos no controle destes motores pode até mesmo levar o controle à instabilidade, portanto a compensação dos mesmos se mostra necessária.

Este trabalho apresenta a implementação da compensação dos sensores no controle de motores que consiste basicamente na adição de um algoritmo e de alguns sensores a mais do que o usual. É uma medida normalmente de baixo custo em relação ao atuador e a planta e pode levar a economias significativas. A metodologia também será avaliada e comparada com outras técnicas de compensação existentes.

No capítulo dois, será apresentada em detalhes a metodologia proposta com uma breve descrição do controle vetorial de máquinas de indução para a avaliação da implementação da compensação. Nos capítulos três e quatro, são abordadas as principais técnicas de modelagem que dão suporte à metodologia e a técnica de modelos parciais desenvolvida neste trabalho. No capítulo cinco, estão os resultados simulados obtidos para diferentes modelos e números de sensores. As conclusões dos resultados são discutidas no capítulo seis.

2 . M E T O D O L O G I A

A invenção do controle vetorial de motores de corrente alternada surgiu no início dos anos 70 demonstrando ser possível o controle de alto desempenho desses motores que antes era possível somente para motores de corrente contínua. Contudo, esse alto desempenho depende de medições corretas, caso contrário o controle poderá levar a queima do motor ou a danos no processo onde o este atua.

Neste capítulo será demonstrada a utilização de técnicas avançadas de monitoramento de sensores no controle vetorial de motores de indução.

2.1. CONSIDERAÇÕES INICIAIS

A primeira consideração desse trabalho é que o controlador é livre de falta. Pois esse controlador geralmente é um computador (por exemplo, microcontrolador ou DSP), que não é o foco deste trabalho. No sistema analisado, o atuador e a planta também serão considerados livres de falta. Somente os sensores serão considerados sujeitos à faltas e sem faltas múltiplas, ou seja, em mais de um sensor. Com um algoritmo DIF os sensores com falta podem ser detectados e isolados, diminuindo a probabilidade do surgimento de faltas múltiplas. Isso porque faltas consecutivas seriam vistas como várias faltas simples e, somente faltas simultâneas, que são pouco prováveis, seriam tratadas como faltas múltiplas.

Supondo que no controle vetorial de uma máquina de indução a corrente medida em uma das fases seja zero, significa que a causa não é o rompimento da ligação do motor ou a perda parcial do atuador. Por convenção, a causa é a perda do sensor. Neste caso, a corrente real não é igual a corrente medida.

Na prática todas as partes são sujeitas a falta, mas as suposições são necessárias para que sejam feitas as avaliações da metodologia separadamente. No momento da

implementação, todas as metodologias deveriam ser aplicadas em conjunto, sendo que cada uma ficaria responsável pelo tratamento de faltas nos locais em que são especializadas.

2.2. CONTROLE VETORIAL DE MÁQUINAS DE INDUÇÃO

Antes do surgimento do controle vetorial, as máquinas CA eram acionadas com controle escalar, que varia a frequência e a tensão proporcionalmente, por isso também é conhecido como controle volts por hertz. A implementação do controle escalar é simples, mas o efeito de acoplamento entre o torque e o fluxo em relação à tensão ou corrente e a frequência leva a uma resposta deficiente. Além disso, o sistema pode facilmente tender à instabilidade por ser um sistema de alta ordem [16].

O controle vetorial [16] realiza uma transformação que torna a máquina de indução semelhante a uma máquina de corrente contínua excitada separadamente. Em outras palavras, o efeito de acoplamento citado é eliminado. Por isso o controle vetorial também é conhecido como desacoplado, ortogonal ou transvetorial.

A alta complexidade do controle vetorial obriga o uso de microcontroladores avançados ou DSPs. Apesar disso, esse controle tem gradativamente substituído o controle escalar e está se tornando um padrão na indústria mundial.

2.2.1. Analogia com o Controle de Motor de Corrente Contínua

Os motores de corrente contínua possuem duas direções de força magneto motriz, como indica a Figura 2.1: a do eixo direto (ou campo) e a do eixo em quadratura (ou armadura). Esses campos podem ser gerados por ímãs permanentes ou por eletroímãs. Quando o motor possui somente eletroímãs e quando estes são alimentados por fontes separadas é dito que a máquina é excitada separadamente. Neste caso, é possível realizar um controle de alto desempenho com facilidade.

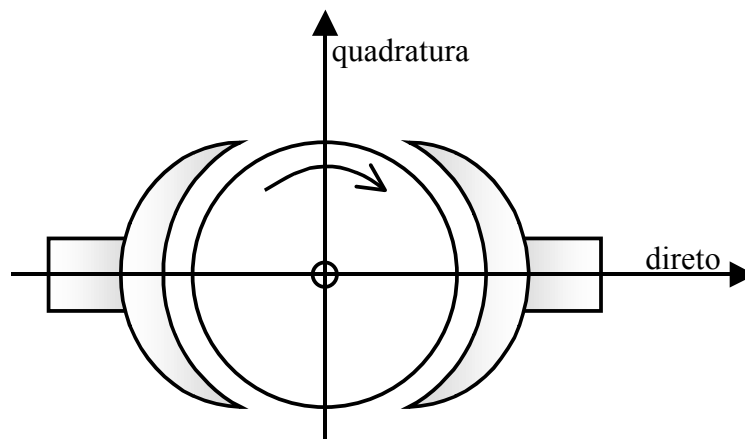


Figura 2.1. Eixos de um Motor de Corrente Contínua

Para o motor excitado separadamente, o torque desenvolvido pelo motor será proporcional ao produto das correntes que alimentam os dois eletroímãs. Na equação (2.1), a constante k_1 depende de características construtivas da máquina, i_d é a corrente de campo ou do eixo direto e i_q é a corrente de armadura ou do eixo em quadratura.

$$T = k_1 i_d i_q \quad (2.1)$$

Ao girar a armadura produzirá uma força contra eletromotriz que é proporcional à velocidade angular e à corrente de campo, como na equação (2.2).

$$E = k_2 \omega i_d \quad (2.2)$$

Dessa forma, a corrente de armadura é dada pela equação (2.3), em que V é a tensão de alimentação e R é a resistência do enrolamento da armadura.

$$i_q = \frac{V - E}{R} \quad (2.3)$$

Combinando as equações (2.2) e (2.3), obtêm-se a equação (2.4), que mostra a velocidade de operação do motor. Teoricamente, a velocidade máxima a vazio é atingida, quando $V = E$, ou seja, a corrente de quadratura for igual a zero, o motor atingirá a velocidade

máxima. A diminuição da corrente direta também pode aumentar a velocidade de operação.

$$\omega = \frac{V - R i_q}{k_2 i_d} \quad (2.4)$$

Portanto o torque depende das duas correntes e a velocidade depende da tensão de alimentação e também das duas correntes.

Para os motores de corrente alternada, especialmente o motor de indução, o eixo direto e o eixo em quadratura estão acoplados. Esse efeito de acoplamento é o empecilho do controle de alto desempenho para este tipo de motor. A transformação apresentada na próxima seção possibilitou a superação deste problema.

2.2.2. Transformação d-q

Suponha que três enrolamentos trifásicos sejam alimentados produzindo um fluxo. A transformação procura quais são os enrolamentos fictícios defasados de 90° que produzam o mesmo fluxo, ilustrado pela seta na Figura 2.2.




Figura 2.2. Equivalência entre os Eixos Trifásicos e os Eixos d-q

A transformação entre os eixos trifásicos e o eixo d-q é dada pela equação (2.5).

$$\begin{bmatrix} d \\ q \\ o \end{bmatrix} = \frac{2}{3} \begin{bmatrix} \sin(\theta) & \sin(\theta-120^\circ) & \sin(\theta+120^\circ) \\ \cos(\theta) & \cos(\theta-120^\circ) & \cos(\theta+120^\circ) \\ 0,5 & 0,5 & 0,5 \end{bmatrix} \begin{bmatrix} a \\ b \\ c \end{bmatrix} \quad (2.5)$$

O eixo adicional o indicado na equação (2.5) é utilizado para representar os eixos trifásicos desbalanceados, mas esse eixo normalmente é desprezado. Quando o ângulo teta é considerado constante, esses são chamados eixos estacionários. Dessa forma é possível separar o eixo direto e o eixo em quadratura, mas os valores de corrente e tensão ainda serão variáveis no tempo. Para resolver este problema, o ângulo teta deve variar junto com a grandeza analisada. Assim, os eixos d-q giram com a velocidade angular síncrona e são chamados eixos síncronos. Essa transformação também é conhecida como transformação de Park, que permitiu a representação de motores de corrente alternada como motores de corrente contínua.

A transformação inversa é feita de acordo com a equação (2.6).

$$\begin{bmatrix} a \\ b \\ c \end{bmatrix} = \begin{bmatrix} \sin(\theta) & \cos(\theta) & 1 \\ \sin(\theta-120^\circ) & \cos(\theta-120^\circ) & 1 \\ \sin(\theta+120^\circ) & \cos(\theta+120^\circ) & 1 \end{bmatrix} \begin{bmatrix} d \\ q \\ o \end{bmatrix} \quad (2.6)$$

2.3. REALIMENTAÇÃO DE ESTIMAÇÕES

Da mesma forma que não há nenhum sistema completamente livre de faltas, não há nenhum sensor livre de faltas. Mas é possível utilizar a redundância nos dados para a obtenção de sinais mais confiáveis do que os medidos.

Essa redundância pode ser física (sensores repetidos) ou analítica (sensores correlacionados). O aproveitamento da redundância analítica pelos modelos é importante por possibilitar a mesma qualidade das estimações com um número reduzido de sensores em relação ao uso exclusivo de redundância física. Isso ocorre porque a qualidade das estimações é determinada pela redundância total, seja ela analítica ou física.

O objetivo de um sistema de controle é fazer com que o sinal de saída acompanhe o sinal de referência. O controlador define a melhor maneira de guiar o sistema baseado no erro que é diferença entre a referência e a saída. Nos sistemas reais, a saída medida pode ser diferente da saída real, caso o sensor esteja com falta. Neste caso, o desempenho da saída real sofrerá um desvio de acordo com o erro da medição e com as características da planta.

Para resolver esse problema, é necessário fazer a estimação do erro da medição. O erro estimado pode ser subtraído da medição para que seja cancelado, assim como é feito em [17]. Neste caso a falta é compensada diretamente e não há um sistema de detecção de falta, mas o erro estimado pode ser analisado para fazer a detecção da falta como em [11, 12, 13].

O erro pode ser estimado diretamente a partir da diferença entre a medição e a estimação da medição. Note que, matematicamente, a subtração do erro na medição para fazer o cancelamento é equivalente ao uso da estimação diretamente na realimentação. Quando o sinal estimado e o sinal medido são diferentes, o sinal medido é o indicado como o causador do erro e não o sinal estimado. Então, a saída estimada é considerada mais confiável do que a medida. Se isso for verdadeiro, é coerente o uso da estimação diretamente na realimentação.

É preciso verificar se os sinais estimados são realmente mais confiáveis do que os medidos. Esses sinais medidos, que são sujeitos a erros, normalmente são os sinais de entrada do modelo. Com o uso da redundância entre eles, os erros destes sinais podem ser eliminados nas estimações do modelo. Por este motivo, as estimações se tornam mais confiáveis do que as medições.

Se o modelo for dependente do processo, caso a planta (ou processo) mude, o modelo também terá que mudar. Portanto, esse modelo dependente do processo será confiável se a planta não mudar ou se ele for adaptativo às mudanças da planta. Contudo, o mais desejável é o modelo independente do processo, porque a planta geralmente muda, seja pela mudança de carga, pelo desgaste ou por mudanças de ponto de operação.

A Figura 2.3 apresenta a proposta central desse trabalho. Os sensores são usados somente para fazer as estimações que são utilizadas na realimentação.




Figura 2.3. Controle Realimentado com Estimções usando Sensores Redundantes

O modelo da Figura 2.3 associa os sinais de entrada entre eles fornecendo estimções dessas mesmas entradas com maior confiabilidade. Esse modelo pode ser entendido como um operador que faz o mapeamento entre o domínio com faltas e o domínio sem faltas. Se o operador for identidade, então as saídas serão iguais as entradas do modelo e o sistema de controle será igual ao sistema de controle convencional.

A combinação da redundância pode acrescentar às estimções, além da rejeição de faltas, outras características desejáveis como a rejeição de ruído e o aumento da precisão.

2.3.1. Análise da Resposta Dinâmica

Para analisar as conseqüências dos erros, considere o sistema dinâmico caracterizado em malha aberta pelas equações em (2.7). Nas equações em (2.7), \mathbf{x} é o vetor dos estados, \mathbf{u} é o vetor das entradas e \mathbf{y} é o vetor das saídas. \mathbf{A} , \mathbf{B} e \mathbf{C} são matrizes que caracterizam o processo. Na primeira linha estão as equações de estado e na segunda está o observador de estado desprezando a influência de \mathbf{u} em \mathbf{y} .

$$\begin{cases} \dot{\mathbf{x}} = \mathbf{A}\mathbf{x} + \mathbf{B}\mathbf{u} \\ \mathbf{y} = \mathbf{C}\mathbf{x} \end{cases} \quad (2.7)$$

Em (2.8) estão as equações de estado equivalentes em malha fechada obtidas considerando $\mathbf{u} = \mathbf{r} - \mathbf{y}$, em que \mathbf{r} é a referência e a entrada em malha fechada. Ou seja, a entrada em malha aberta é o erro entre a referência e a saída.

$$\dot{\mathbf{x}} = (\mathbf{A} - \mathbf{B}\mathbf{C})\mathbf{x} - \mathbf{B}\mathbf{r} \quad (2.8)$$

A matriz que multiplica \mathbf{x} determina o comportamento dinâmico do sistema, incluindo a controlabilidade e a estabilidade [25].

As equações com erro aditivo em (2.9) são encontradas fazendo $\mathbf{u} = \mathbf{r} - (\mathbf{y} + \mathbf{e})$, onde \mathbf{e} é um erro.

$$\dot{\mathbf{x}} = (\mathbf{A} - \mathbf{B}\mathbf{C})\mathbf{x} + \mathbf{B}(\mathbf{r} - \mathbf{e}) \quad (2.9)$$

Observe na equação (2.9), que a matriz que multiplica o vetor dos estados não é alterada. Contudo ocorrerá um erro de regime permanente na resposta, que implicará na alteração do ponto de operação do sistema.

Em (2.10) estão as equações de estado com erro multiplicativo, que são encontradas fazendo $\mathbf{u} = \mathbf{r} - \mathbf{y}\mathbf{e}$.

$$\dot{\mathbf{x}} = (\mathbf{A} - \mathbf{B}\mathbf{C}\mathbf{e})\mathbf{x} - \mathbf{B}\mathbf{r} \quad (2.10)$$

Este erro é equivalente a um ganho na realimentação, que altera a matriz que multiplica os estados. Portanto, esses erros multiplicativos são mais críticos do que os aditivos por alterarem a dinâmica do sistema.

Esses erros podem surgir nas estimações ou nas medições. A princípio, todos os modelos construídos corretamente devem fornecer estimações que em média são iguais às medições em condições normais. Além disso, o ruído nas estimações é geralmente reduzido em relação ao ruído das medições. O valor médio e o ruído estão relacionados com a exatidão e a precisão, respectivamente. Com estimações exatas e mais precisas, o

desempenho da resposta do sistema tende a ser superior com o uso dos modelos em condições normais de operação.

A falta nos sensores produzirá um erro multiplicativo ou aditivo na medição. Se o modelo for capaz de atenuar os erros, o desempenho do sistema será melhor com o uso das estimações também na ocorrência de faltas. Caso os erros sejam amplificados, o efeito da falta será agravado. No próximo capítulo, serão apresentadas medidas que possibilitarão avaliar o grau de amplificação ou atenuação dos erros, tornando possível prever o impacto do modelo no sistema de controle.

2.3.2. *Comparação com os Observadores de Estado*

Um observador de estado é uma extensão do modelo de espaço de estados que fornece a realimentação para o sistema de controle, como mostra a segunda linha da equação (2.7). Um observador é utilizado no sistema onde o acesso direto ao estado não é possível, neste caso eles são chamados de sensores virtuais. Por exemplo, existem sensores para medir o fluxo magnético no interior de motores, mas são caros e sua alocação na máquina é inapropriada. Neste caso, outras medidas como corrente e tensão são utilizadas para estimar o fluxo.

Uma importante diferença entre os modelos apresentados e os observadores de estado é que, nos modelos deste trabalho, a redundância entre os sinais de entrada utilizados é explorada. Não somente os estados que não podem ser medidos são estimados, mas também os sinais que já são medidos, com a finalidade de obter estimações de alta confiabilidade.

Outra característica interessante é que quaisquer outros sinais externos como vibração e temperatura que não são necessariamente estados do processo também podem ser utilizados para a construção do modelo. Caso haja alguma relação (redundância) entre eles, as estimações poderão ser aperfeiçoadas.

2.3.3. *Melhoria da Confiabilidade*

A confiabilidade é difícil de ser calculada, mas podemos perceber quais atributos podem ser aperfeiçoados com a utilização de um sistema de controle realimentado com estimações. A continuidade certamente seria melhorada, pois será menor a probabilidade da interrupção do processo devido a uma falta nos sensores e, de forma semelhante, a disponibilidade do processo também seria melhorada, pois o sistema poderia ser ligado mesmo com um sensor danificado.

O erro entre as estimações e as medições pode ser utilizado para a detecção de falta (indicando o sensor danificado em um display, por exemplo), geração de alarmes e isolamento da falta. Isso é uma grande melhoria para a segurança e a reparabilidade. Além disso, os sensores poderiam ser substituídos sem a parada do processo (havendo condições construtivas apropriadas para isso), porque as estimações são utilizadas na realimentação e a ausência de um sensor é compensada. Deste modo, as manutenções são facilitadas sem prejuízos para a continuidade.

Com as medições mais confiáveis, o sistema poderá se manter funcionando sem que seja danificado devido a oscilações e instabilidade da resposta transitória, o que significa uma melhoria da integridade.

O único atributo da confiabilidade que não é alterado é a confidencialidade, que está relacionada com a restrição de acesso ao sistema, onde somente operadores autorizados poderiam ter o acesso ao sistema.

2.4. UTILIZAÇÕES DA REDUNDÂNCIA

A Figura 2.4 ilustra o procedimento normalmente utilizado para aumentar a confiabilidade da medição de uma fonte comum (medindo exatamente a mesma grandeza). Várias medições são realizadas e a média destes é utilizada, pois será mais confiável do que as medidas. Isso é análogo ao procedimento experimental, em que

muitas medidas são feitas e um método de regressão é utilizado para encontrar a curva mais próxima dos valores medidos.




Figura 2.4. Modelo Básico

Embora seja provavelmente a mais comum, existem muitas outras maneiras de obter estimações ainda mais confiáveis com menos sensores. Por exemplo, a substituição da média pela mediana já tornaria o sistema mais tolerante a falta nos sensores. Médias ponderadas ou outros métodos de votação também poderiam ser implementados.

O método da Figura 2.4 requer muitos sensores para melhorar a confiabilidade das estimações. Isso implica no aumento do custo e da manutenção. O uso da redundância analítica é uma maneira eficaz de reduzir a necessidade da redundância física. Sistemas trifásicos com neutro isolado são um bom exemplo de redundância analítica, onde a soma das correntes das três fases deve ser igual a zero.

Em controle de motores somente dois sensores normalmente são usados enquanto a terceira corrente é estimada. Deste modo, a redundância analítica é utilizada para a redução no número de sensores. Na realidade, toda redundância é eliminada para a redução do número de componentes e do custo nas aplicações mais comuns. Isso ocorre porque a redundância normalmente não é utilizada e, portanto, desnecessária. Entretanto, neste trabalho a redundância possui grande valor e alguns métodos para melhor explorá-la serão apresentados nos capítulos a seguir.

2.5. ETAPAS DE DESENVOLVIMENTO DO TRABALHO

Após a introdução das técnicas de modelagem linear, kernel, técnica de estimação de estados multivariáveis, redes neurais auto-associativas e os modelos parciais, serão construídos os modelos para cada técnica com dois, três, quatro, cinco e seis sensores de corrente. No total serão vinte e cinco modelos que serão avaliados com as medidas de desempenho. Como não há redundância com dois sensores de corrente, esses modelos foram construídos somente para o levantamento das medidas. Para as simulações com o controle vetorial, somente os modelos de três a seis sensores de corrente são avaliados.

Os modelos do controle vetorial no simulink implementados para a avaliação das técnicas são apresentados no Apêndice A1. A maneira como os modelos das técnicas foram construídos é detalhada no Apêndice A2. Para cada uma das vinte simulações foram levantadas as respostas de velocidade, torque, correntes d-q e correntes trifásicas. As respostas de velocidade são apresentadas no capítulo dos resultados e as demais são apresentadas no Apêndice A3.

As correntes trifásicas foram separadas em reais, medidas e estimadas. As reais são as correntes que realmente passam pelos condutores, sem ruído ou erro de medição. As medidas já são sujeitas a erros e ruídos. E as estimadas são as saídas dos modelos que utilizam as correntes medidas. O modelo ideal deveria fornecer correntes estimadas iguais às medidas.

Para todos os casos simulados, as respostas compensadas sempre são comparadas com a resposta sem falta (referência para o bom) e a resposta com falta (referência para o ruim). Isso facilita a avaliação qualitativa dos modelos. A comparação final das medidas de desempenho permitirá a avaliação quantitativa dos modelos.

3. TÉCNICAS DE MODELAGEM

Nos capítulos anteriores foram apresentados os estudos existentes relacionados com a compensação de falta em sensores e a metodologia proposta. As estimações utilizadas para a compensação de falta nos sensores neste trabalho são obtidas a partir de modelos que exploram a redundância nas medições para proporcionar o aumento da confiabilidade. Portanto, é essencial conhecer as principais técnicas recentemente utilizadas para a construção de tais modelos e como avaliá-los. Neste capítulo, essas técnicas serão descritas e algumas métricas de desempenho serão apresentadas. Dessa forma, esses modelos poderão ser compreendidos com maior profundidade.

É importante também ressaltar que a contribuição principal deste trabalho não se resume ao uso das técnicas de modelagem apresentadas, mas ao uso da redundância existente nas medições de sistemas de controle realimentados para o aumento da confiabilidade. Sendo assim, outros modelos com o mesmo princípio também poderiam ser utilizados.

3.1. CONVENÇÕES

Todos os modelos apresentados possuem N entradas e M saídas como mostra a Figura 3.1. Em alguns casos, o número de saídas é igual ao número de entradas, pois as estimações são obtidas para cada uma das medições utilizadas na entrada. No estudo de caso apresentado no capítulo 5, somente três saídas (três correntes) são necessárias para o controle e o número de entradas depende do número de sensores utilizados.




Figura 3.1. Representação dos Modelos Utilizados

O modelo apresentado na Figura 3.1 pode ser baseado em dados (modelos empíricos) ou construído analiticamente. Os modelos analíticos são feitos a partir dos princípios físicos como a lei de Newton, a lei de Lenz e outros. Contudo, sistemas mais complexos tornam inviável a modelagem analítica. A construção de modelos analíticos é possível para sistemas de controle de motores. Entretanto, alguns modelos empíricos têm características úteis para a melhoria da confiabilidade e podem ser úteis mesmo para sistemas simples.

Para a melhor compreensão desses modelos empíricos é útil uma definição clara das notações utilizadas. Suponha que \mathbf{x}_i é a $i^{\text{ésima}}$ das N entradas e \mathbf{y}_j é a $j^{\text{ésima}}$ das M saídas, de acordo com a Figura 3.1. E $\hat{\mathbf{y}}_j$ é a $j^{\text{ésima}}$ estimativa correspondente a saída \mathbf{y}_j . Note que \mathbf{x}_i , \mathbf{y}_j e $\hat{\mathbf{y}}_j$ estão em negrito porque são vetores com n observações cada. Consideremos também \mathbf{X} , \mathbf{Y} e $\hat{\mathbf{Y}}$ como sendo as matrizes que contém os vetores \mathbf{x}_i , \mathbf{y}_j e $\hat{\mathbf{y}}_j$, respectivamente. A Figura 3.2 representa a notação adotada descrita.




Figura 3.2. Notação Utilizada

Na prática, cada coluna da matriz \mathbf{X} representa um sensor utilizado na entrada do modelo e as colunas da matriz \mathbf{Y} são os sinais cujas medidas necessitam ser estimadas. Quando for necessário obter uma estimativa para cada sensor, então essas duas matrizes serão iguais. As matrizes \mathbf{X} e \mathbf{Y} (Entrada e Saída da Figura 3.1 e representadas na Figura 3.2) são os

dados utilizados para o treinamento ou aprendizado do modelo. A matriz \hat{Y} são as estimações de Y obtidas com o modelo treinado para a entrada X .

Para melhorar a avaliação dos modelos é importante separar as observações de treino das observações de teste. Além disso, faltas podem ser simuladas nas entradas de modo a verificar se elas são compensadas nas saídas. A redução do ruído também pode ser verificada de maneira semelhante.

Entre as diversas técnicas que poderiam ser utilizadas para a construção de modelos empíricos estão as regressões polinomiais, os mínimos quadrados, mínimos quadrados parciais, regressão de componentes principais, redes neurais e diversos outros. Para testes e avaliações serão apresentadas as seguintes técnicas: regressão linear, a RKAA - regressão kernel auto-associativa (Do inglês: AAKR - *Auto-Associative Kernel Regression*), técnica de estimação de estados multivariados auto-associativa (Do inglês: AAMSET - *Auto-Associative Multivariate State Estimation Technique*) e RNAA - redes neurais auto-associativas (Do inglês: AANN - *Auto-Associative Neural Network*). Essas estão entre as principais técnicas do estado da arte atual para a criação dos modelos apresentados.

Note que as três últimas técnicas podem ser chamadas de auto-associativas, porque elas automaticamente associam os dados entre eles mesmos combinando a redundância existente. No caso da regressão linear isso não ocorre como será explicado na seção 3.3.

3.2. MEDIDAS DE DESEMPENHO

Para a definição da qualidade de cada modelo há importantes medidas de performance que podem ser utilizadas, entre elas: erro quadrático médio, sensibilidade e filtragem. Elas mostram se o modelo pode piorar a performance do sistema em condições normais de operação e se o modelo poderá melhorar a performance em condições de falta.

3.2.1. Erro Quadrático Médio

O erro quadrático médio (MSE – *Mean Square Error*) é exibido expressão (3.1), que compara a saída estimada com a real sem erros e sem ruídos. Em (3.1), n é o número de observações, \hat{y}_{kj} é a $k^{\text{ésima}}$ estimativa do sinal j e y_{kj} é a $k^{\text{ésima}}$ observação do mesmo.

$$MSE_j = \frac{1}{n} \sum_{k=1}^n (\hat{y}_{kj} - y_{kj})^2 \quad (3.1)$$

Observe que cada sinal j da saída possui uma medida de MSE. A média do MSE de cada saída determina o MSE total do modelo.

3.2.2. Sensibilidade

A sensibilidade trata da propagação da falta para as estimativas. Considere que x_{ki}^{desvio} é a $k^{\text{ésima}}$ observação de x_i com um desvio gerado artificialmente (simulado) e \hat{y}_{kj}^{desvio} é a $k^{\text{ésima}}$ observação estimada de y_j para as mesmas entradas com o desvio simulado. Esse desvio consiste em uma soma ou multiplicação no sinal original alterando o nível ou a escala, que é o erro aditivo ou multiplicativo, respectivamente. Assim, o denominador da equação (3.2) representa um desvio simulado da entrada i e o numerador é a propagação da falta para as estimativas do sinal j .

$$S_{ij} = \frac{\sum_{k=1}^n |\hat{y}_{kj}^{desvio} - \hat{y}_{kj}|}{\sum_{k=1}^n |x_{ki}^{desvio} - x_{ki}|} \quad (3.2)$$

Note que o resultado dessa medida é uma matriz que reflete qual será o efeito na saída j devido à falta ocorrida na entrada i . Da mesma forma que o erro quadrático médio, a sensibilidade do modelo pode ser considerada a média de todas as sensibilidades. Essa medida pode ser chamada de robustez ou auto-sensibilidade com $i = j$ e de espalhamento ou sensibilidade cruzada com $i \neq j$.

A sensibilidade ótima seria obtida quando os desvios gerados pelas faltas fossem completamente eliminados. Neste caso, o valor das medidas seria sempre zero, já que os numeradores da equação (3.2) seriam zeros.

É importante notar também que, de acordo com o modelo a ser avaliado, a sensibilidade pode estar em função do desvio simulado na entrada. Por exemplo, desvios grandes podem ser mais atenuados do que os pequenos. Por isso, um erro aditivo crescente (em forma de rampa) pode ser adicionado como desvio nas entradas para melhor representar a sensibilidade.

3.2.3. Filtragem

A Filtragem também pode ser considerada a medida para avaliar a redução de ruído como mostra a equação (3.3). Ela é calculada de forma muito semelhante à sensibilidade, mas um ruído é adicionado ao sinal de entrada no lugar de um desvio simulado. Na equação (3.3), $x_{ki}^{ruído}$ é a $k^{ésima}$ observação do sinal i com ruído adicionado e $\hat{y}_{kj}^{ruído}$ é a estimativa da saída j para as entrada com ruído.

$$F_{ij} = \frac{\sum_{k=1}^n |\hat{y}_{kj}^{ruído} - \hat{y}_{kj}|}{\sum_{k=1}^n |x_{ki}^{ruído} - x_{ki}|} \quad (3.3)$$

3.2.4. Meta de Desempenho

Quando as saídas são iguais às entradas ($\mathbf{X} = \mathbf{Y}$) e nenhum modelo é utilizado, o que é equivalente a um modelo identidade, a redundância existente na entrada não é combinada para obter as estimativas. Em outras palavras, esse modelo identidade é equivalente à ausência de modelos, porque as estimativas obtidas serão exatamente iguais as entradas.

Para esse modelo identidade as estimativas terão o erro quadrático médio = 0 e o erro em um sinal não propagará para os outros, que significa que o modelo terá bom espalhamento ou sensibilidade cruzada (Espalhamento = 0). Contudo, ele não terá uma boa robustez ou

auto-sensibilidade (Robustez = 1), porque um desvio na entrada é completamente propagado para a saída e não há redução de ruído (Filtragem = 1).

O modelo ideal deve combinar as entradas fazendo com que todas as medidas sejam iguais a zero. Entretanto, a melhoria da robustez geralmente leva ao aumento do erro quadrático médio, do espalhamento e da filtragem. O aumento do número de sinais redundantes é uma solução fácil para esse problema, mas são desejáveis o melhor desempenho com a menor quantidade de redundância física possível. As técnicas apresentadas a seguir visam superar esse desafio.

3.3. REGRESSÃO LINEAR

O objetivo da regressão linear é encontrar a matriz M que multiplica a matriz X composta pelas variáveis de entrada aproximando aos valores da matriz Y que é composta pelas variáveis de saída. Assim as estimativas de Y (representada por \hat{Y}) podem ser encontradas como mostra a equação (3.4).

$$\hat{Y} = X \times M \quad (3.4)$$

A solução normal para encontrar a matriz M seria multiplicar Y pela inversa da matriz X . Contudo, a matriz X normalmente não é quadrada e então não é possível fazer a inversão. Por esta razão a pseudo-inversa (3.5) é utilizada. Essa também é a solução dos mínimos quadrados, que é a matriz M que minimiza o erro quadrático entre \hat{Y} e Y .

$$M = (X^T X)^{-1} X^T Y \quad (3.5)$$

Se $Y = X$, então o modelo está sendo treinado para estimar na saída os mesmos sinais da entrada. A solução será $X^T X$ dividido por ele mesmo, fazendo com que M seja igual a matriz identidade, independente de quais sejam os sinais de entrada. Assim, havendo ou não redundância na entrada, ela não será combinada nas estimações. Por essa razão, essa

técnica não é auto-associativa, já que ela não é capaz de associar os sinais de entrada automaticamente.

Nesta técnica, cada saída é obtida por uma média ponderada das entradas. A regressão é uma maneira de obter os pesos dessa média ponderada a partir dos dados, mas eles também podem ser escolhidos caso a planta já seja conhecida. Esses pesos contidos na matriz M também podem ser compreendidos como coeficientes angulares de uma reta multidimensional que melhor se ajusta aos dados como na Figura 3.3.

3.3.1. Regularização e Regressão Ridge

A matriz $X^T X$ é a uma versão escalada da matriz de covariância. Essa matriz pode ser invertida, mas usualmente é mal condicionada, ou seja, é singular ou próxima de ser singular. Neste caso, a solução não existe ou será instável, respectivamente. Resultados instáveis são aqueles que possuem pesos muito grandes, o que leva a grandes variações nas estimações para pequenas variações na entrada. A Figura 3.3 ilustra um exemplo de solução instável. Os pesos grandes podem ser visualizados pela grande inclinação da reta. Note que a reta se ajusta bem aos pontos, mas um pequeno ruído no sinal de entrada será amplificado nas estimações.

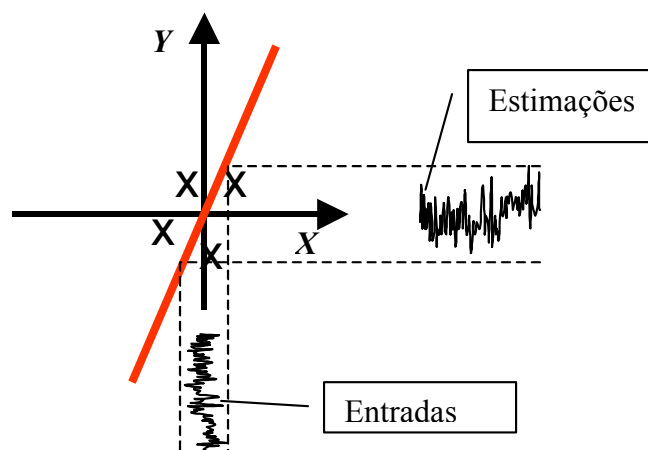


Figura 3.3. Ilustração de um Modelo Instável

Quando a matriz é próxima de ser singular, os métodos de regularização podem ser utilizados para resolver este problema. A regressão ridge [26, 27, 28] é apresentada na equação (3.6) e é, de certa forma, a equação (3.5) aprimorada. Essa também é uma forma da regularização de Tikhonov [29].

$$\mathbf{M} = (\mathbf{X}^T \mathbf{X} + \alpha^2 \mathbf{I})^{-1} \mathbf{X}^T \mathbf{Y} \quad (3.6)$$

O coeficiente α na equação (3.6) é chamado de parâmetro de regularização e deve ser ajustado de modo a minimizar o valor entre os pesos na matriz \mathbf{M} tornando as estimativas mais “suaves” sem distorcer a solução.

Se α for zero a regressão simplesmente busca a matriz \mathbf{M} que minimiza os erros quadráticos assim como na regressão linear convencional. Se α for um valor grande, \mathbf{M} terá pesos pequenos que implicam numa solução mais estável. Embora a diminuição dos pesos aumente a suavidade, o erro quadrático também aumenta. Portanto, esse parâmetro representa um balanço entre a fidelidade aos dados e a suavidade das estimações.

3.3.2. Sensibilidade do Modelo Linear

Independente de como a matriz \mathbf{M} seja obtida é desejável que o valor dos pesos sejam o menor possível. Dessa forma, as estimações obtidas com a equação (3.4) serão menos suscetíveis a erros nas entradas. A sensibilidade igual a zero poderia ser alcançada se a matriz \mathbf{M} também fosse nula. Contudo, o erro quadrático médio aumentaria.

Neste ponto o leitor pode estar questionando se é possível a construção de um modelo ideal. A princípio, infinitas medições seriam necessárias para a construção de um modelo ideal, mas isso é certamente inviável. Com o uso das próximas técnicas a serem apresentadas é possível obter desempenho superior em relação ao modelo linear apresentado nesta seção para o mesmo número de medições.

3.4. REGRESSÃO KERNEL

Essa é uma técnica não paramétrica, porque todas as estimações são feitas baseadas no conjunto de dados de treinamento. Então nenhuma matriz M (matriz de parâmetros), como no caso anterior, precisa ser encontrada.

A Regressão Kernel é basicamente uma Regressão Localmente Ponderada [24], onde os pesos são calculados com base em uma função kernel. Há muitos tipos de funções kernel, mas a função utilizada neste trabalho é a gaussiana, que é a mais usual.

Dado um ponto a ser estimado, as distâncias entre esse ponto e todos os outros pontos no conjunto de dados são calculadas, e então a função kernel é aplicada para essas distâncias de modo que os pontos mais próximos terão os maiores pesos. Gráficamente, isso é o equivalente a traçar a função kernel sobre o ponto a ser estimado como mostra a Figura 3.4. Para cada nova entrada uma nova função kernel é traçada centrada no ponto de entrada em questão. Os valores encontrados com essa função kernel são os pesos aplicados sobre os dados. De modo que a estimativa será encontrada com a equação (3.7).




Figura 3.4. Funcionamento da Regressão Kernel

$$\hat{Y} = \frac{\sum Y_{data} \cdot W(X_{data}, X)}{\sum W(X_{data}, X)} \quad (3.7)$$

Veja que esse modelo também pode fazer mapeamentos não lineares ao contrário do anterior. É interessante notar também que mesmo se o ponto a ser estimado estiver longe dos dados, então a estimação sempre será um valor em torno do conjunto de dados. Portanto, é importante que os dados de treinamento representem bem a faixa de operação.

Quando os dados de saída são iguais aos de entrada a regressão tem a capacidade de associar os dados entre eles automaticamente, ao contrário da técnica anterior. Portanto ela também pode ser chamada de Regressão Kernel Auto-Associativa (RKAA) neste caso.

3.4.1. Influência da Largura de Banda nas Estimações

Para garantir uma boa qualidade das estimações é necessário ajustar a largura de banda ou o suporte da função kernel. Para grandes larguras de banda a solução fica sobre-amortecida e as estimações são distorcidas como mostra a Figura 3.5. Por isso a regressão kernel também possui o efeito de filtro, onde a frequência de corte está relacionada com a largura de banda da função kernel.




Figura 3.5. Estimações para uma Grande Largura de Banda

Para pequenas larguras de banda as estimações se tornam ruidosas com grande variância, como mostra a Figura 3.6. Embora isso gere alta precisão para os dados de treino, que

são os dados armazenados na memória, não haverá boa precisão com os dados de teste, porque o modelo passa a se ajustar ao ruído.




Figura 3.6. Estimções para uma Pequena Largura de Banda

A otimização da largura de banda deve ser feita de acordo com os dados disponíveis para o treinamento. Para dados normalizados com média zero e desvio padrão unitário, a largura de banda ótima tende a estar próximo de um. Contudo, o ajuste deste parâmetro normalmente é um procedimento aconselhável.

3.5. TÉCNICA DE ESTIMAÇÃO DE ESTADO MULTIVARIÁVEL

Também chamado de MSET (*Multivariate State Estimation Technique*), esse é um método de modelagem baseado em memória, porque há uma matriz de dados históricos. Essa matriz é chamada de matriz de memória e é um subconjunto dos dados de treinamento. O MSET tem sido utilizado com sucesso na validação de sensores [31] e na detecção de envelhecimento de software como em [30].

Antes de apresentar o detalhamento matemático da técnica, é importante ter o entendimento do operador similaridade, que é a principal base desta técnica.

3.5.1. Operador Similaridade

O símbolo \otimes representa este operador similaridade. Ele é um operador não-linear que pode ser entendido de maneira análoga a uma multiplicação matricial. A multiplicação matricial pode ser escrita como a equação (3.8) onde a , b e c são os elementos das matrizes A e B que estão sendo multiplicadas e C que é a de resposta de $A \times B$.

$$c_{ij} = \sum_{k=1}^n a_{ik} \cdot b_{kj} \quad (3.8)$$

Da mesma forma que na equação anterior, o operador similaridade será calculado com (3.9).

$$c_{ij} = \text{Kernel} \left(\sqrt{\sum_{k=1}^n (a_{ik} - b_{kj})^2} \right) \quad (3.9)$$

Onde a matriz $C = A \otimes B$. Veja que esta equação é o cálculo de uma função kernel da distância entre dois vetores. Para a equação apresentada, a distância euclidiana foi utilizada, mas outras distâncias poderiam ser consideradas. Também é possível a utilização de diferentes funções kernel. O problema da seleção da largura de banda também é relevante neste caso assim como na regressão kernel.

3.5.2. Formulação

As observações mais relevantes dos dados históricos em X e Y são selecionadas e armazenadas em X_{mem} e Y_{mem} que são chamados de vetores de memória. O objetivo é encontrar qual é o conjunto de pesos em M na equação (3.10) que multiplicam X_{mem} para aproximar o $X_{entrada}$, que é o conjunto de entradas para as quais deseja-se estimar as saídas.

$$X_{entrada} = M \times X_{mem} \quad (3.10)$$

Uma vez que estes pesos foram encontrados, eles multiplicam Y_{mem} para gerar a saída estimada em \hat{Y} como em (3.11).

$$\hat{Y} = M \times Y_{mem} \quad (3.11)$$

No caso da regressão linear, a estimação é obtida com uma soma ponderada das entradas em $X_{entrada}$. Neste caso, a estimação é obtida com uma soma ponderada dos dados na memória, semelhante à regressão kernel na equação (3.7). A principal diferença está na maneira como os pesos são calculados.

Os pesos neste método são calculados a partir da equação (3.10) de maneira semelhante à solução da regressão linear. Aplicando o operador similaridade em ambos os lados da equação por X_{mem}^T e isolando M tem-se a equação (3.12).

$$M = (X_{entrada} \otimes X_{mem}^T) \times (X_{mem} \otimes X_{mem}^T)^{-1} \quad (3.12)$$

O vetor de memória é único para um dado conjunto de observações selecionadas, assim, a inversa apresentada na equação (3.12) precisa ser calculada somente uma vez. A matriz a ser invertida é chamada de matriz de memória na equação (3.13).

$$MEM = X_{mem} \otimes X_{mem}^T \quad (3.13)$$

A matriz M são os pesos encontrados pela equação (3.12) e são aplicados na equação (3.11) para encontrar as estimações desejadas.

Note, pela equação (3.12), que se a matriz de memória na equação (3.13) for igual à matriz identidade, então o MSET se torna igual à regressão kernel, porque a ponderação dependerá somente da função kernel das distâncias, que é a similaridade entre a entrada e os dados da memória. Isso ocorre quando os dados de entrada são linearmente independentes. Para dados de entrada correlacionados, a matriz de memória não será igual a identidade. Neste caso, os dados de entrada estão mal distribuídos e os pesos serão encontrados considerando essa distribuição. Portanto, o MSET é de certa forma uma

regressão kernel com a consideração da distribuição dos dados na memória. Da mesma forma que na regressão kernel, o MSET também pode ser considerado auto-associativo.

Essa não é a única maneira de formular essa técnica. De maneira geral, as estimativas serão uma média ponderada das saída na memória, em que a ponderação depende da função kernel das distâncias e da similaridade entre os dados na memória.

3.6. REDES NEURAS AUTO-ASSOCIATIVAS

Chamada de RNAA (Do inglês: AANN - *Auto-Associative Neural Network*), essa técnica foi inicialmente desenvolvida por Kramer [32, 33]. Elas são usadas como uma alternativa em diagnóstico de sensores.

Uma RNAA consiste em uma rede neural *feedforward* propriamente dimensionada para ser auto-associativa. O treinamento é feito com as entradas X para obter as saídas Y de forma semelhante às técnicas previamente descritas. Durante o treinamento, o relacionamento entre as variáveis fica embutido nos pesos das conexões.

A Figura 3.7 mostra a arquitetura geral de uma dessas redes. Elas são constituídas por uma camada de entrada, um certo número de camadas ocultas e uma camada de saída.

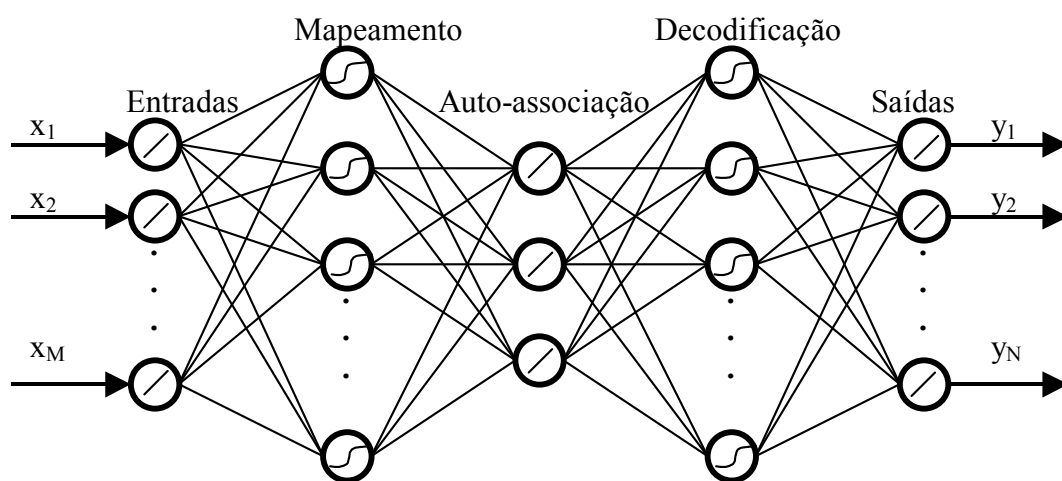


Figura 3.7. Arquitetura Geral de uma Rede Neural Auto-Associativa

É teoricamente suficiente para essa rede neural ter três camadas ocultas [32]. Contudo, na prática, tem sido mostrado que mais camadas ocultas ajudam a rede ter um melhor desempenho. Camadas ocultas adicionais ajudam a rede a mapear mais efetivamente o relacionamento entre as variáveis [34].

A primeira camada oculta também é chamada de camada de mapeamento. A função de transferência dos nós nessa camada pode ser sigmoide ou outra função não linear similar. A segunda camada oculta é mais estreita do que as demais, por isso é chamada de camada gargalo. A sua função de transferência pode ser linear ou não linear. A terceira camada oculta é chamada de camada de mapeamento inverso, onde é feita a decodificação do mapeamento. A função de transferência de cada nó dessa camada é não linear (normalmente sigmóide).

Redes neurais auto-associativas têm uma força interna para prevenir o mapeamento um para um. É justamente a camada gargalo que faz esse papel. No treinamento, essa “camada estrangulada” força a rede a codificar (comprimir) as entradas e decodificar (descomprimir) para produzir as saídas da rede. Como resultado, as estimações são produzidas como uma combinação das entradas e tendem a não mudar devido aos distúrbios como ruído, falta ou não linearidades. Em outras palavras, assim como nas técnicas anteriores, o modelo construído fornece estimações de alta confiabilidade aproveitando a redundância nos dados.

Essa técnica funciona de maneira semelhante à regressão linear, com a vantagem de ter a capacidade de fazer mapeamentos não lineares. Por outro lado, a construção do modelo é mais trabalhosa, pois é necessária a escolha de uma topologia de rede adequada para cada tipo de dados.

4. MODELOS PARCIAIS

A técnica de modelos parciais desenvolvida não é o objetivo principal neste trabalho. Mas, como houve uma contribuição relevante em relação ao aperfeiçoamento do desempenho dos modelos, ela será tratada neste capítulo separadamente. O aumento da capacidade dos modelos na eliminação dos efeitos da falta permite um melhor aproveitamento dos sensores para a compensação. Em outras palavras, torna-se possível obter uma melhor compensação com menos sensores.

4.1. INTRODUÇÃO

O objetivo deste método é aumentar a capacidade de eliminar os efeitos da falta nos modelos, que está relacionada com a sensibilidade descrita no capítulo anterior. A base desse aperfeiçoamento se encontra nos esquema de votação da maioria. Suponha que três termômetros estão medindo a mesma temperatura para aumentar a precisão da medição como na Figura 4.1. Extraíndo a média das três medições o valor obtido certamente será mais confiável. Isso é semelhante ao que é feito nos modelos lineares. Contudo, o erro aditivo na medição do terceiro termômetro devido a uma falta propagará para a estimação. Para que o erro propagado seja zero deveriam ser utilizados infinitos sensores como comentado anteriormente.

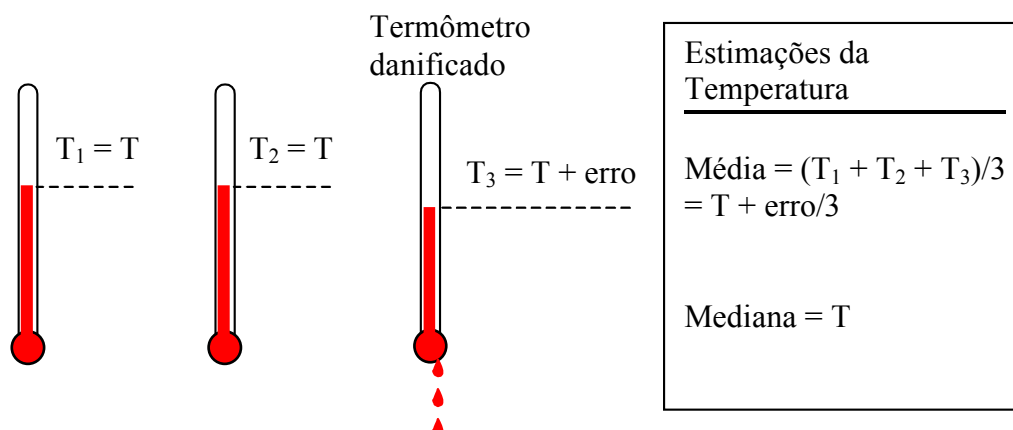


Figura 4.1. Exemplo de Votação da Maioria

A princípio parece impossível impedir completamente a propagação do erro, mas repare que a mediana utilizada no lugar da média elimina completamente o erro ainda que seja muito pequeno.

A mediana calcula o valor que divide a distribuição da probabilidade na metade. Considerando a função densidade de probabilidade normal o valor da mediana corresponderá a maioria, por isso ela pode ser considerada um esquema de votação da maioria. Outros esquemas de votação poderiam ser utilizados, mas a mediana será utilizada neste trabalho por ser de fácil implementação e fornecer bons resultados.

Há duas desvantagens principais relacionadas ao uso da mediana para esta aplicação: a redução da eficiência para medidas com ruído e piores estimações com faltas múltiplas. Para sinais muito ruidosos se torna difícil a determinação de qual é a maioria, a menos que haja um número suficiente de medições. Na ocorrência de faltas múltiplas é necessário garantir que elas continuarão sendo a minoria, caso contrário elas “vencerão” a votação. Isso pode ser feito com detecção e isolamento de faltas, como descrito no Capítulo 1. Neste caso, a medição que apresente um erro maior do que o tolerado deixará de ser considerada nas estimações para que seja isolada.

4.2. PARTICIONAMENTO DOS MODELOS

Para que a votação da maioria seja utilizada é necessário que haja mais de uma estimação para cada sinal da saída. Por isso o modelo é dividido em p modelos parciais, onde cada modelo utiliza somente M/p entradas para estimar N saídas com o objetivo de isolar as faltas. Portanto, haverá p estimações para cada uma das N saídas. Veja a Figura 4.2.

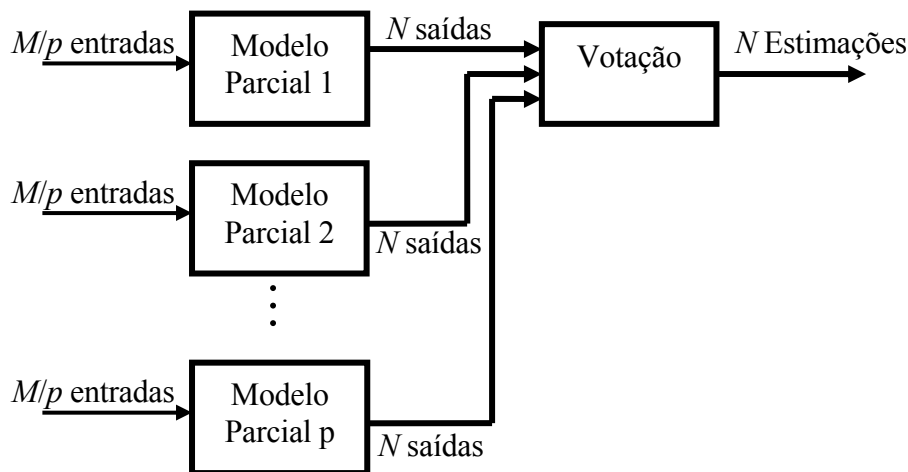


Figura 4.2. Diagrama dos Modelos Parciais

Para compreender melhor o funcionamento da técnica considere o exemplo da Figura 4.3. O objetivo do exemplo é estimar um triângulo com base na medição das arestas. Supondo que o triângulo seja equilátero, então apenas uma aresta poderia ser utilizada para fazer a estimação, o que confirma a existência de redundância. No modelo, essa redundância é aproveitada para compensar um possível erro de medição de uma das arestas. No modelo ideal esse erro deveria ser totalmente compensado. No modelo convencional, entretanto, o erro é reduzido mas não é eliminado como mostra na Figura 4.3, em que o erro em uma das arestas é distribuído entre todas as outras.

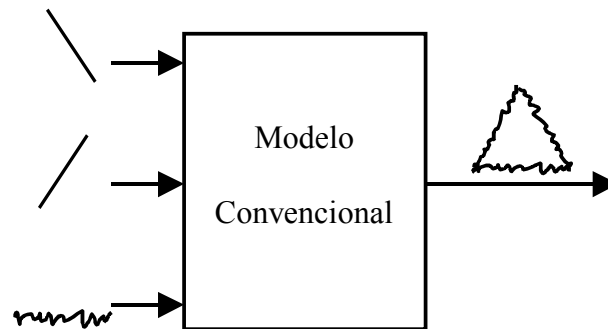


Figura 4.3. Ilustração da Estimação de um Triângulo com um Modelo Convencional

Com os modelos parciais, apenas uma aresta é utilizada por cada um deles como na Figura 4.4. Quando surge o erro, somente o modelo parcial que mede o sinal com erro apresentará erros nas estimações. Como a estimação errada do triângulo é a minoria, ela é completamente eliminada pela votação.

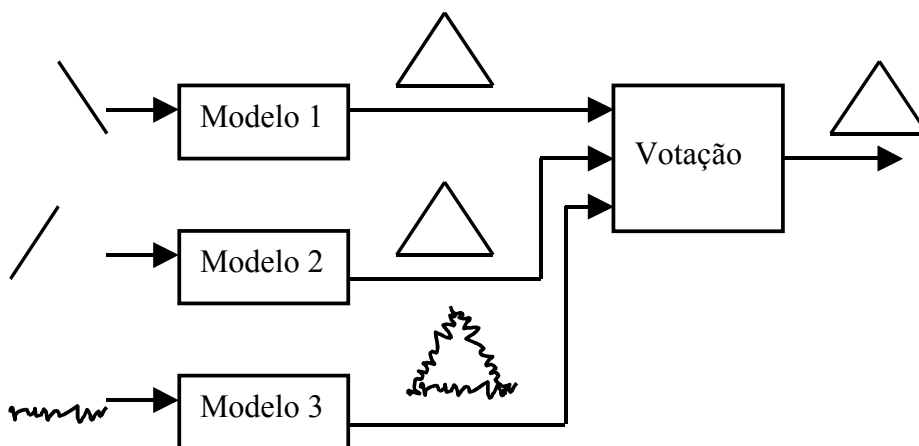


Figura 4.4. Ilustração da Estimação de um Triângulo com Modelos Parciais

O número de modelos parciais é um parâmetro de projeto. Veja que o número de saída é normalmente maior do que o número de entradas, a menos que o número de entradas seja maior do que p vezes o número de saídas. Isso implica que as estimações sejam obtidas com um número limitado de entradas. Portanto, o número de divisões está relacionado com a redundância nos dados, que determinará o número mínimo de entradas necessárias para fazer as estimações.

Retornando ao exemplo do triângulo, se ele não fosse equilátero, não seria possível estimar o triângulo somente com a informação de uma aresta. Isso impede que haja um número muito grande de divisões. Por outro lado, um número pequeno de divisões dificultará a distinção da maioria. Para p igual a um, o modelo parcial será igual ao modelo convencional.

O particionamento dos dados de entrada é ainda mais importante do que o particionamento do modelo. É necessária a maior diversidade de dados possível na entrada, pois cada modelo parcial terá somente uma fração dos dados para fazer a estimação. Caso os dados de entrada sejam escassos de informações, a estimação de cada modelo parcial será deficiente o que levará a estimações piores do que as medições originais.

4.3. SINAIS DE TESTE

Para avaliar a performance obtida com a aplicação da técnica apresentada, foram utilizados dados reais de temperatura medida em seis pontos distintos da câmara de combustão de uma turbina a gás natural, como mostra a Figura 4.5.

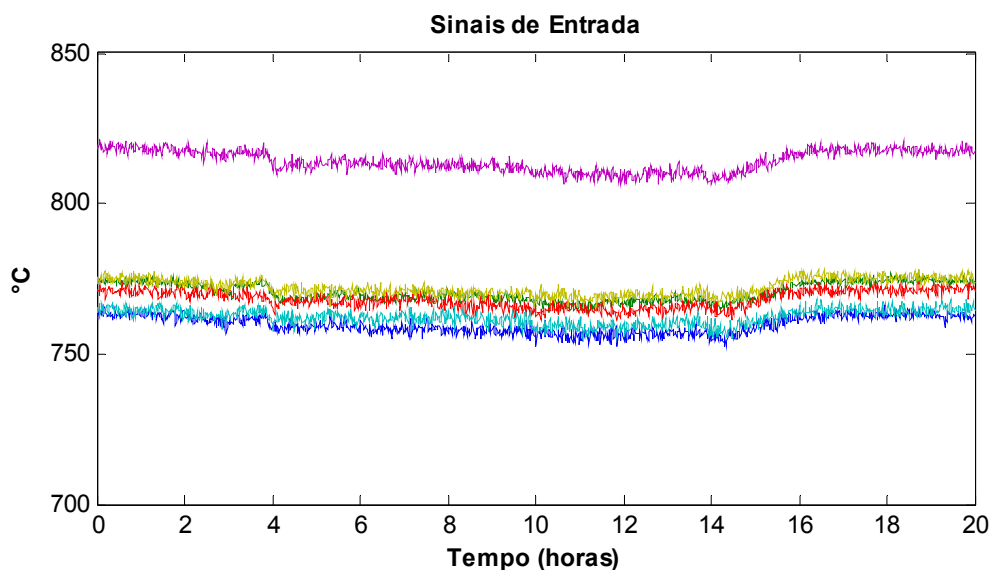


Figura 4.5. Sinais de Entrada

Um erro crescente foi simulado no sinal azul como pode ser visto na Figura 4.6. Esse erro, correspondente a uma falta, é necessário para a avaliação da compensação da mesma.




Figura 4.6. Sinais de Entrada com Falta Simulada

Os modelos foram testados com 1, 2, 3 e 6 divisões, mantendo o mesmo número de entradas em todos os modelos parciais, e a mediana é utilizada para a votação.

Os resultados apresentados nas Figuras 4.7, 4.8, 4.9 e 4.10 são uma comparação das estimações obtidas com uma (modelo convencional) e com seis divisões. Nessas figuras, os sinais verdes são as medições sem falta e os sinais vermelhos são os sinais com faltas. Em outras palavras, o verde indica aonde a estimacão ideal deve estar e o vermelho é o oposto. As estimacões com o modelo convencional estão em preto e as estimacões com seis modelos parciais em azul.




Figura 4.7. Modelos Parciais Lineares

Veja na Figura 4.7 que a estimação com os modelos parciais é aparentemente perfeita com relação à sensibilidade, enquanto que a estimação do modelo convencional sofre alguma propagação do erro. No caso dos modelos lineares, a filtragem do modelo convencional aparenta ser superior. Ainda assim, a estimação é menos ruidosa do que a medição.

Com o modelo kernel na Figura 4.8, as filtragens das duas estimações parecem equivalentes. Referente à sensibilidade, os modelos kernel normalmente são superiores, porque as estimações nunca estão fora do alcance dos dados de treino. Contudo, as estimações com seis divisões são melhores do que os modelos kernel convencionais.




Figura 4.8. Modelos Parciais Kernel

As estimações obtidas com o MSET na Figura 4.9 se aproximam da média, quando o sinal medido está com falta. O que confere ao modelo uma sensibilidade muito boa em relação aos demais, embora tenha um aumento do erro quadrático médio. Entretanto a estimativa produzida com os modelos parciais é mais fiel à medição real.

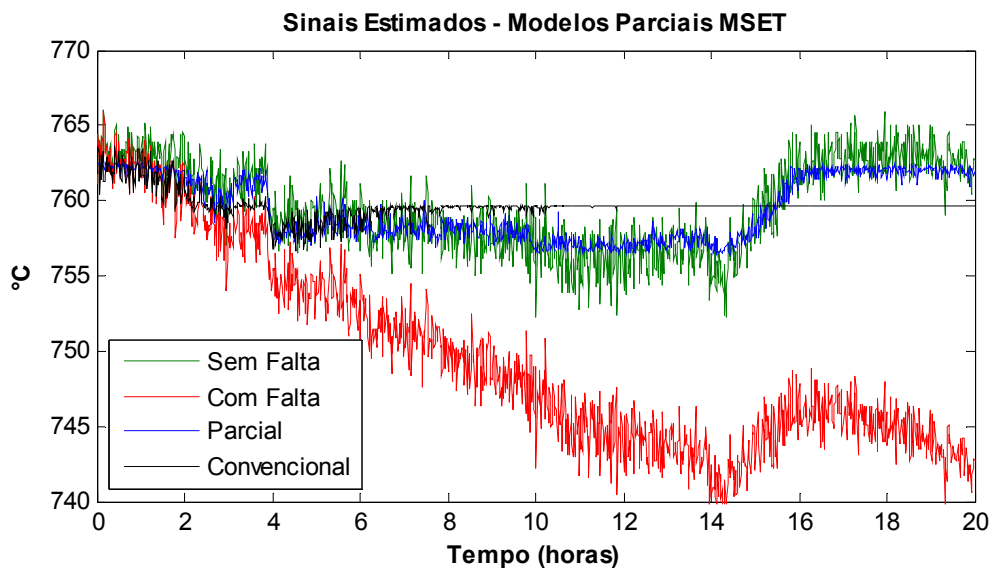


Figura 4.9. Modelos Parciais com MSET

Na Figura 4.10, um grande aperfeiçoamento é alcançado nas estimações com os modelos parciais implementados com redes neurais auto-associativas.

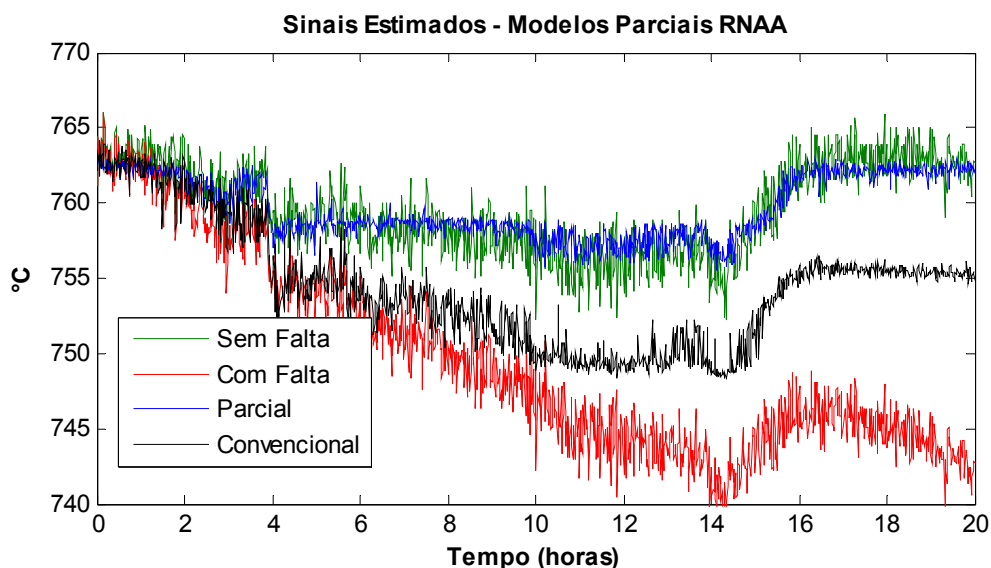


Figura 4.10. Modelos Parciais com RNAA

Independente do tipo da técnica de modelagem utilizada, a robustez dos modelos parciais é muito próxima da ideal, porque a falta é eliminada nas figuras. O ruído também é claramente reduzido. Até aqui uma idéia qualitativa da técnica dos modelos parciais foi apresentada. As medidas de performance apresentadas na próxima seção refletem a qualidade das estimações das figuras anteriores e permitirão uma avaliação quantitativa das mesmas.

4.4. DESEMPENHO

As medidas de performance apresentadas podem ser compreendidas facilmente, pois o melhor valor é zero para todas elas. A robustez, o espalhamento e a filtragem sempre devem ser menores do que um. Valores maiores do que 1 implicarão em estimações piores do que a medições. A Figura 4.11 mostra os resultados das medidas para os modelos parciais lineares. Praticamente não há mudanças com duas divisões, mas a

robustez e o espalhamento são melhorados com três e seis divisões. O erro quadrático médio e a filtragem foram levemente piorados.




Figura 4.11. Performance com Regressão Linear

A Figura 4.12 mostra as medidas para os modelos parciais kernel. Apesar do pior erro quadrático médio, a robustez, o espalhamento e a filtragem foram aperfeiçoados.




Figura 4.12. Performance com RKA

A Figura 4.13 mostra as medidas para os modelos parciais com MSET, que apresentaram resultados similares aos modelos construídos com regressão kernel.




Figura 4.13. Performance com MSET

A Figura 4.14 mostra as medidas para os modelos parcial com redes neurais. A Robustez e o espalhamento são melhorados. A filtragem e o erro quadrático médio aparentam variar irregularmente com o número de divisões.




Figura 4.14. Performance com RNAA

A Tabela 4.I mostra a melhoria geral de desempenho obtida de acordo com o número de divisões em relação ao modelo sem divisões. Os valores positivos indicam um aperfeiçoamento do desempenho em relação ao modelo convencional. Com uma divisão, o modelo é igual ao convencional, por isso não há mudanças de desempenho. Apesar da robustez e o espalhamento sempre apresentarem aperfeiçoamento, o modelo parcial linear com três divisões apresentou uma diminuição do desempenho geral devido à depreciação do erro quadrático médio e da filtragem. Os percentuais da Tabela 4.I refletem as variações do desempenho, mas não mostram a adequação ou não da técnica para a

aplicação, visto que cada medida de desempenho possui características e importâncias distintas.

Tabela 4.I. Melhoria da qualidade com o uso de modelos parciais

<i>Técnica de Modelagem</i>	<i>Melhoria para cada número de divisões</i>			
	1	2	3	6
Linear	0.0%	0.0%	-4.0%	0.9%
RKAA	0.0%	20.9%	33.1%	46.3%
MSET	0.0%	38.3%	47.9%	59.5%
RNAA	0.0%	21.4%	15.5%	42.7%

4.5. DETECÇÃO DE FALTA

A melhoria na detecção pode ser diretamente observada nos resultados apresentados a seguir. As faltas são detectadas pela observação dos erros com um limiar fixo de dois para todos os modelos. As próximas figuras mostram a probabilidade de detecções corretas e de alarmes falsos (detecções incorretas) em relação a magnitude do desvio (erro). Na situação ideal, a falta deveria ser detectada somente quando o erro for maior do que o limiar de detecção, assim a curva das detecções seria um degrau de zero a cem por cento no desvio dois. Os alarmes falsos deveriam ser sempre zero independente do desvio. Na prática, a curva das detecções se comporta como uma rampa devido ao ruído nos resíduos. O ruído gera detecções antes que o desvio atinja o limiar dois e só permite que o sinal seja totalmente detectado, quando o resíduo mais o ruído estiver totalmente acima do limiar de detecção. Desta forma, é possível afirmar que a inclinação da curva de detecção está relacionada com o ruído do resíduo. O ruído também é o causador de alarmes falsos mesmo com desvio zero, mas o aumento do desvio também pode aumentar os alarmes falsos devido ao efeito do espalhamento.

A Figura 4.15a apresenta as curvas de detecções para os modelos parciais lineares. Com duas divisões não há nenhuma melhoria aparente. Com três e seis divisões a detecção é melhorada para o mesmo limiar. Note que a inclinação das curvas é muito semelhante, o que mostra que não houve mudanças no ruído. Na Figura 4.15b a probabilidade de

alarmes falsos para pequenos desvios é igual para todos os casos, mas o aumento de alarmes falsos devido ao espalhamento com grandes desvios é bastante reduzido para três e seis divisões em relação ao modelo convencional.

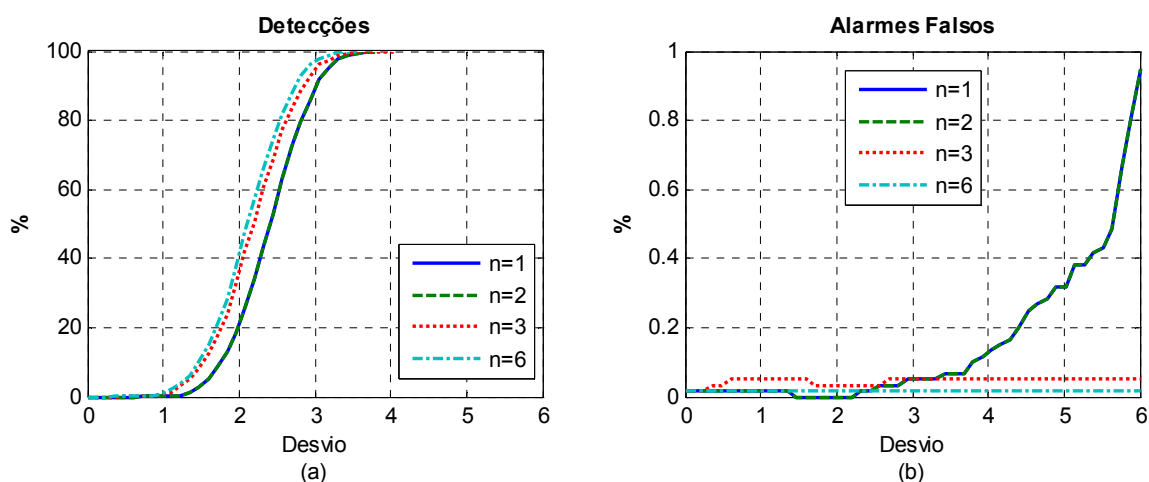


Figura 4.15. Detecção de Falhas e Alarmes Falsos com Modelos Lineares

As linhas contínuas representam os modelos sem divisões ($n=1$). Esses são os modelos sem a aplicação da técnica apresentada e são referências para as comparações.

Os resultados com os modelos kernel mostram um aperfeiçoamento da detecção de falta, na Figura 4.16a, mesmo com duas divisões. Os alarmes falsos na Figura 4.16b diminuíram para grandes desvios, mostrando novamente uma redução do espalhamento.

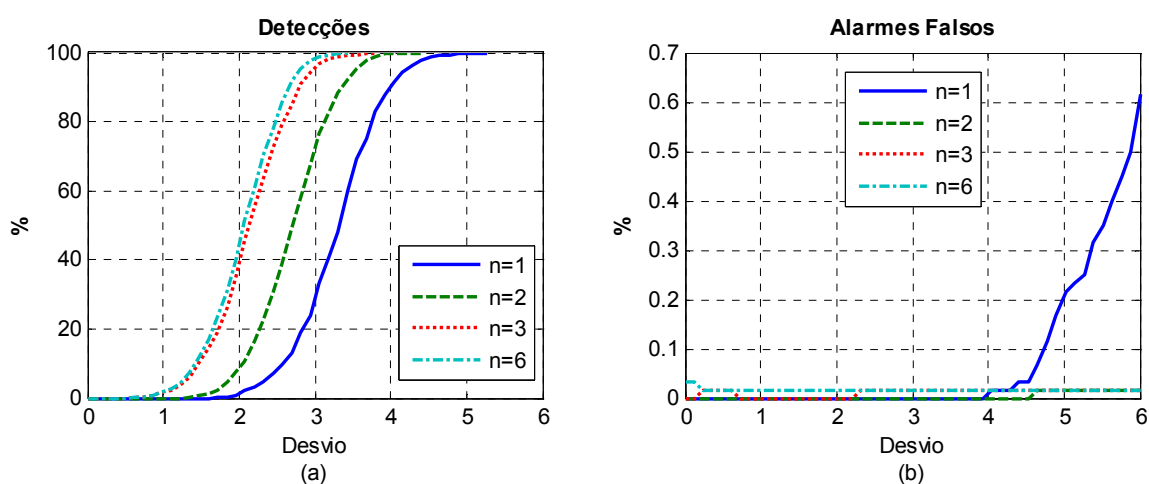


Figura 4.16. Detecção de Falhas e Alarmes Falsos com RKAA

O MSET apresentou mudanças principalmente na inclinação da curva de detecção na Figura 4.17a, ou seja, o ruído no resíduo com mais divisões dos modelos parciais foi reduzido. Os alarmes falsos com desvio pequeno na Figura 4.17b também mostram que o modelo MSET com uma divisão têm mais ruídos que os demais modelos. O aumento dos alarmes falsos devido ao espalhamento não é tão grave quanto nas outras técnicas, ainda assim os alarmes falsos são reduzidos com duas, três e seis divisões.

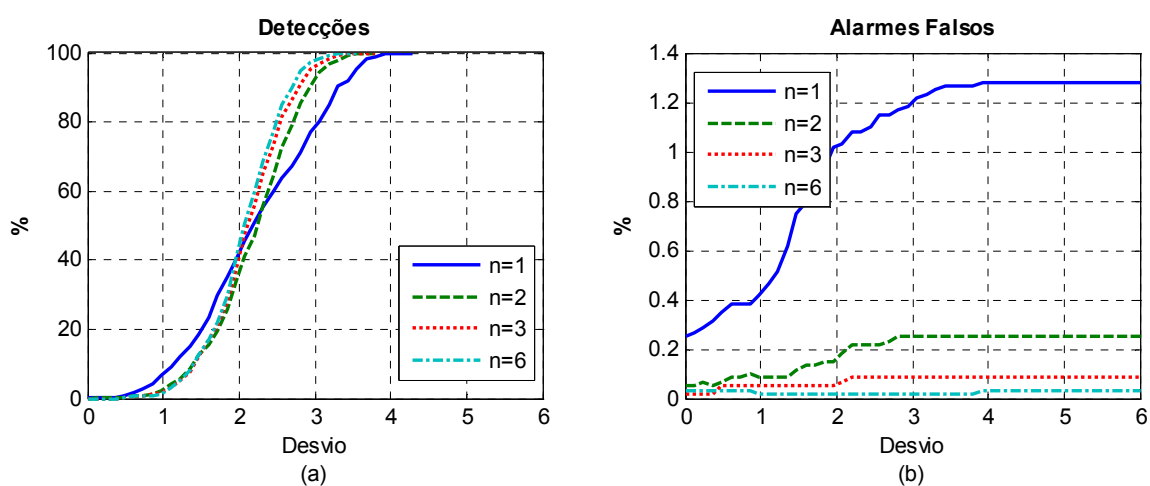


Figura 4.17. Detecção de Falhas e Alarmes Falsos com MSET

Os resultados mais otimistas foram apresentados com o uso das RNAA na Figura 4.18. A aproximação da detecção em torno do limiar reflete a melhor robustez e a redução dos alarmes falsos para grandes desvios reflete o melhor espalhamento.

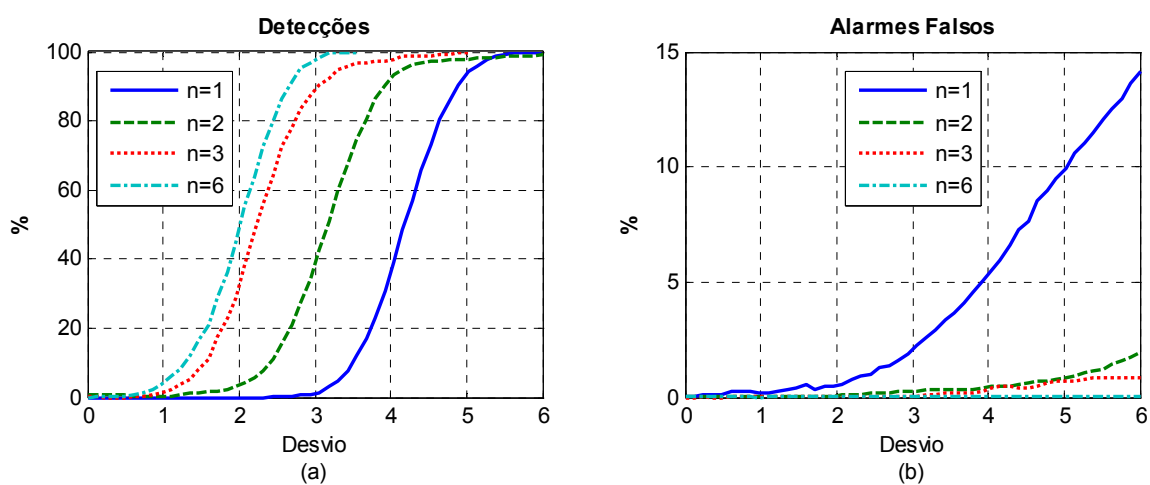


Figura 4.18. Detecção de Falhas e Alarmes Falsos com RNAA

5. COMPENSAÇÃO DE SENSORES EM CONTROLE DE MOTORES

Os resultados apresentados neste capítulo refletem o potencial das técnicas apresentadas para a compensação de falta nos sensores. Quanto maior for o número de sensores, melhor tende a ser a compensação, independente da técnica utilizada. Entretanto, uma modelagem adequada pode melhorar a qualidade da compensação sem aumentar o número de sensores. Uma comparação entre todos os modelos será apresentada no final do capítulo.

5.1. INTRODUÇÃO

Foram desenvolvidos modelos com regressão linear, regressão kernel, MSET e redes neurais de 3 a seis sensores de corrente. O modelo de um motor de indução de 20HP de 4 pólos com controle vetorial indireto foi utilizado para a coleta dos resultados. Os principais modelos do simulink utilizados para o levantamento dos resultados e os dados detalhados do motor de indução são apresentados no Apêndice 1.

Os cálculos das medidas de desempenho (erro quadrático médio, sensibilidade e filtragem) foram realizados separadamente utilizando os sinais trifásicos de 60 Hz, com ruído gaussiano de 20% em relação ao sinal e erros multiplicativos.

Os efeitos da falta na velocidade podem ser vistos através da Figura 5.1. A referência pontilhada representa o valor de velocidade desejado. A linha com traço e ponto representa a resposta em condições normais. A resposta tracejada é a resposta com falta. Foram aplicados erros aditivo e multiplicativo simultaneamente. De acordo com [17], o erro aditivo de corrente é responsável pela oscilação igual a f_e (frequência elétrica de alimentação) e o erro multiplicativo é responsável pela oscilação com o dobro da frequência elétrica como indicado abaixo.




Figura 5.1. Efeitos na Velocidade da Falta no Sensor de Corrente

O motor é simulado com uma carga proporcional ao quadrado da velocidade, que é típico de uma carga de ventilação. A referência é uma rampa que atinge a velocidade desejada de 120 rad/s (19 Hz ou 1146 rpm) no instante de seis segundos. Na Figura 5.1, é apresentado o detalhe da resposta no final da rampa. Como o motor possui dois pares de pólos, a frequência elétrica é aproximadamente igual ao dobro da frequência mecânica de rotação, ou seja, em torno de 38 Hz. Assim, o espectro apresentado está de acordo com o esperado.

Uma análise das correntes medidas e reais também é importante para ressaltar que a origem da falta está nos sensores. A Figura 5.2 apresenta o que ocorre com as correntes em caso de erros de medição. As correntes atingem praticamente o dobro do valor de pico em relação ao caso normal. Essas correntes podem causar danos maiores no motor e no inversor.

Note que, embora a corrente real seja muito grande, a corrente medida na fase *A* é muito pequena e com um leve desvio positivo. Como a corrente medida é o que o controlador observa, a decisão lógica a ser tomada é de aumentar a amplitude da corrente e subtrair o desvio positivo. Por isso, a corrente real da fase *A* aumenta mais do que as demais e apresenta um desvio negativo obedecendo ao controlador.

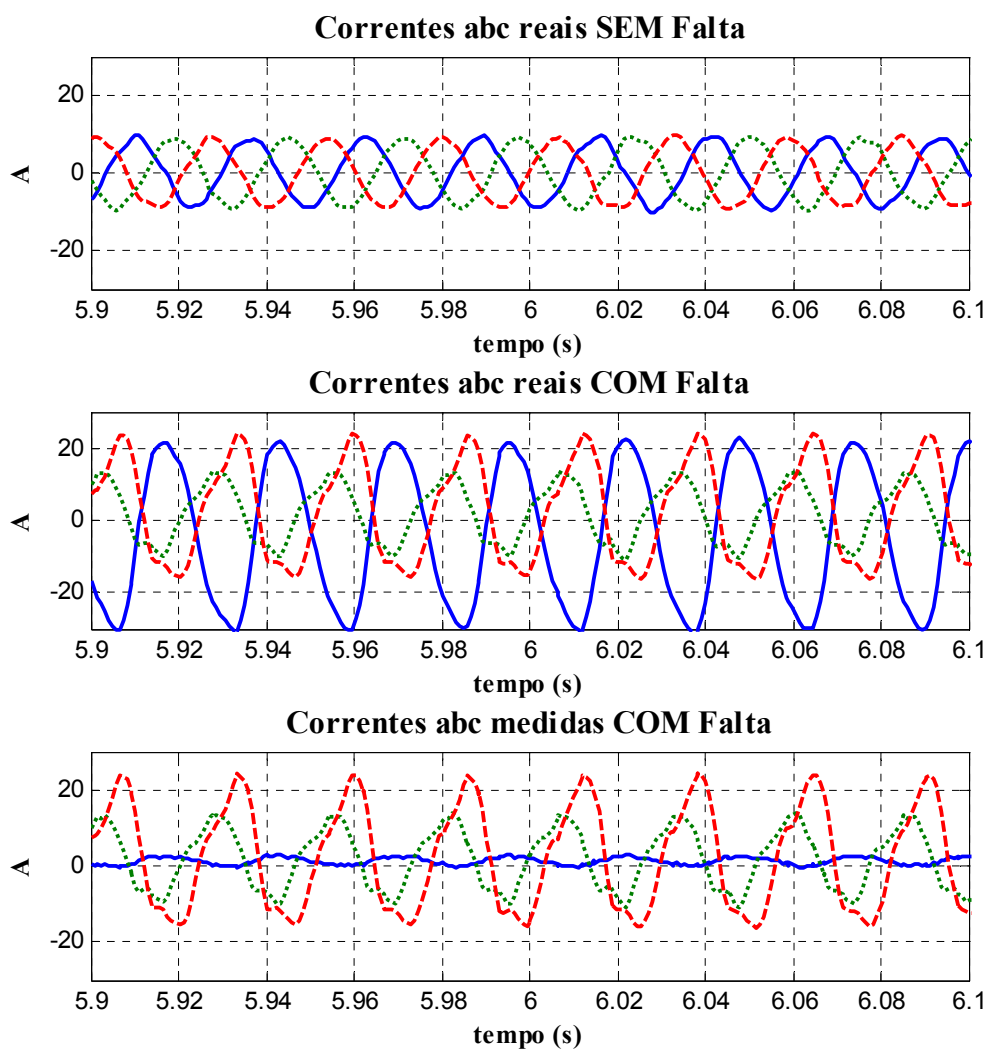


Figura 5.2. Correntes de Alimentação Reais e Medidas

As correntes abc transformadas para os eixos d-q síncronos são apresentadas na Figura 5.3. A oscilação dessas correntes em condições normais é bastante inferior em relação ao caso com falta.




Figura 5.3. Correntes do Eixo Direto e em Quadratura Com Falta e Sem Falta

Essas mesmas oscilações refletem no torque desenvolvido que surge em função do produto das correntes direta e em quadratura.

A oscilação do torque desenvolvido em torno do torque da carga na Figura 5.4 implica em rápidas acelerações e frenagens que ocasionam a oscilação da velocidade apresentada na Figura 5.1. Essas vibrações podem danificar componentes mecânicos do motor, além de poder prejudicar a carga por ele acionado.




Figura 5.4. Torque Com Falta e Sem Falta

Essas condições apresentadas serão utilizadas como referência para distinguir os resultados bons dos resultados indesejados. Por simplificação, serão mostrados nas próximas sessões somente a resposta de velocidade e as correntes trifásicas. Os torques e as correntes d-q são apresentadas no Apêndice 2.

5.2. REDUNDÂNCIA NAS MEDIDAS DE CORRENTE

Antes de apresentar os resultados obtidos com redundância nas medidas de corrente, é importante saber quantificar essa redundância. A redundância disponível no conjunto de dados independe da técnica a ser utilizada para fazer as estimações.

É possível saber analiticamente o montante de redundância existente nas medidas das correntes trifásicas com neutro isolado como mostra a Tabela 5.I. Se houver somente um sensor, somente uma estimativa será disponível. Como deve haver pelo menos uma estimativa por fase, então pelo menos dois sensores são utilizados. E com três sensores, há mais do que uma estimativa por fase, que significa a existência de redundância.

Tabela 5.I. Redundância em relação ao número de sensores

<i>Número de Sensores</i>	<i>Número de Estimações</i>	<i>Estimações por Fase</i>
1	1	1/3
2	3	1
3	6	2
4	7	2 + 1/3
5	9	3
6	12	4

A relação mostrada na Tabela 5.I pode ser obtida pelas seguintes equações, onde n é o número de sensores e Ne é o número de estimações.

$$\begin{cases} Ne = 2.n & , \text{ para } n = \{3, 6, \dots \infty\} \\ Ne = 2.n - 1 & , \text{ caso contrário} \end{cases} \quad (5.1)$$

Note que o número de estimações por sensores é máximo quando o número de sensores é múltiplo de três. Isso significaria um melhor aproveitamento dos sensores para as estimações.

Se a redundância analítica não fosse usada, então a redundância física necessária para conseguir os mesmos resultados teria que ser igual ao número total de estimações. Por exemplo, o uso da redundância analítica com seis sensores seria equivalente ao uso de doze sensores sem a redundância analítica.

5.3. RESULTADOS COM TRÊS SENSORES DE CORRENTE

Uma maneira muito simples de usar um modelo nas estratégias de controle de motores poderia ser uma simples multiplicação matricial. Considerando que as três correntes estão disponível em um vetor linha $I = [I_a \ I_b \ I_c]$, então esse vetor pode ser multiplicado pela seguinte matriz de pesos M_3 na equação (5.2).

$$M_3 = \frac{1}{2} \begin{bmatrix} 1 & -1 & -1 \\ -1 & 1 & -1 \\ -1 & -1 & 1 \end{bmatrix} \quad (5.2)$$

Observe que as correntes estimadas serão a resposta do produto matricial de I por M_3 . Essa matriz é um modelo linear. Como o sistema é relativamente simples, essa matriz foi obtida analiticamente, mas poderia também ter sido obtida através da regressão linear.

O erro em uma entrada é dividido por dois na saída, o que reflete uma certa robustez. Mas esse mesmo erro também se propaga para as outras saídas indicando um espalhamento indesejado. O valor absoluto da matriz em (5.2) é igual a matriz de sensibilidade. Quanto menor for o valor absoluto dos pesos da matriz melhor será a sensibilidade do modelo linear.

Embora haja uma melhoria da sensibilidade, esse modelo aplicado em um controle vetorial não foi capaz de compensar a falta, como mostra a Figura 5.5.




Figura 5.5. Resposta da Velocidade Utilizando um Modelo Linear com Três Sensores

A Tabela 5.II mostra a matriz de sensibilidade encontrada com o modelo linear com três sensores de corrente. É interessante reafirmar que a matriz de sensibilidade para esse modelo é igual ao valor absoluto da matriz apresentada na equação (5.2).

Tabela 5.II. Sensibilidade do modelo linear com 3 sensores

	<i>Para a fase A</i>	<i>Para a fase B</i>	<i>Para a fase C</i>	<i>Erro propagado total</i>
Do sensor A	0,5	0,5	0,5	1,5
Do sensor B	0,5	0,5	0,5	1,5
Do sensor C	0,5	0,5	0,5	1,5

Pela Tabela 5.II é possível afirmar também que um erro em qualquer um dos três sensores será atenuado em 50% para cada uma das fases. Porém, o erro propagado total, que soma a propagação para as três fases, é aumentado 1,5 vezes, ou seja, é aumentado em 50%.

A Regressão Kernel é uma técnica não paramétrica que guarda os dados para fazer as estimações. Então, algum conjunto de dados tem que ser gerado. A robustez e o espalhamento são melhores em relação ao modelo linear, mas pode apresentar problemas com o erro quadrático médio, o que poderia acarretar em um pior desempenho sem a ocorrência de falta.

Na resposta de velocidade com controle vetorial exibido na Figura 5.6, o efeito da falta é pouco atenuado. O uso de um novo conjunto de dados na memória pode levar a modelos kernel com desempenhos diferentes.




Figura 5.6. Resposta de Velocidade com o Modelo Kernel com Três Sensores

A Tabela 5.III mostra a matriz de sensibilidade para o modelo kernel com 3 sensores. Em relação ao modelo linear, o modelo kernel possui um melhor espalhamento (fora da diagonal principal) e uma pior robustez (na diagonal principal), mas o erro propagado total é inferior ao modelo linear, o que justifica o melhor desempenho.

Tabela 5.III. Sensibilidade do modelo kernel com 3 sensores

	<i>Para a fase A</i>	<i>Para a fase B</i>	<i>Para a fase C</i>	<i>Erro propagado total</i>
Do sensor A	0,6547	0,3240	0,3307	1,3094
Do sensor B	0,3320	0,6592	0,3273	1,3185
Do sensor C	0,3351	0,3230	0,6581	1,3162

O fato da matriz de sensibilidade possuir valores maiores na diagonal principal indica que um erro no sensor da fase *A* será propagado mais para a mesma fase do que para as demais.

Para o modelo MSET com 3 sensores, os resultados simulados na Figura 5.7 são praticamente indiferentes assim como no modelo linear. Os mesmos dados da memória utilizados pelo modelo kernel também foram utilizados neste caso. Com largura de banda

muito grande o MSET apresentou resultados iguais aos do modelo linear. No caso apresentado na Figura 5.7, a resposta foi semelhante.




Figura 5.7. Resposta de Velocidade com o Modelo MSET com Três Sensores

A matriz de sensibilidade na Tabela 5.IV é muito semelhante em relação ao modelo kernel.

Tabela 5.IV. Sensibilidade do modelo MSET com 3 sensores

	<i>Para a fase A</i>	<i>Para a fase B</i>	<i>Para a fase C</i>	<i>Erro propagado total</i>
Do sensor A	0,6551	0,3259	0,3292	1,3102
Do sensor B	0,3328	0,6620	0,3292	1,324
Do sensor C	0,3328	0,3259	0,6587	1,3174

Com o uso de RNAA a compensação na Figura 5.8 foi muito eficiente comparada com os demais. Mas o tempo de treinamento da rede que obteve esses resultados é grande. A busca pelo número de neurônios e camadas que ofereçam o melhor resultado é normalmente feita por tentativa e erro. Além disso, a mesma rede com o mesmo número de neurônios e funções de ativação podem apresentar resultados completamente diferentes se treinada novamente.




Figura 5.8. Resposta de Velocidade com o Modelo RNAA com Três Sensores

Apesar do bom resultado, a análise da matriz de sensibilidade na Tabela 5.V mostra que o erro propagado é realmente melhor do que os outros modelos, somente para erro no sensor da fase *A*, que é a fase em que a falta atua nas simulações. Portanto, a mesma rede neural pode apresentar resultados piores do que os outros modelos, caso a falta ocorra em outro sensor. Por esse mesmo motivo, é importante priorizar os modelos que possuam a propagação do erro aproximadamente igual para todos os sensores a serem compensados.

Tabela 5.V. Sensibilidade do modelo RNAA com 3 sensores

	<i>Para a fase A</i>	<i>Para a fase B</i>	<i>Para a fase C</i>	<i>Erro propagado total</i>
Do sensor A	0,5033	0,2732	0,2302	1,0067
Do sensor B	0,4967	0,7268	0,2302	1,4537
Do sensor C	0,4967	0,2732	0,7698	1,5397

Com três sensores de corrente há apenas duas estimações por fase, como comentado anteriormente. Por isso, apenas dois modelos parciais são utilizados e, para duas estimações, a mediana é equivalente a média. Assim, o resultado apresentado na Figura 5.9 foi praticamente igual ao resultado com o modelo linear.




Figura 5.9. Resposta com o Modelo Parcial Linear com Três Sensores

Essa igualdade também pode ser observada na matriz de sensibilidade da Tabela 5.VI.

Tabela 5.VI. Sensibilidade do modelo parcial linear com 3 sensores

	<i>Para a fase A</i>	<i>Para a fase B</i>	<i>Para a fase C</i>	<i>Erro propagado total</i>
Do sensor A	0,5	0,5	0,5	1,5
Do sensor B	0,5	0,5	0,5	1,5
Do sensor C	0,5	0,5	0,5	1,5

5.4. RESULTADOS COM QUATRO SENSORES DE CORRENTE

Se um outro sensor é adicionado, a nova performance dependerá de qual sensor foi adicionado. Um outro sensor medindo a mesma corrente da fase onde a falta ocorreu facilitaria a compensação. Desta forma, foi considerado o pior caso em que a falta ocorre na fase com menos sensores. Sendo assim, um sensor foi adicionado na fase *B* e a matriz da equação (5.3) foi utilizada.

O erro gerado no sensor A é propagado para as outras medidas conforme os valores contidos na primeira linha da matriz M_4 . Assim, é possível notar que somente a estimação

da corrente B (fase onde o novo sensor foi adicionado) será menos atingida pela falta em relação ao caso anterior. Mas também, pode haver uma diminuição de ruído nas outras fases com um sensor a menos. Os pesos da segunda e da quarta linha são os menores, o que reflete que um erro em um sensor na fase B será o menos propagado para as estimações, como já era previsto.

$$M_4 = \begin{bmatrix} 1/2 & -1/3 & -1/2 \\ -1/4 & 1/3 & -1/4 \\ -1/2 & -1/3 & 1/2 \\ -1/4 & 1/3 & -1/4 \end{bmatrix} \quad (5.3)$$

A simulação com controle vetorial na Figura 5.10 mostra que o efeito da falta foi um pouco atenuada. Ou seja, já é possível observar alguma compensação da falta.




Figura 5.10. Resposta com Modelo Linear com Quatro Sensores de Corrente

A Tabela 5.VII mostra a matriz de sensibilidade para o modelo linear com 4 sensores. Da mesma forma que para o caso com 3 sensores, essa matriz é o valor absoluto da matriz do modelo na equação (5.3).

Tabela 5.VII. Sensibilidade do modelo linear com 4 sensores

	<i>Para a fase A</i>	<i>Para a fase B</i>	<i>Para a fase C</i>	<i>Erro propagado total</i>
Do sensor A	0,5	0,3333	0,5	1,3333
Do sensor B1	0,25	0,3333	0,25	0,8333
Do sensor C	0,5	0,3333	0,5	1,3333
Do sensor B2	0,25	0,3333	0,25	0,8333

Pela matriz de sensibilidade é possível notar que há dois sensores na fase *B*. Por isso, um erro nesses sensores é menos propagado para as estimações. De forma semelhante, a estimativa da fase *B* estará menos suscetível a falta nos sensores, já que os valores da segunda coluna estão entre os menores. É claro, o modelo poderia ser construído de forma diferente podendo tirar esse benefício dos sensores da fase *B*.

A Figura 5.11 mostra uma melhoria da rejeição dos efeitos da falta com o modelo kernel.




Figura 5.11. Resposta com o Modelo Kernel com Quatro Sensores de Corrente

A Tabela 5.VIII mostra que a matriz de sensibilidade é um pouco melhor do que no modelo linear. Contudo, pelo fato de ter apresentado uma resposta na Figura 5.11 um pouco irregular em relação ao linear na Figura 5.10, o modelo linear ainda pode ser uma melhor opção.

Tabela 5.VIII. Sensibilidade do modelo kernel com 4 sensores

	<i>Para a fase A</i>	<i>Para a fase B</i>	<i>Para a fase C</i>	<i>Erro propagado total</i>
Do sensor A	0,5952	0,1924	0,4029	1,1905
Do sensor B1	0,1980	0,3956	0,1976	0,7912
Do sensor C	0,4033	0,1923	0,5956	1,1912
Do sensor B2	0,1980	0,3956	0,1976	0,7912

Com o modelo MSET o desempenho da resposta também é similar ao linear, como mostra a Figura 5.12, apesar de ter sensibilidade da Tabela 5.IX superior.




Figura 5.12. Resposta com o Modelo MSET com Quatro Sensores de Corrente

Tabela 5.IX. Sensibilidade do modelo MSET com 4 sensores

	<i>Para a fase A</i>	<i>Para a fase B</i>	<i>Para a fase C</i>	<i>Erro propagado total</i>
Do sensor A	0,5870	0,1929	0,3940	1,1739
Do sensor B1	0,2020	0,3975	0,1955	0,795
Do sensor C	0,3983	0,1930	0,5913	1,1826
Do sensor B2	0,2021	0,3977	0,1955	0,7953

Na Figura 5.13 a resposta de velocidade para o modelo utilizando RNAA novamente foi melhor do que os outros modelos.




Figura 5.13. Resposta com o Modelo RNAA com Quatro Sensores

A matriz de sensibilidade na Tabela 5.X novamente apresentou um desbalanceamento da propagação do erro. Um dos sensores da fase *B* é melhor compensado do que o outro, e o sensor da fase *C* é o menos compensado entre eles.

Tabela 5.X. Sensibilidade do modelo RNAA com 4 sensores

	<i>Para a fase A</i>	<i>Para a fase B</i>	<i>Para a fase C</i>	<i>Erro propagado total</i>
Do sensor A	0,5893	0,2101	0,3792	1,1786
Do sensor B1	0,0135	0,2124	0,1989	0,4248
Do sensor C	0,4107	0,2101	0,6208	1,2416
Do sensor B2	0,3973	0,5776	0,1803	1,1552

O modelo parcial linear com quatro sensores foi construído de uma forma diferente, onde cada sensor é utilizado somente duas vezes contribuindo 50% para cada fase. Deste modo, o erro de cada sensor será propagado no máximo 100% no total. Por isso não apresentou

resultados iguais aos do modelo linear. Pela Figura 5.14, é possível observar que o resultado foi quase tão satisfatório quanto o resultado com redes neurais.




Figura 5.14. Resposta com o Modelo Parcial Linear com Quatro Sensores

A matriz de sensibilidade na Tabela 5.XI apresenta um perfeito equilíbrio entre o erro propagado total dos sensores. O erro propagado igual a 1 significa que 100% do erro propaga para as estimações, mas neste caso 50% vai para a estimaco de uma fase e os outros 50% vai para outra fase.

Tabela 5.XI. Sensibilidade do modelo parcial linear com 4 sensores

	<i>Para a fase A</i>	<i>Para a fase B</i>	<i>Para a fase C</i>	<i>Erro propagado total</i>
Do sensor A	0,5	0	0,5	1
Do sensor B1	0	0,5	0,5	1
Do sensor C	0,5	0	0,5	1
Do sensor B2	0,5	0,5	0	1

Até este ponto, esse foi o primeiro modelo que apresentou alguma sensibilidade igual a zero. Por exemplo, o erro no sensor da fase *A* não é percebido na estimaco da fase *B*. O

espalhamento igual a zero é fácil de se obter, pois a ausência de um modelo já seria assim, mas neste caso, o espalhamento é melhorado junto com a robustez.

5.5. RESULTADOS COM CINCO SENSORES DE CORRENTE

Considerando o pior caso, onde há dois sensores nas fases *B* e *C* e um sensor na fase *A*, a matriz M_5 em (5.4) é utilizada no modelo linear.

$$M_5 = \begin{bmatrix} 1/3 & -1/3 & -1/3 \\ -1/3 & 1/3 & -1/6 \\ -1/3 & -1/6 & 1/3 \\ -1/3 & 1/3 & -1/6 \\ -1/3 & -1/6 & 1/3 \end{bmatrix} \quad (5.4)$$

A simulação com controle vetorial na Figura 5.15 mostrou um aumento da compensação mais significativo em relação aos casos anteriores.




Figura 5.15. Resposta com Modelo Linear com Cinco Sensores

Novamente a matriz de sensibilidade na Tabela 5.XII é o módulo da matriz do modelo na equação (5.4). A primeira linha dessa matriz determina a propagação do erro no sensor da

fase *A* para as estimações. Portanto, todas as fases serão atingidas igualmente pela falta na fase *A*. Para falta em um sensor na fase *B* a estimativa da fase *C* será a menos prejudicada e vice versa.

Tabela 5.XII. Sensibilidade do modelo linear com 5 sensores

	<i>Para a fase A</i>	<i>Para a fase B</i>	<i>Para a fase C</i>	<i>Erro propagado total</i>
Do sensor A	0,3333	0,3333	0,3333	0,9999
Do sensor B1	0,3333	0,3333	0,1667	0,8333
Do sensor C1	0,3333	0,1667	0,3333	0,8333
Do sensor B2	0,3333	0,3333	0,1667	0,8333
Do sensor C2	0,3333	0,1667	0,3333	0,8333

Esse é o primeiro modelo em que todos os erros propagados são menores do que 1, ou seja, são atenuados.

O desempenho do modelo kernel também é atrativo, comparado à compensação com o modelo linear. A resposta simulada na Figura 5.16 é semelhante.




Figura 5.16. Resposta com Modelo Kernel com Cinco Sensores

Com relação à matriz de sensibilidade na Tabela 5.XIII, todos os erros também são atenuados nas estimações. Da mesma forma que no modelo linear, o sensor A é o menos beneficiado com relação a propagação total.

A robustez do sensor A para a fase A é a pior e, ainda assim, o modelo apresentou bons resultados, que tenderiam a ser melhores se a falta ocorresse em algum dos sensores das fases B ou C.

Tabela 5.XIII. Sensibilidade do modelo kernel com 5 sensores

	<i>Para a fase A</i>	<i>Para a fase B</i>	<i>Para a fase C</i>	<i>Erro propagado total</i>
Do sensor A	0,4942	0,2466	0,2476	0,9884
Do sensor B1	0,2496	0,3717	0,1221	0,7434
Do sensor C1	0,2493	0,1218	0,3710	0,7421
Do sensor B2	0,2496	0,3717	0,1221	0,7434
Do sensor C2	0,2493	0,1218	0,3710	0,7421

Para o modelo MSET com cinco sensores, a resposta transitória na Figura 5.17 foi novamente semelhante à resposta com o modelo linear.




Figura 5.17. Resposta com o Modelo MSET com Cinco Sensores

A matriz da sensibilidade na Tabela 5.XIV mostra ser um pouco melhor do que a sensibilidade do modelo linear.

Tabela 5.XIV. Sensibilidade do modelo MSET com 5 sensores

	<i>Para a fase A</i>	<i>Para a fase B</i>	<i>Para a fase C</i>	<i>Erro propagado total</i>
Do sensor A	0,4857	0,2403	0,2453	0,9713
Do sensor B1	0,2509	0,3728	0,1218	0,7455
Do sensor C1	0,2510	0,1156	0,3666	0,7332
Do sensor B2	0,2509	0,3731	0,1222	0,7462
Do sensor C2	0,2507	0,1160	0,3667	0,7334

A compensação da resposta da velocidade na Figura 5.18 apresentou um bom resultado.




Figura 5.18. Resposta com o Modelo RNAA com Cinco Sensores

Ao contrário dos modelos com redes neurais anteriores, o sensor da fase *A* é o menos beneficiado, como mostra a Tabela 5.XV. Assim, é provável que a compensação das faltas em outras fases seja ainda melhor.

Tabela 5.XV. Sensibilidade do modelo RNAA com 5 sensores

	<i>Para a fase A</i>	<i>Para a fase B</i>	<i>Para a fase C</i>	<i>Erro propagado total</i>
Do sensor A	1,0179	0,7820	0,0218	1,8217
Do sensor B1	0,0428	0,0529	0,0246	0,1203
Do sensor C1	0,1821	0,1253	0,4618	0,7692
Do sensor B2	0,0249	0,2709	0,0027	0,2985
Do sensor C2	0,2000	0,6567	0,5600	1,4167

A Figura 5.19 mostra que a compensação obtida com o modelo parcial é muito próxima do ideal. Isso ocorre porque cada fase possui três estimações com cinco sensores de corrente. Com três estimações, a mediana elimina a estimativa incorreta pela votação da maioria.




Figura 5.19. Resposta com o Modelo Parcial Linear com Cinco Sensores

Pela matriz de sensibilidade da Tabela 5.XVI, é observado que o erro propagado total é aproximadamente 23 % em média. Essa é a menor propagação do erro até o momento, o que justifica a qualidade obtida na compensação.

Tabela 5.XVI. Sensibilidade do modelo parcial linear com 5 sensores

	<i>Para a fase A</i>	<i>Para a fase B</i>	<i>Para a fase C</i>	<i>Erro propagado total</i>
Do sensor A	0,1020	0,0715	0,0729	0,2464
Do sensor B1	0,0796	0,0746	0,0663	0,2205
Do sensor C1	0,0796	0,0655	0,0753	0,2204
Do sensor B2	0,0829	0,0767	0,0663	0,2259
Do sensor C2	0,0829	0,0655	0,0761	0,2245

5.6. RESULTADOS COM SEIS SENSORES DE CORRENTE

Para o modelo linear a matriz M_6 (5.5), utilizada apresenta uma simetria assim como a M_3 (5.2), o que representa que todas as fases seriam beneficiadas igualmente.

$$M_6 = \frac{1}{4} \begin{bmatrix} 1 & -1 & -1 \\ -1 & 1 & -1 \\ -1 & -1 & 1 \\ 1 & -1 & -1 \\ -1 & 1 & -1 \\ -1 & -1 & 1 \end{bmatrix} \quad (5.5)$$

A simulação com controle vetorial para o modelo linear mostra que os efeitos da falta são bastante atenuados, como mostra a Figura 5.20.




Figura 5.20. Resposta com o Modelo Linear com Seis Sensores

A Tabela 5.XVII mostra que 75% do erro de qualquer sensor se propaga para as fases no total. Uma boa vantagem que pode ser percebida desses modelos lineares é a facilidade de compensar todos os sensores igualmente.

Tabela 5.XVII. Sensibilidade do modelo linear com 6 sensores

	<i>Para a fase A</i>	<i>Para a fase B</i>	<i>Para a fase C</i>	<i>Erro propagado total</i>
Do sensor A1	0,2500	0,2500	0,2500	0,75
Do sensor B1	0,2500	0,2500	0,2500	0,75
Do sensor C1	0,2500	0,2500	0,2500	0,75
Do sensor A2	0,2500	0,2500	0,2500	0,75
Do sensor B2	0,2500	0,2500	0,2500	0,75
Do sensor C2	0,2500	0,2500	0,2500	0,75

A compensação da resposta transitória com o modelo kernel na Figura 5.21 é semelhante à compensação com o modelo linear.




Figura 5.21. Resposta com o Modelo Kernel com Seis Sensores

As sensibilidades na Tabela 5.XVIII também são bem distribuídas, mas são um pouco melhores em relação ao modelo linear.

Tabela 5.XVIII. Sensibilidade do modelo kernel com 6 sensores

	<i>Para a fase A</i>	<i>Para a fase B</i>	<i>Para a fase C</i>	<i>Erro propagado total</i>
Do sensor A1	0,3314	0,1653	0,1662	0,6629
Do sensor B1	0,1655	0,3320	0,1664	0,6639
Do sensor C1	0,1664	0,1664	0,3327	0,6655
Do sensor A2	0,3314	0,1653	0,1662	0,6629
Do sensor B2	0,1655	0,3320	0,1664	0,6639
Do sensor C2	0,1664	0,1664	0,3327	0,6655

A compensação com MSET na Figura 5.22 também é muito parecida com o uso do modelo linear.




Figura 5.22. Resposta com o Modelo MSET com Seis Sensores

Mas as sensibilidades na Tabela 5.XIX são ainda melhores do que com o modelo kernel.

Tabela 5.XIX. Sensibilidade do modelo MSET com 6 sensores

	<i>Para a fase A</i>	<i>Para a fase B</i>	<i>Para a fase C</i>	<i>Erro propagado total</i>
Do sensor A1	0,3185	0,1560	0,1625	0,637
Do sensor B1	0,1697	0,3320	0,1624	0,6641
Do sensor C1	0,1698	0,1557	0,3255	0,651
Do sensor A2	0,3181	0,1558	0,1623	0,6362
Do sensor B2	0,1696	0,3320	0,1624	0,664
Do sensor C2	0,1693	0,1559	0,3253	0,6505

As redes neurais apresentaram resultados de compensação na Figura 5.23 semelhante aos demais.




Figura 5.23. Resposta com o Modelo RNAA com Seis Sensores

O problema de sensibilidades irregulares também é observado na Tabela 5.XX. Para este modelo, os sensores da fase C foram os mais prejudicados.

Tabela 5.XX. Sensibilidade do modelo RNAA com 6 sensores

	<i>Para a fase A</i>	<i>Para a fase B</i>	<i>Para a fase C</i>	<i>Erro propagado total</i>
Do sensor A1	0,5971	0,1814	0,0578	0,8363
Do sensor B1	0,4066	0,2126	0,2039	0,8231
Do sensor C1	0,1511	0,3237	0,4938	0,9686
Do sensor A2	0,1380	0,1437	0,0354	0,3171
Do sensor B2	0,1343	0,4623	0,1107	0,7073
Do sensor C2	0,6920	0,0014	0,5993	1,2927

O modelo parcial com 6 apresentou também uma resposta muito próxima da ideal na Figura 5.24.




Figura 5.24. Resposta com o Modelo Parcial Linear com Seis Sensores

O erro propagado médio total é ainda menor do que com o modelo parcial com 5 sensores de corrente, como pode ser notado na Tabela 5.XXI. Como foi explicado no capítulo 4, os modelos parciais não atingem a sensibilidade ideal por causa do ruído. A solução para aumentar a sensibilidade poderia ser uma pré-filtragem dos sinais medidos ou o aumento do número de sinais, como ocorreu neste caso.

Tabela 5.XXI. Sensibilidade do modelo parcial linear com 6 sensores

	<i>Para a fase A</i>	<i>Para a fase B</i>	<i>Para a fase C</i>	<i>Erro propagado total</i>
Do sensor A1	0,0665	0,0588	0,0582	0,1835
Do sensor B1	0,0597	0,0670	0,0582	0,1849
Do sensor C1	0,0597	0,0588	0,0674	0,1859
Do sensor A2	0,0675	0,0577	0,0606	0,1858
Do sensor B2	0,0593	0,0686	0,0606	0,1885
Do sensor C2	0,0593	0,0577	0,0657	0,1827

Apesar do número de sensores ser três vezes maior do que o usual, o efeito da compensação é equivalente à compensação sem redundância analítica com quatro sensores por fase (doze sensores).

5.7. COMPARAÇÃO DOS RESULTADOS

A Tabela 5.XXII abaixo é o resumo dos resultados dos erros propagados totais médios para cada modelo. Com dois sensores todos os modelos apresentaram propagação de 200%. Isso ocorre porque um erro em um dos sensores será propagado para a estimação de duas fases. Como não há redundância, nenhum dos modelos pode evitar isso.

Tabela 5.XXII. Erros propagados pelos modelos

<i>Número de sensores de corrente</i>	2	3	4	5	6
Modelo Linear	200%	150%	108%	86%	75%
Modelo Kernel	200%	132%	99%	79%	66%
Modelo MSET	200%	132%	99%	79%	65%
Modelo RNAA	200%	133%	100%	89%	82%
Modelo Parcial Linear	200%	150%	100%	23%	18%

Os mesmos dados da tabela podem ser visualizados graficamente na Figura 5.25.




Figura 5.25. Resumo dos Erros Propagados Totais Percentuais

Em geral o modelo linear é o que mais propaga o erro, exceto para cinco e seis sensores, onde as redes neurais apresentaram maior propagação. Isso ocorreu devido ao aumento da complexidade da rede neural e à dificuldade de treinamento. O modelo parcial linear apresentou resultados iguais ao modelo linear com dois e três sensores. Com quatro houve uma melhoria e, com cinco e seis, se tornou bastante superior em relação aos demais.

Os modelos feitos com regressão kernel ficaram praticamente com a mesma medida de propagação do erro que os modelos feitos com MSET. Contudo, os modelos com regressão kernel conseguiram em geral uma resposta melhor do que com o MSET, porque a sensibilidade não é a única característica desejável para se obter bons resultados.

A Tabela 5.XXIII apresenta o erro quadrático médio dos modelos.

Tabela 5.XXIII. Erro quadrático médio dos modelos

<i>Número de sensores de corrente</i>	2	3	4	5	6
Modelo Linear	0,0000	0,0000	0,0000	0,0000	0,0000
Modelo Kernel	0,0263	0,4846	0,0839	0,0395	0,0003
Modelo MSET	0,0000	0,0000	0,0000	0,0000	0,0000
Modelo RNAA	0,0000	0,0000	0,0000	0,0000	0,0000
Modelo Parcial Linear	0,0000	0,0000	0,0000	0,0000	0,0000

Os modelos kernel são os únicos que apresentam erros diferentes de zero. É difícil afirmar o quão problemático isso pode ser, os modelos com menor erro são mais adequados para plantas mais complexas que poderiam apresentar problemas de estabilidade.

A filtragem na Tabela 5.XXIV indica quais são os modelos que são capazes de reduzir o ruído nas medições. Nenhum modelo é capaz de atenuar o ruído da saída utilizando somente dois sensores. Por outro lado, com três ou mais sensores todos os modelos atenuam o ruído da saída, sendo que as melhores filtragens ocorreram com os modelos kernel e MSET.

Tabela 5.XXIV. Filtragem dos modelos

<i>Número de sensores de corrente</i>	2	3	4	5	6
Modelo Linear	1,1343	0,8638	0,7416	0,6530	0,6107
Modelo Kernel	1,1133	0,7487	0,7062	0,6153	0,5764
Modelo MSET	1,1344	0,8106	0,7250	0,6425	0,5750
Modelo RNAA	1,1343	0,8392	0,8256	0,9468	0,9372
Modelo Parcial Linear	1,1343	0,8638	0,8088	0,7481	0,6445

A Figura 5.26 apresenta os mesmos números de filtragem na forma de ruído propagado percentual. Valores maiores do que 100% indicam que o ruído é amplificado. Para três ou mais sensores o ruído é atenuado para todos os modelos e essa atenuação tende a aumentar quanto maior for o número de sensores. No caso das redes neurais essa filtragem é desvantajosa para cinco e seis sensores, por causa, novamente, do aumento da complexidade. De maneira geral, os modelos parciais não são tão bons quanto os demais e os modelos com MSET e RKAA são os melhores para a eliminação do ruído, provavelmente pelo fato de serem modelos baseados em memória e os dados da memória serem livres de ruído.




Figura 5.26. Resumo dos Ruídos Propagados Totais Percentuais

6. CONCLUSÕES

O sistema de controle proposto com realimentação das estimações pode se tornar uma generalização de sistemas de controle tolerantes a falta em sensores. A sugestão de aplicação em controle de motores é um caso típico utilizado para ilustrar a implementação desta metodologia. Em controle de motores, o método ainda pode ser estendido adicionando sensores de tensão, de velocidade e sensores externos como os de vibração.

As técnicas de modelagem apresentadas são exemplos de como os modelos podem ser construídos, embora haja outras formas como modelos polinomiais, regressão de componentes principais e etc.

Com relação aos modelos testados no acionamento de motores, as seguintes conclusões gerais podem ser tomadas:

- Os modelos lineares são atrativos por serem os mais simples e poderem ser feitos beneficiando todos os sensores igualmente. Mas, apresentam um desempenho inferior em relação aos outros modelos.
- Os modelos feitos com regressão kernel apresentam boa sensibilidade mesmo com poucos sensores, mas apresentaram problemas de erro quadrático médio que está relacionada com a perda de exatidão da estimação, o que altera o comportamento dinâmico do sistema. Entretanto, ele é o melhor de filtragem, que está relacionada com um aumento da precisão da estimação.
- A técnica de estimação de estados multivariados produz respostas que mesclam as características dos modelos com regressão kernel e dos modelos lineares. Apesar de apresentarem sensibilidade tão boa quanto o modelo kernel, a resposta simulada apresentou compensação semelhante à do modelo linear. A boa

sensibilidade é útil para a detecção da falta, mesmo que o modelo não tenha sido bom para a compensação da falta.

- As redes neurais são paramétricas assim como o modelo linear, mas os valores dos pesos são determinados de acordo com um algoritmo de treinamento. Além disso, elas têm a vantagem de aprenderem mapeamentos não-lineares, mas somente funções de transferência lineares foram utilizadas. As redes neurais foram as únicas que apresentaram um bom desempenho com três sensores, mas o desempenho pode ser pior para erros em outros sensores. Isso porque a principal desvantagem observada foi a assimetria da matriz de sensibilidade que beneficia uns sensores mais do que outros.
- O particionamento dos modelos apresentado nesse trabalho, nomeado como modelos parciais, aumenta consideravelmente a capacidade da compensação de faltas em relação aos modelos convencionais. A desvantagem é que ele é pior com relação à filtragem do ruído.

Para cinco ou mais sensores os modelos parciais são bastante indicados, pois a compensação é muito próxima da situação ideal. Para três ou quatro sensores o modelo kernel pode ser utilizado ou o modelo MSET para evitar problemas com a exatidão. Uma outra opção seria também manter os modelos parciais lineares para três (que é igual ao modelo linear) ou quatro sensores, por ser mais simples do que os modelos não-paramétricos. Independente do modelo escolhido e da aplicação, é necessário que haja redundância e que ela seja combinada no modelo para melhorar a confiabilidade das estimações. Sem redundância nenhum modelo é capaz de compensar o erro, como foi mostrado pela sensibilidade utilizando dois sensores de corrente.

O custo adicional desta aplicação está relacionado principalmente com o aumento do número de sensores. O modelo utilizado para a estimação dos sinais normalmente será uma implementação em software juntamente com os controladores. Apesar do aumento da confiabilidade também ser certo, ele não é exato, tornando-se difícil de ser quantificado.

As contribuições deste trabalho podem ser resumidas nos seguintes itens:

- Proposição da compensação de falta em sensores de sistemas de controle realimentados utilizando modelos auto-associativos.
- Utilização de técnicas de modelagem para a compensação de falta em sensores no controle vetorial de motores de indução trifásico.
- Comparação entre diversas técnicas de modelagem na compensação dos sensores no controle vetorial de motores de indução trifásico.
- Proposição da técnica dos modelos parciais.
- Comparações da aplicação de técnicas de modelagem linear, kernel, MSET e RNAA em medições reais de temperatura em um câmara de combustão de uma turbina. Bem como, a avaliação do efeito da implementação dos modelos parciais com cada uma das técnicas de modelagem citadas.
- Revisão bibliográfica das principais técnicas de modelagem utilizadas no monitoramento de sensores, dos conceitos de confiabilidade e de sistemas de controle tolerantes à falta.
- Publicação de um artigo sobre os modelos parciais no COMADEM 2006 [35].
- Preparação de um artigo para submissão no IAS 2007 e IEMDC 2007.

Entre as sugestões de trabalhos futuros estão:

- A implementação de um protótipo em laboratório para comparação com os resultados simulados.
- Aplicar a técnica em outros sensores como os de tensão e de velocidade.
- Aplicar em diferentes sistemas de controle.

GLOSSÁRIO

Aplicações Críticas. Aplicação cuja falha pode ter duras conseqüências.

Erro. Conseqüências das faltas que podem levar a uma falha.

Falha. Interrupção permanente.

Falta Simples. Ocorrência de uma única falta.

Falta. Desvio anormal que levam a erros.

Faltas Múltiplas. Ocorrência de várias faltas simultâneas ou não. Contudo, a probabilidade de ocorrerem faltas simultâneas é muito pequena.

Detecção e Isolação de Falta - DIF (*Fault Detection and Isolation - FDI*). Algoritmos utilizados em SCTFA. Eles são os geradores de alarmes de faltas e são importantes para combater faltas múltiplas, já que além de detectar, a falta também é isolada.

Modelo Auto-Associativo. Modelo treinado para associar os dados com eles mesmos. A saída dos dados de treinamento é igual aos sinais de treinamento de entrada.

Redundância Analítica. Informação Repetida em diferentes sinais.

Redundância Física (ou de Hardware). Componentes físicos repetidos.

SCTF Ativo (SCTFA). SCTF com reconfiguração do controlador.

SCTF Passivos (SCTFP). SCTF com redundância física.

Sistema de Controle Tolerante a Falta (SCTF). Sistemas de controle com tolerância a falta.

REFERÊNCIAS

- [1]http://en.wikipedia.org/wiki/List_of_civilian_nuclear_accidents
- [2]<http://www.planecrashinfo.com/>
- [3] D. Lardner, Babbage's calculating engine. *Edinburgh Review*, Julho de 1834. Reimpresso nos editores P. Morrison e E. Morrison, *Charles Babbage and His Calculating Engines*. Dover, 1961.
- [4] AVIZIENIS, A. LAPRIE, J.C., RANDEL, B., Fundamental Concepts of Dependability, *Technical Report, LAAS-NewCastle University-UCLA*, 2001.
- [5]<http://www.ifip.org/>
- [6] AVIZIENIS, A. LAPRIE, J.C., RANDEL, B., Dependability and its threats: a taxonomy, *Proceedings of the Building of Information Society*, 2004.
- [7]<http://www.dependability.org/>
- [8] MAHMOUD, MUFEED; JIANG, JIN; ZHANG, YOUJIN. *Active Fault Tolerant Control Systems – Stochastic Analysis and Synthesis*. Springer, 2003.
- [9] RUNE M. JENSEN. DES Controller Synthesis and Fault Tolerant Control - A Survey of Recent Advances. *The IT University of Copenhagen*, 2003.
- [10] J. CHEN AND R. J. PATTON. *Robust Model-Based Fault Diagnosis for Dynamic Systems*. Kluwer Academic Publishers, 1999.
- [11] BASSEVILLE, M. Detecting changes in signals and systems - A survey. *Automatica*, 1988.
- [12] MIKE LIND RANK, HENRIK NIEMANN, Norm based threshold selection for fault detectors, *AACC* 1998.
- [13] R.J. PATTON, J. CHEN, G.P. LIU, Robust fault detections of dynamic systems via genetic algorithms, *IEE* 1995.
- [14] MEHANBOD, N., SOROUSH, M., PIVOSO, M. AND OGUNNAIKE, B.A., Sensor Fault Detecion and Identification via Bayesian Belief Networks, *Proceedings of the Amerian Control Conference IEEE*, Junho 4-6, 2003.
- [15] MEHANBOD, Nasir, *A Probabilistic Approach for Sensor Fault Detecion and Identification*, Tese, Novembro, 2002 - Drexel University.

- [16] BOSE, BIMAL K. *Modern Power Electronics and AC Drives*, Prentice Hall PTR, 2002.
- [17] DAE-WOONG CHUNG, SEUNG-KI SUL, Analysis and Compensation of Current Measurement Error in Vector-Controlled AC Motor Drives, *IEEE transaction*, 1998.
- [18] YU-SEOK JEONG, SEUNG-KI SUL, STEVEN E. SCHULTZ, NITIN R. PATEL, Fault Detection and Fault-Tolerant Control of Interior Permanent-Magnet Motor Drive System for Electric Vehicle, *IEEE transaction*, 2005.
- [19] S.M. BENNETT, R.J. PATTON, S. DALEY AND D.A. NEWTON, Torque and Flux Estimation for a Rail Traction System in the Presence of Intermittent Sensor Faults, *IEE* 1996.
- [20] A. EL-ANTABLY, L. XIAOGANG, AND R. MARTIN, System simulation of fault conditions in the components of the electric drive system of an electric vehicle of an industrial drive, *IEEE* 1993.
- [21] B.A. WELCHKO, T.M. JAHNS, AND S. HITI, IPM synchronous machine drive response to a single-phase open circuit fault, *IEEE transaction* 2002.
- [22] N. RETIERE, D. ROYE, AND P. MANNEVY, Vector-based investigation of induction motor drive under inverter fault operations, *IEEE*, 1997.
- [23] R.B. SEPE JR., B. FAHIMI, C. MORRISON, AND J.M. MILLER, Fault-tolerant operation of induction motor drives with automatic controller reconfiguration, *IEEE* 2001.
- [24] CHRISTOPHER G. ATKESON, ANDREW W. MOOREY, AND STEFAN SCHAALZ. *Locally Weighted Learning*. 1996.
- [25] KEMIN ZHOU, PRAMOD P. KHARGONEKAR, JAKOB STOUSTRUP, HAS HENRIK NIEMANN, Robust Stability and Performance of Uncertain Systems in State Space, *IEEE*, 1992.
- [26] HOERL, A. E., *Application of Ridge Analysis to Regression Problems*, Chemical Engineering Progress, 1962.
- [27] HOERL, A. E., AND KENNARD, R. W., On Regression Analysis and Biased Estimation, *Technometrics*, 1968.
- [28] ARTHUR E. HOERL AND ROBERT W. KENNARD, Ridge regression: biased estimation for nonorthogonal problems, *Technometrics*, 2000.
- [29] AN TIKHONOV, Regularization of Incorrectly Posed Problems, *Sov. Math. Dokl*, 1963.

- [30] KENNY C. GROSS, VATSAL BHARDWAJ, Randy Bickford, Proactive Detection of Software Aging Mechanisms in Performance Critical Computers, *Computer Society, IEEE* 2003.
- [31] ANDREI V. GRIBOK, ALEKSEY M. URMANOV, J. WESLEY HINES, *Uncertainty Analysis of Memory Based Sensor Validation Techniques*, Kluwer Academic Publishers, Real-Time Systems, 2004.
- [32] M. A. KRAMER, Autoassociative Neural Networks, *Computers in Chemical Engineering*, 1992.
- [33] M. A. KRAMER, Nonlinear principles component analysis using autoassociative neural network, *AIChE Journal*, 1991.
- [34] M. SHAJITH IKBAL, H. MISRA, B. YEGNANARAYANA, Analysis of autoassociative mapping neural networks, in *International Joint Conference on Neural Network*, 1999.
- [35] L. GALOTTO, J.O.P. PINTO, J.W. HINES, R.O. SANCHES, B.N. CARRASCO E G.S. TATIBANA, Improvement of Fault Detection with Partial Auto-Associative Models, *COMADEM*, 2006.

ÍNDICE

A

Aplicações Críticas, 1

C

Confiabilidade, 3
Confidencialidade, 3
Continuidade, 3
Correção de Falta, 5

D

Detecção de Falta, 11
Disponibilidade, 3

E

Efeitos das Falhas em Controle
de Motores, 14
Erro, 4
Espalhamento, 32
Esquema de votação, 44
Estabilidade, 24

F

Falha, 4
Falta, 4
Falhas Múltiplas, 17
FDI, 11
Filtragem, 33

G

Ganho na Realimentação, 24

I

Integridade, 3
Isolação de Detecção de Falta
(DIF), 11

L

Largura de banda, 38

M

Manutenção Baseada em
Condição, 13
Mediana, 45
Modelos Parciais, 44

P

Prevenção de Falta, 5

R

Redes Neurais Auto-
Associativas (RNAA),
42
Regressão Kernel, 37
Regressão Linear, 34
Regressão Ponderada
Localmente, 37
Regressão Ridge, 34
Reparabilidade, 3
Resistência a Falta, 5
RKAA, 37
RNAA, 42
Robustez, 32

S

Segurança, 3
Sistema de Controle Tolerante
a Falta Ativo, 9
Sistema de Controle Tolerante
a Falta Passivo, 9
Sistema de Controle Tolerante
e a Falta, 8

T

Técnica de Estimção de
Estados Multivariada
(MSET), 39
Tolerância a Falta, 5

V

Votação da maioria, 44

APÊNDICE 1 – SIMULAÇÕES

O modelo do simulink utilizado para o levantamento dos resultados simulados é apresentado na Figura A1.1. Na figura são observados os dois principais blocos do controle vetorial e do motor de indução, os blocos da referência, da carga, do ruído e algumas das principais medições. A carga utilizada é quadrática, que caracteriza uma carga de ventilação. O ruído é inserido externamente e, neste caso, ele é a única diferença entre o sinal medido e o sinal real.

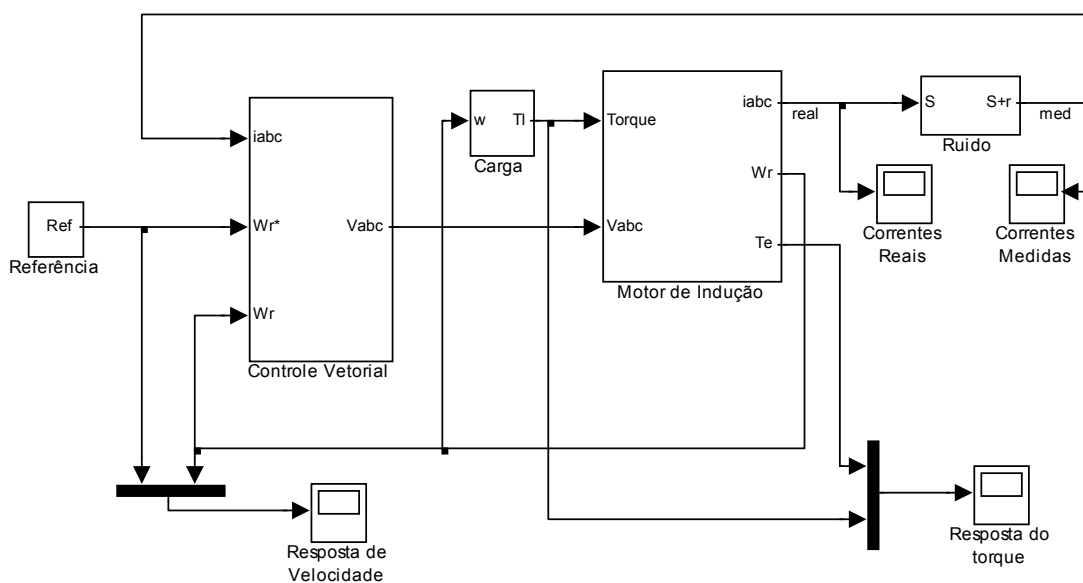


Figura A1.1. Sistema de Controle Vetorial com Motor de Indução

O controle vetorial implementado na Figura A1.2 é o indireto. A transformação d-q está presente logo no início da realimentação e a transformação inversa é utilizada para converter o comando do controlador em um sinal trifásico. Veja que sem essa transformação esse controle não seria possível.

Na Figura A1.3 está o detalhe do motor de indução utilizado que é um modelo do simulink. Note que não foi utilizado o modelo do inversor, por simplificação e facilidade de simulação. Assim, as frequências decorrentes da modulação e de banda morta não aparecem nos resultados.

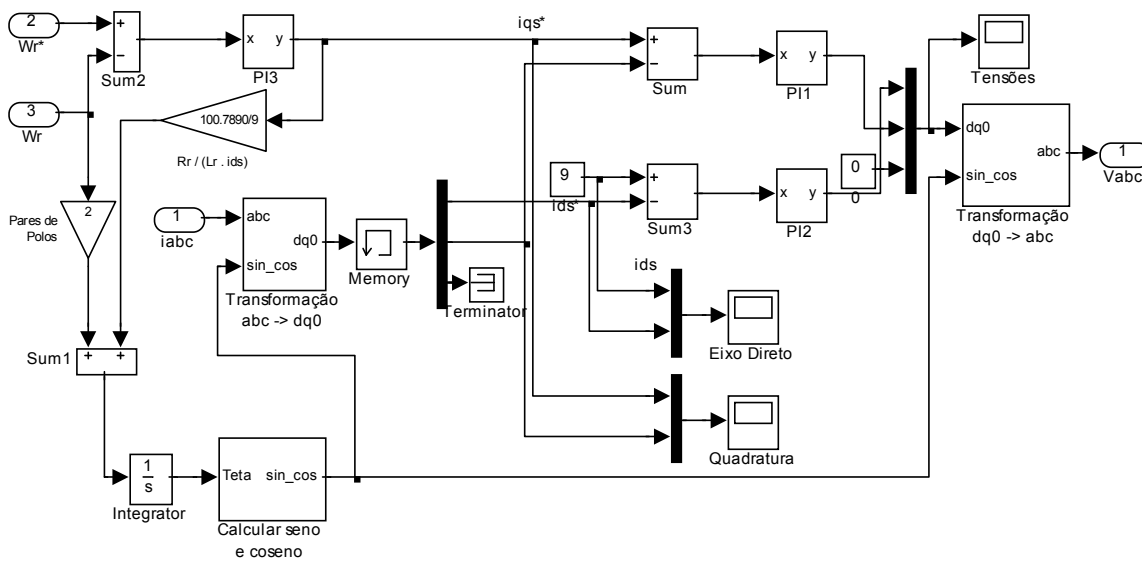


Figura A1.2. Detalhe do Controle Vetorial

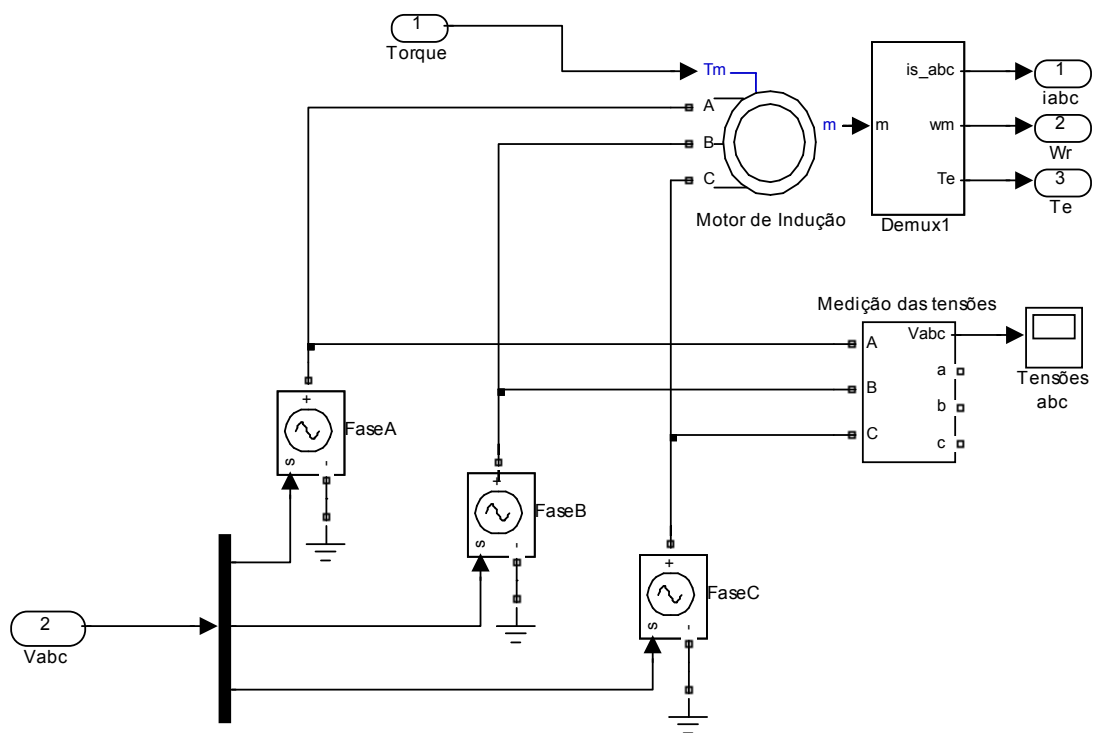


Figura A1.3. Detalhe do Motor de Indução

Os dados do motor utilizado na Figura A1.3 estão apresentados na Tabela 5.XXV.

Tabela 5.XXV. Dados do motor utilizado na simulação

<i>Condições Nominais</i>	
Potência	20 HP
Tensão de linha	575 V
Frequência	60 Hz
Velocidade	1765 rpm
<i>Características Elétricas</i>	
Resistência do Estator	0,454 Ω
Indutância do Estator	2,915 mH
Resistência do Rotor	0,2938 Ω
Indutância do Estator	2,915 mH
Indutância Mútua	107,7 mH
<i>Características Mecânicas</i>	
Inércia	0,1 Kg.m ²
Fator de fricção	0,008209 N.m.s
Pares de pólos	2
<i>Carga Externa</i>	
Torque da Carga	$\frac{\omega^2}{2250}$ N.m

O erro devido à falta aplicado no sensor foi feito como mostra a Figura A1.4. Somente um sensor sofre o efeito da falta por ser falta simples. Agora, a corrente medida se diferencia da real também pela falta aplicada.

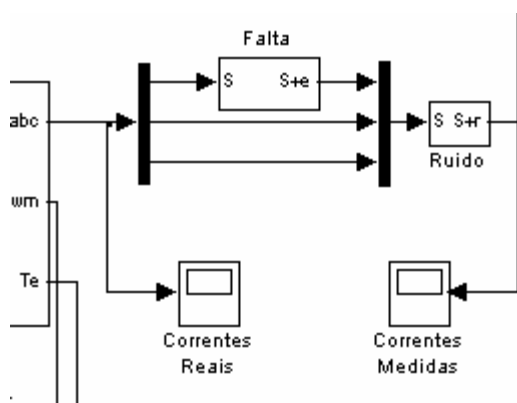


Figura A1.4. Aplicação do Erro

A Figura A1.5 mostra como os erros aditivo e multiplicativo foram aplicado no sinal. Ambos são em função do tempo. O erro aditivo é uma rampa crescente e o multiplicativo é uma exponencial decrescente.

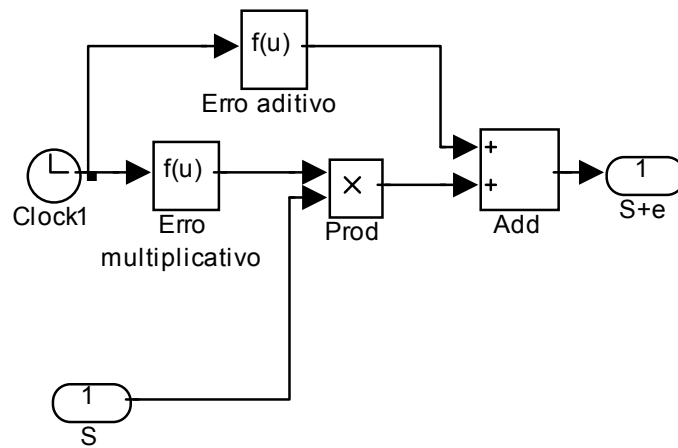


Figura A1.5. Detalhe do Bloco de Aplicação do Erro

APÊNDICE 2 – CONSTRUÇÃO DOS MODELOS

Esse apêndice detalha melhor como os modelos foram construídos. O modelo kernel é executado utilizando a função do matlab apresentada abaixo.

```
function out = kernelwts(datax, datay, in, h);

wts = similarity(in, datax', h);

wts = wts ./ (sum(wts, 2) * ones(1, size(datax, 1)));

out = wts * datay;
```

Repare que a função possui duas entradas chamadas datax e datay, que são os dados da memória que serão utilizados para fazer a regressão. As variáveis in e out são as correspondentes à $x_{entrada}$ e \hat{y} , respectivamente, de acordo com a nomenclatura adotada neste trabalho. A largura de banda é o quarto argumento de entrada de que deve ser utilizado.

A terceira e a quarta linha do programa é simplesmente o cálculo da média ponderada. O cálculo dos pesos é feito na segunda linha utilizando a função similarity exibida a seguir. Este é o código simplificado da função, mostrando somente as partes essenciais para o cálculo.

```
function m = similarity(x, y, h)

[nlinx, ncolx] = size(x);

[nliny, ncoly] = size(y);

m = zeros(nlinx, ncoly);

for k = 1:nlinx,

    for p = 1:ncoly,
```

```

    for q = 1:ncolx,

        m(k,p) = m(k,p) + (x(k,q) - y(q,p)).^2;

    end

    m(k,p) = exp(-m(k,p) / (2*h^2)) ./ (h*sqrt(2*pi));

end

end

```

Esta função é o operador não linear similaridade descrito neste trabalho. Ele é utilizado tanto para o modelo kernel quanto para o modelo MSET. Ela utiliza por padrão a função kernel gaussiana e a soma dos quadrados como distância.

No caso do modelo MSET a matriz de memória, que também é construída utilizando o mesmo operador similaridade, deve ser criada na inicialização. Os dois modelos necessitam de dados da memória por se tratarem de métodos não-paramétricos. Os dados devem identificar o plano que indica que a soma das três correntes é igual a zero. A Figura A2.1 mostra os dados escolhidos por obterem o melhor desempenho.

A fase C fica entre -100 e 100 e as outras fases ficam entre -50 e 50. Caso os valores medidos das correntes ultrapassem esses limites em condições normais de operação, o modelo kernel irá saturar nos limites desses dados. Portanto, o alcance desses dados deve ser ampliado de acordo com a corrente a ser medida.




Figura A2.1. Dados Utilizados para a Memória dos Modelos

As redes neurais também utilizam estes mesmo dados para realizar o treinamento. Mas quando treinada, os dados não são mais necessários.

As implementações no simulink dos modelos parciais são exibidas pela com três na Figura A2.2 e com seis sensores na Figura A2.3. Os demais são feitos de maneira semelhante. Note que com seis sensores de corrente é possível construir quatro diferentes modelos parciais, já que há quatro estimações por fase.

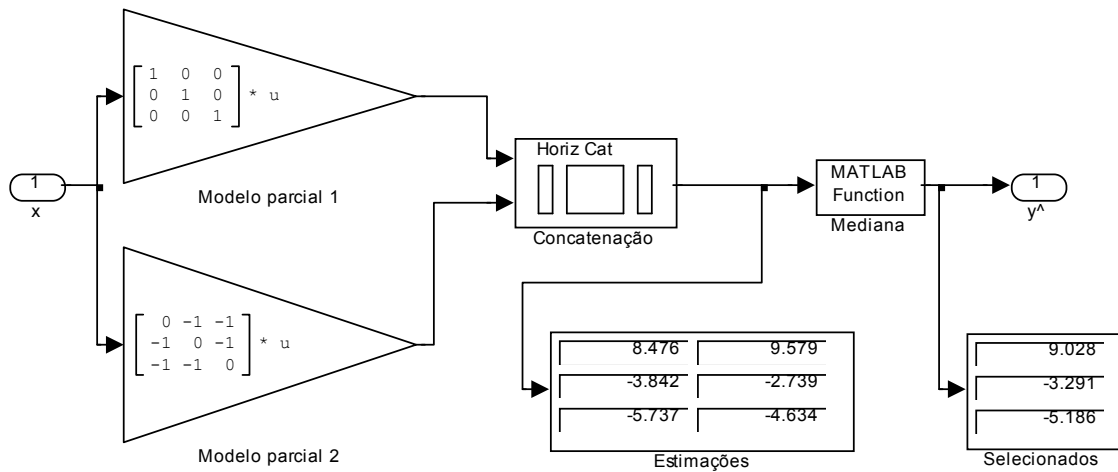


Figura A2.2. Modelo Parcial Linear com Três Sensores de Corrente

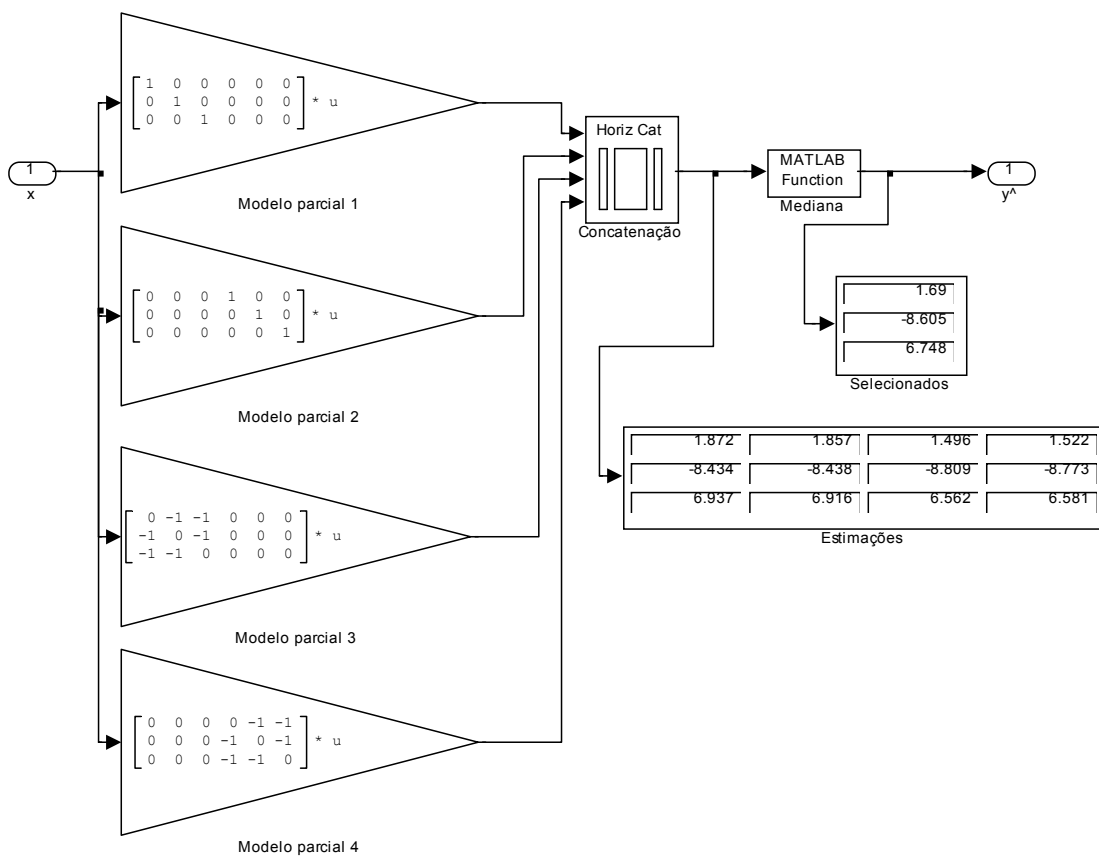


Figura A2.3. Modelo Parcial Linear com Seis Sensores de Corrente

APÊNDICE 3 – RESULTADOS DETALHADOS

Neste apêndice serão apresentados as correntes trifásicas, as correntes do eixo direto e em quadratura e o torque desenvolvido pelo motor utilizando as técnicas de compensação.

- **Linear – 3 Sensores**

Na Figura A3.1, as correntes de linha são separadas em reais, medidas e estimadas operando com um modelo linear com três sensores de corrente. A diferença entre as correntes reais e as correntes medidas ocorre devido ao erro de medição. As correntes estimadas são obtidas a partir das correntes medidas, mas devem se aproximar o máximo das correntes reais. Assim, o controlador poderia identificar o que realmente ocorre nas correntes ainda que haja erros de medição.

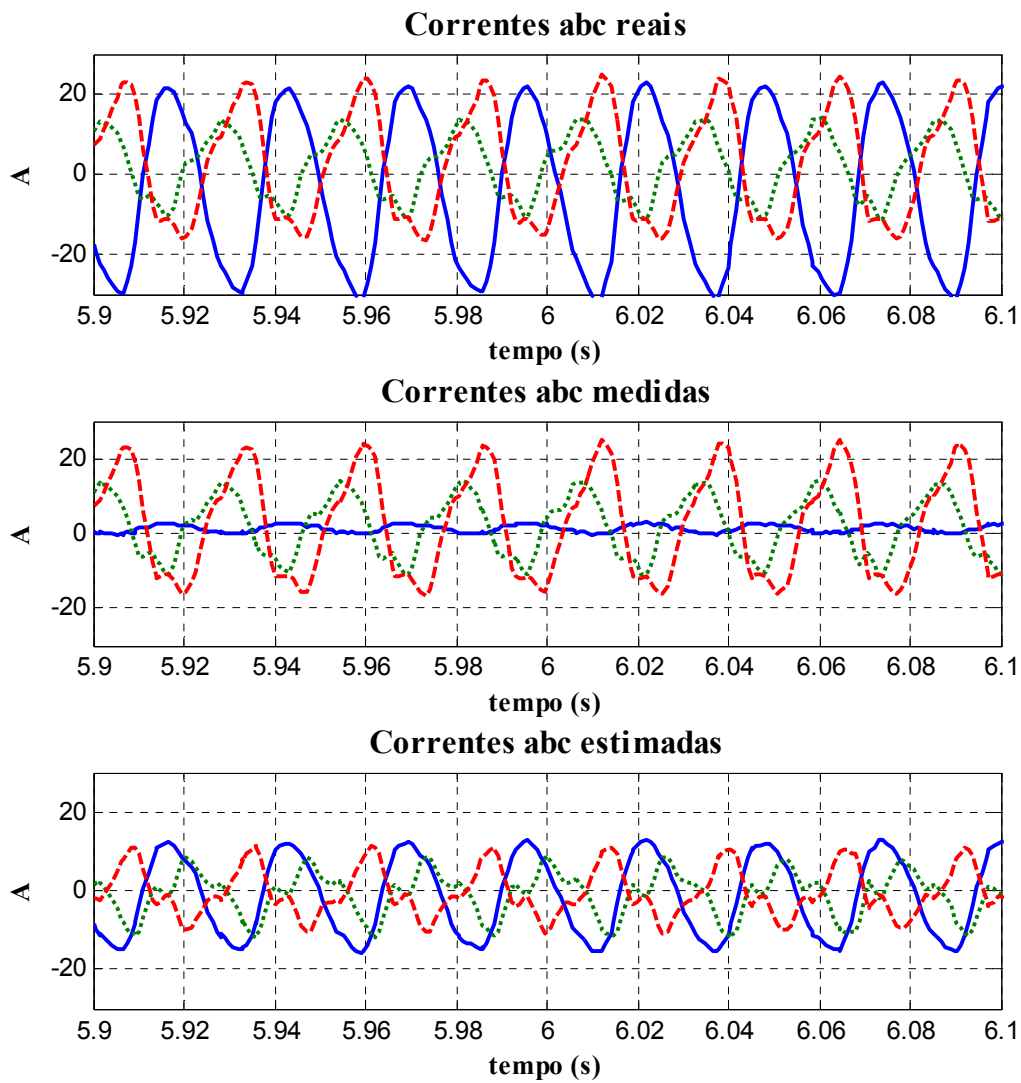


Figura A3.1. Correntes de Linha Utilizando um Modelo Linear com 3 Sensores

Na Figura A3.2 é possível visualizar as correntes do eixo direto e em quadratura correspondentes.




Figura A3.2. Correntes d-q Utilizando um Modelo Linear com 3 Sensores

A Figura A3.3 apresenta o torque desenvolvido com a compensação, que é diretamente proporcional ao produto das duas correntes apresentadas na Figura A3.2.




Figura A3.3. Torque Utilizando um Modelo Linear com 3 Sensores

- **Kernel – 3 Sensores**

Na Figura A3.4, as correntes estimadas se assemelham muito com as correntes reais, mas elas são atenuadas. Essa atenuação das correntes estimadas justifica a amplificação das oscilações, visto que o controlador recebe os sinais de corrente menores do que realmente são.

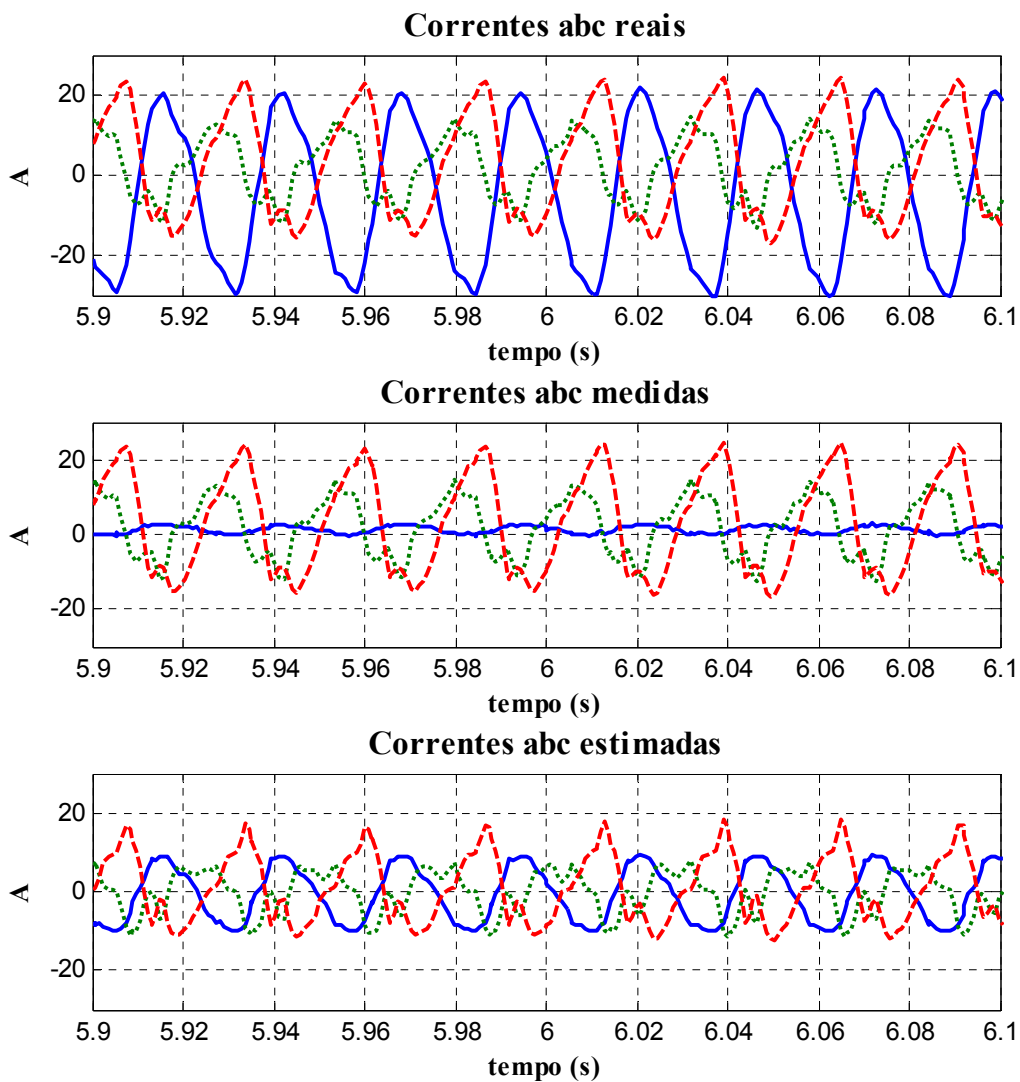


Figura A3.4. Correntes de Linha com o Modelo Kernel com 3 Sensores

As correntes d-q com o modelo kernel apresentam picos maiores do que a situação com falta pela Figura A3.5. Essa ocorrência de picos pode ser resultado da perda do desacoplamento dos eixos direto e em quadratura. Neste caso, o controle vetorial não estaria mais sendo realizado.




Figura A3.5. Correntes d-q com o Modelo Kernel com 3 Sensores

Os mesmos picos de corrente também implicam em picos de torque na Figura A3.6.




Figura A3.6. Torque com o Modelo Kernel com 3 Sensores

- **MSET – 3 Sensores**

O modelo MSET tende a se aproximar de um modelo linear com uma grande largura de banda, por isso as correntes em tendem a ser menos distorcidas.

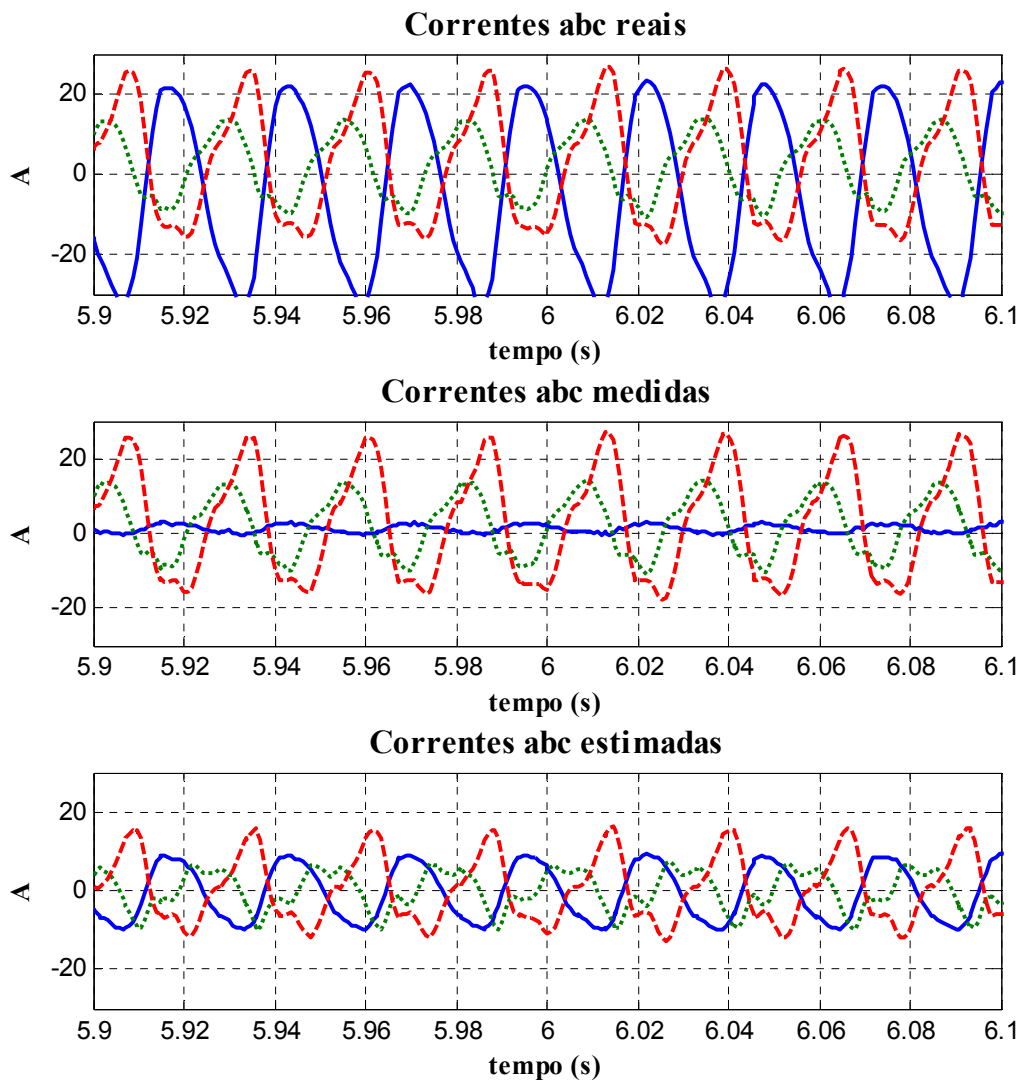


Figura A3.7. Correntes de Linha com o Modelo MSET com 3 Sensores




Figura A3.8. Correntes d-q com o Modelo MSET com Três Sensores




Figura A3.9. Torque com o Modelo MSET com 3 Sensores

- RNAA – 3 Sensores

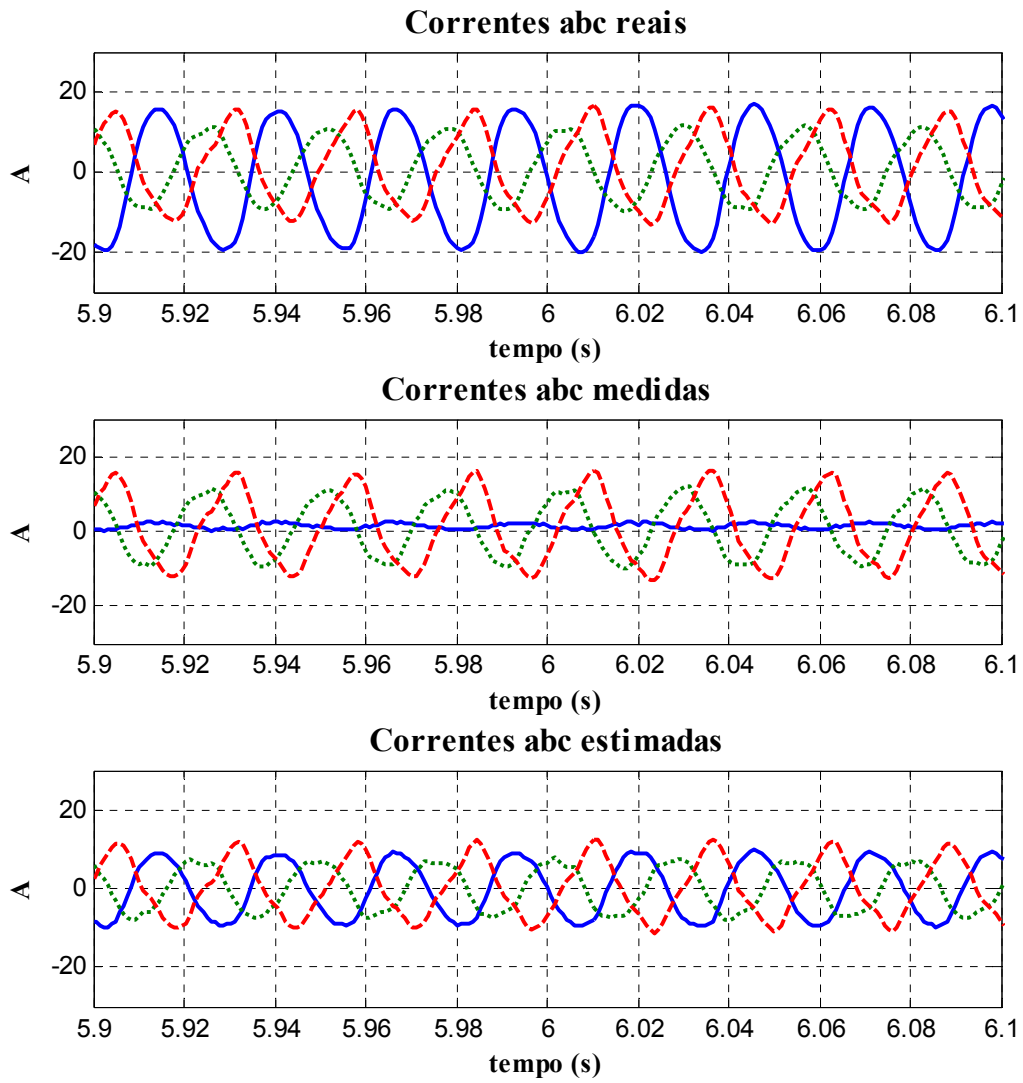


Figura A3.10. Correntes de Linha com o Modelo RNAA com 3 Sensores




Figura A3.11. Correntes d-q com o Modelo RNAA com 3 Sensores




Figura A3.12. Torque com o Modelo RNAA com 3 Sensores

- **Linear Parcial – 3 Sensores**

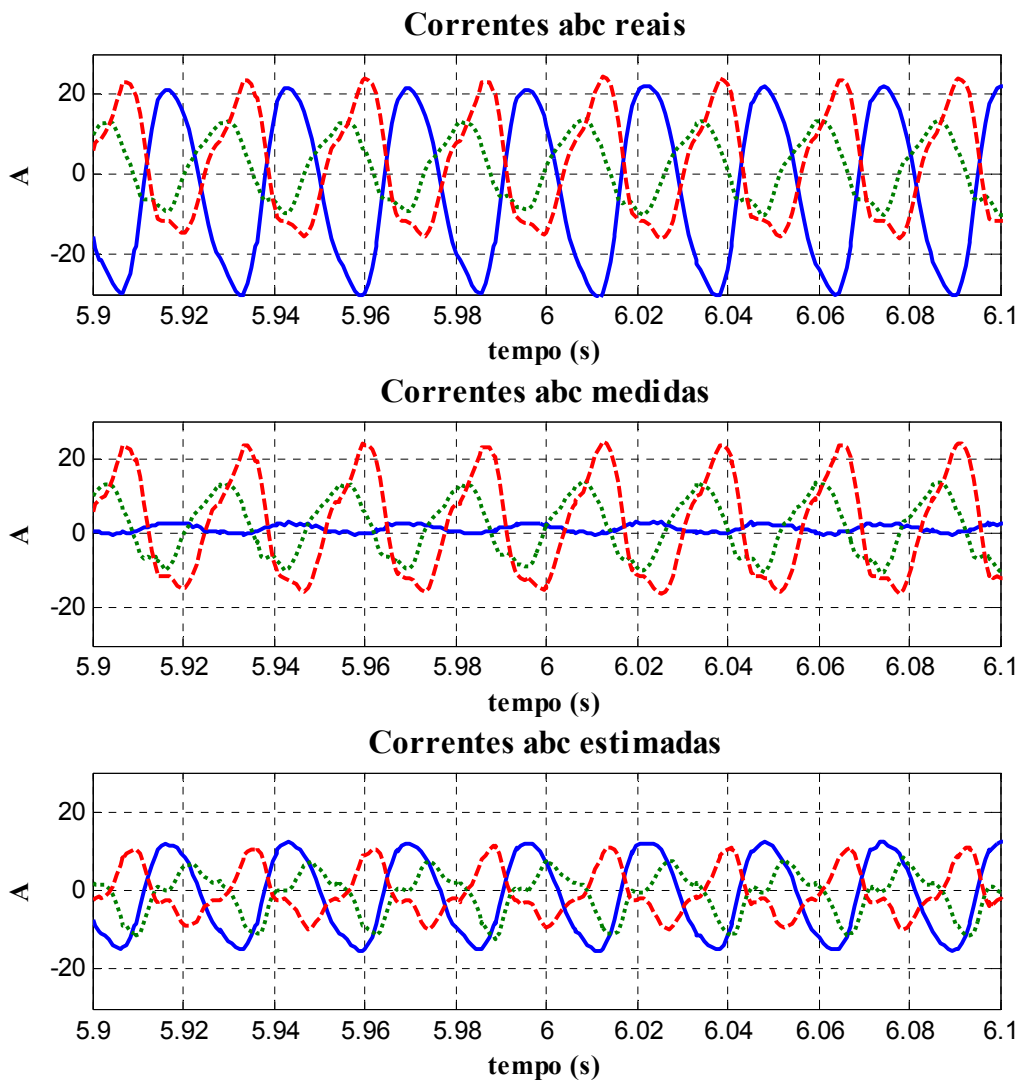


Figura A3.13. Correntes de Linha com o Modelo Parcial Linear com 3 Sensores




Figura A3.14. Correntes d-q com o Modelo Parcial Linear com 3 Sensores




Figura A3.15. Torque com o Modelo Parcial Linear com 3 Sensores

- **Linear – 4 Sensores**

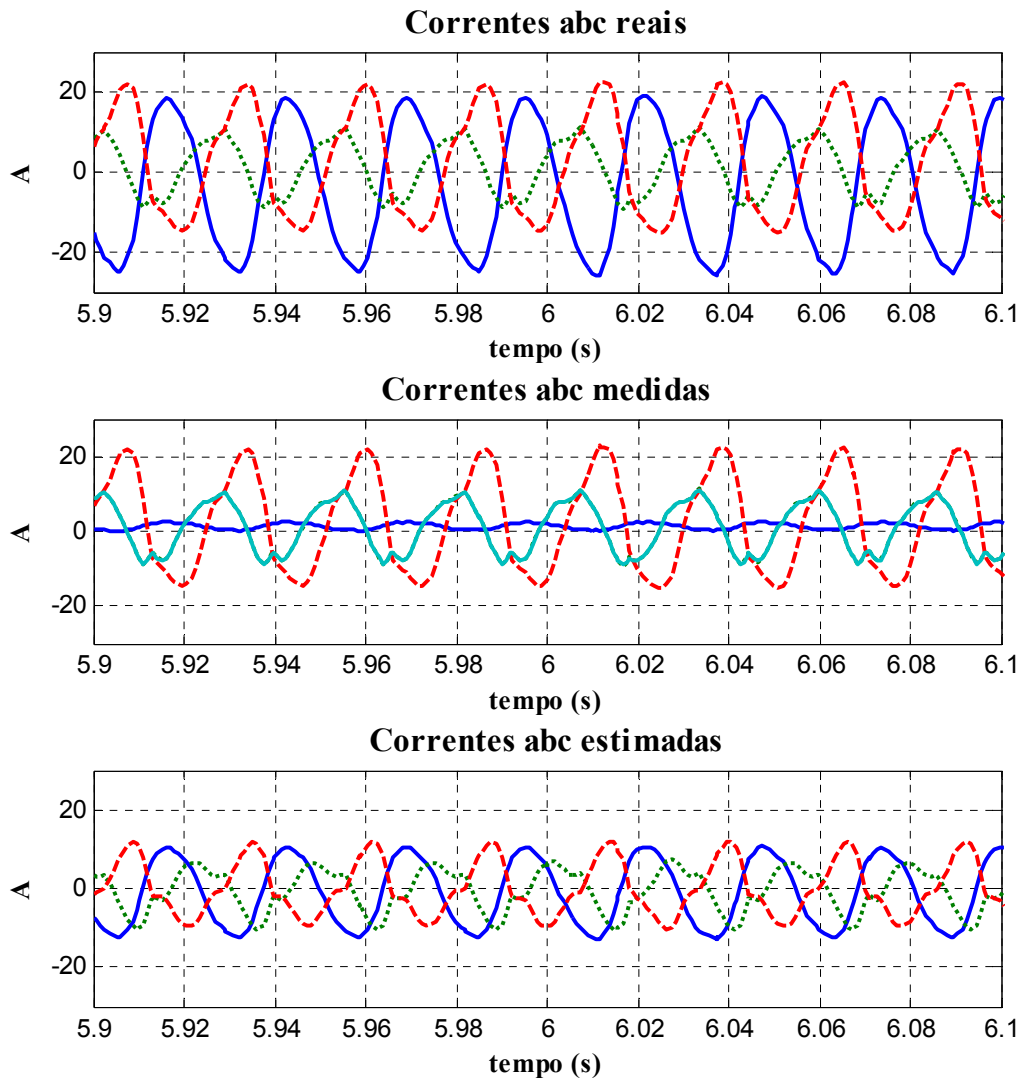


Figura A3.16. Correntes de Linha com o Modelo Linear com 4 Sensores




Figura A3.17. Correntes d-q com o Modelo Linear com 4 Sensores




Figura A3.18. Torque com o Modelo Linear com 4 Sensores

- Kernel – 4 Sensores

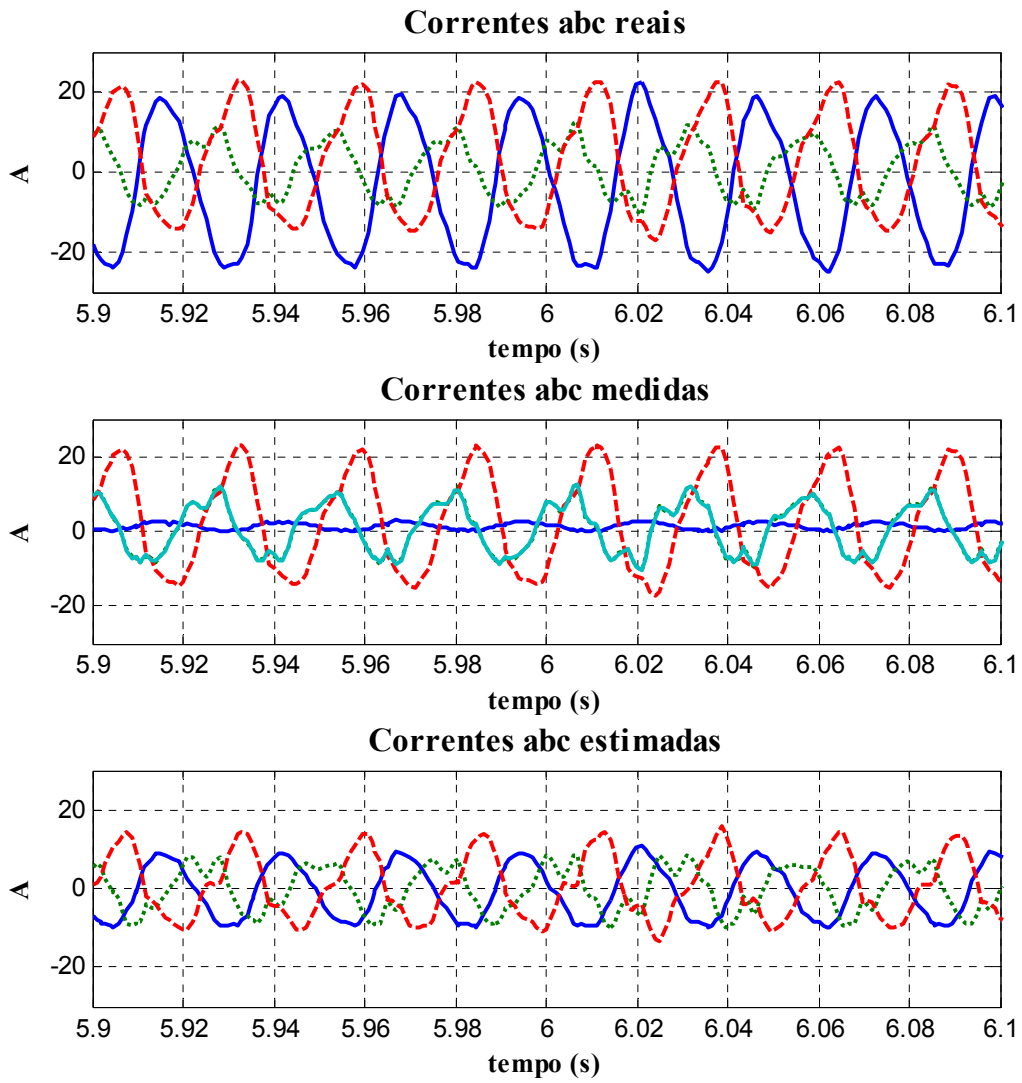


Figura A3.19. Correntes de Linha com o Modelo Kernel com 4 Sensores




Figura A3.20. Correntes d-q com o Modelo Kernel com 4 Sensores




Figura A3.21. Torque com o Modelo Kernel com 4 Sensores

- MSET – 4 Sensores

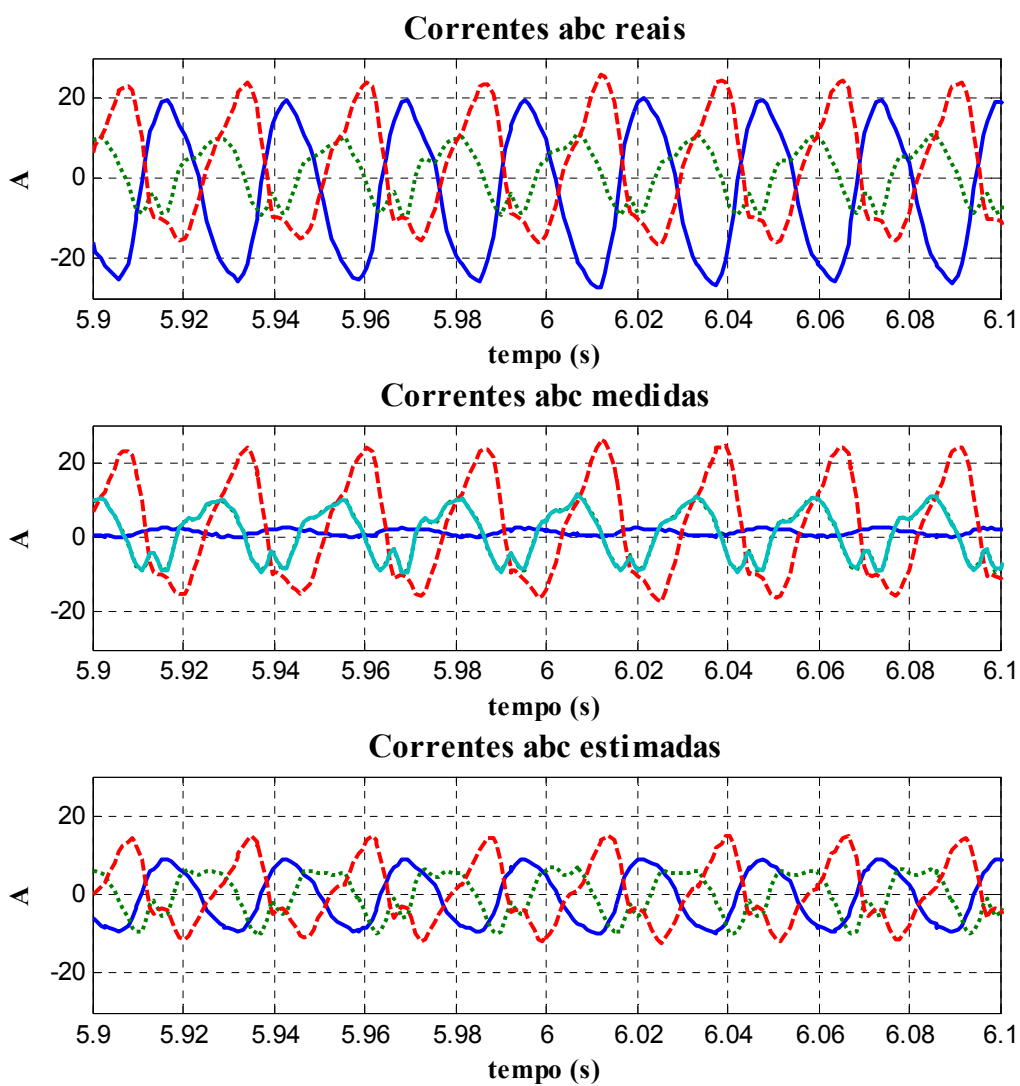


Figura A3.22. Correntes de Linha com o Modelo MSET com 4 Sensores




Figura A3.23. Correntes d-q com o Modelo MSET com 4 Sensores




Figura A3.24. Torque com o Modelo MSET com 4 Sensores

- RNAA – 4 Sensores

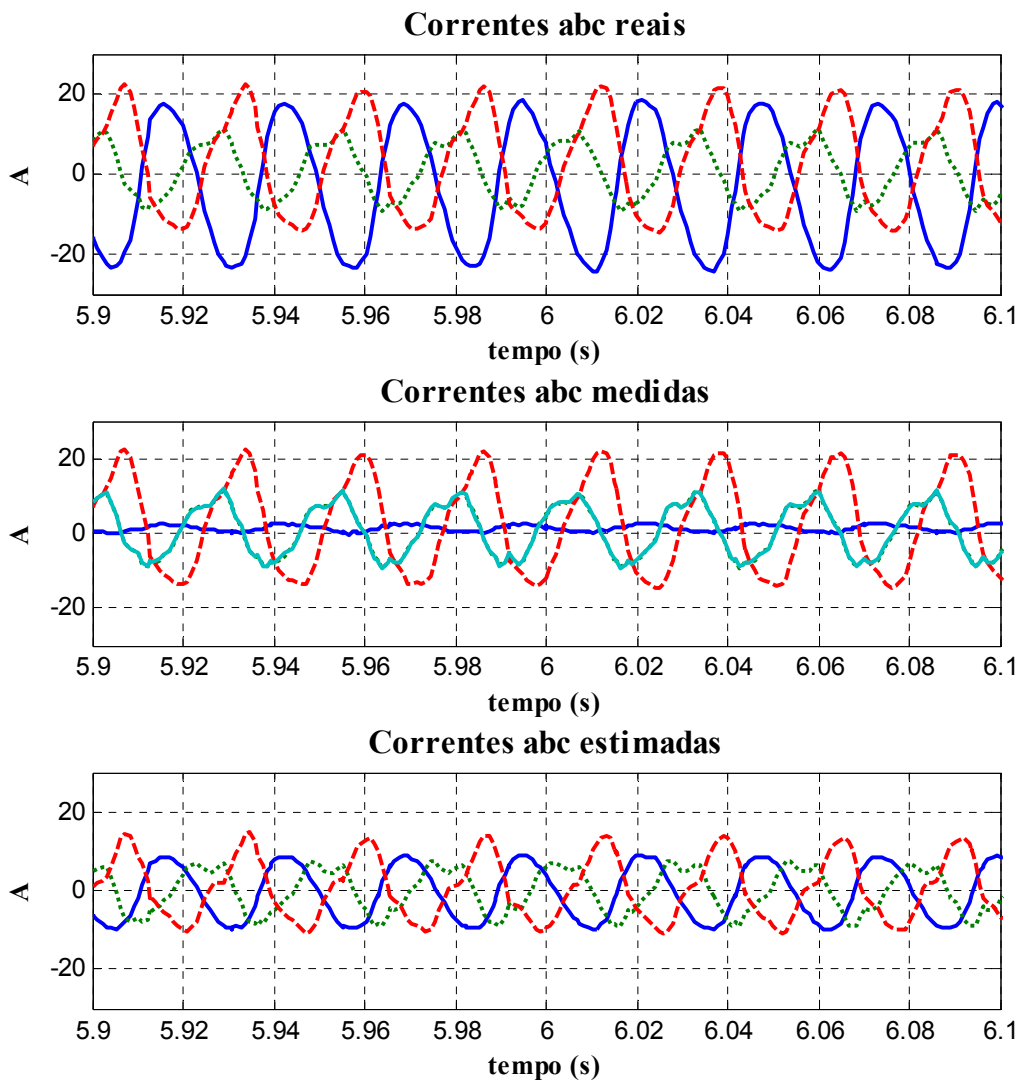


Figura A3.25. Correntes de Linha com o Modelo RNAA com 4 Sensores




Figura A3.26. Correntes d-q com o Modelo RNAA com 4 Sensores




Figura A3.27. Torque com o Modelo RNAA com 4 Sensores

- **Parcial Linear – 4 Sensores**

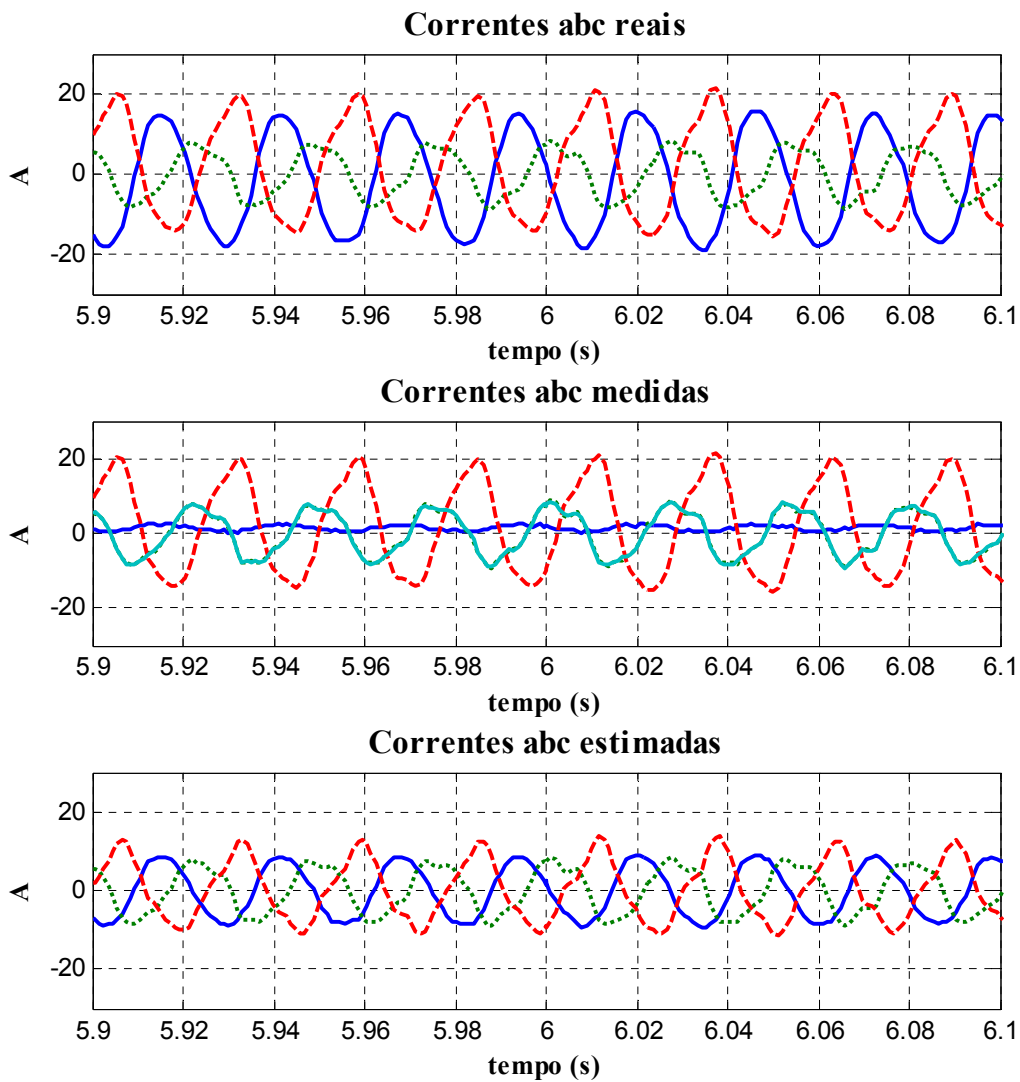


Figura A3.28. Correntes de Linha com o Modelo Parcial Linear com 4 Sensores




Figura A3.29. Correntes d-q com o Modelo Parcial Linear com 4 Sensores




Figura A3.30. Torque com o Modelo Parcial Linear com 4 Sensores

- **Linear – 5 Sensores**

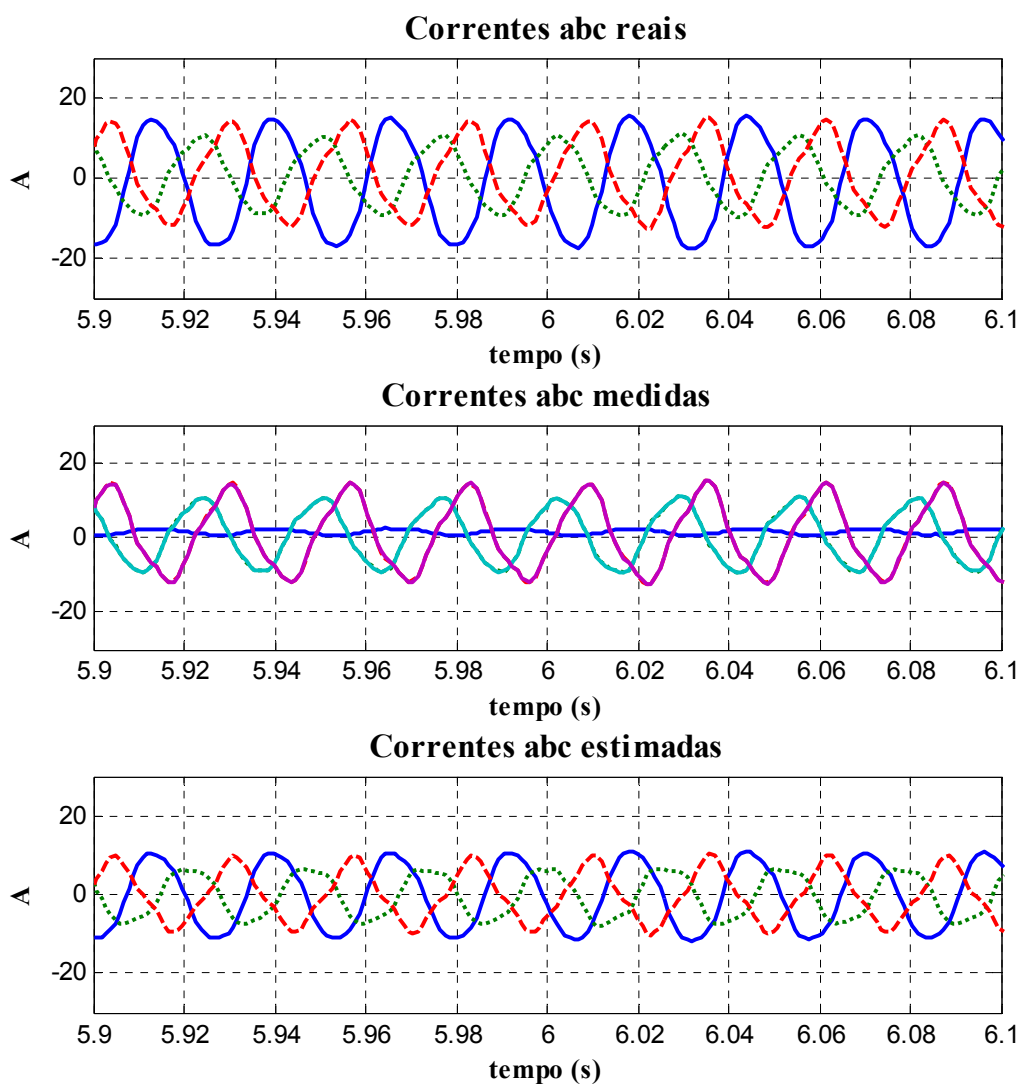


Figura A3.31. Correntes de Linha com o Modelo Linear com 5 Sensores




Figura A3.32. Correntes d-q com o Modelo Linear com 5 Sensores




Figura A3.33. Torque com o Modelo Linear com 5 Sensores

- Kernel – 5 Sensores

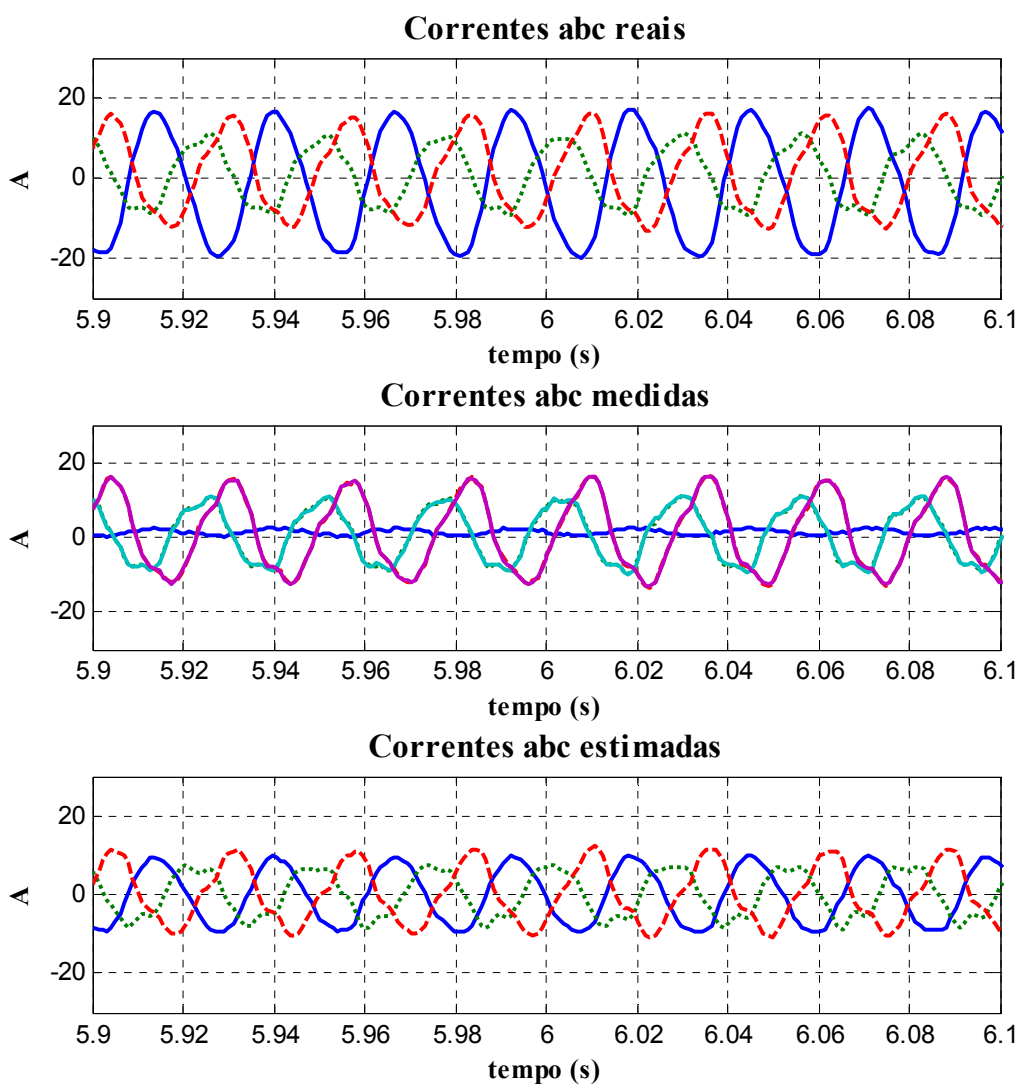


Figura A3.34. Correntes de Linha com o Modelo Kernel com 5 Sensores




Figura A3.35. Correntes d-q com o Modelo Kernel com 5 Sensores




Figura A3.36. Torque com o Modelo Kernel com 5 Sensores

- MSET – 5 Sensores

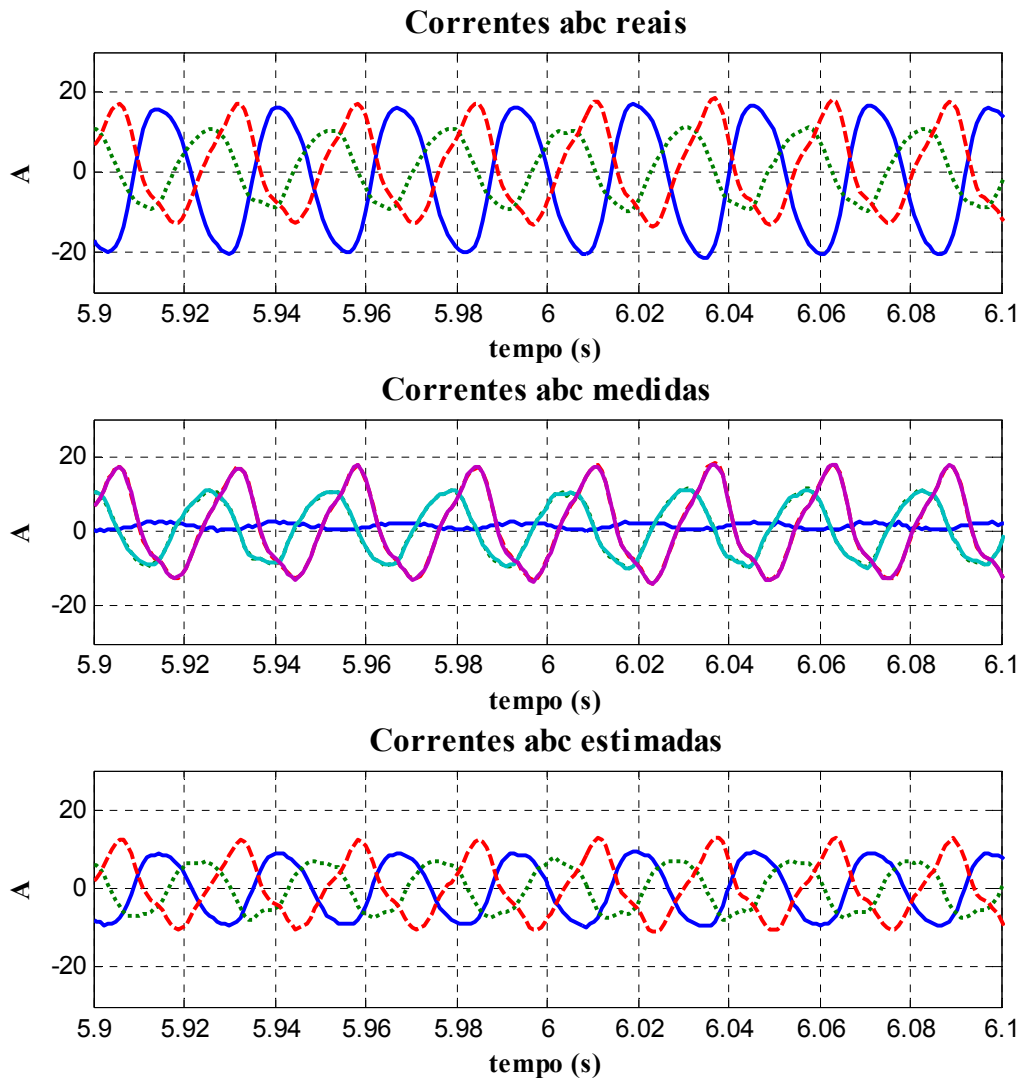


Figura A3.37. Correntes de linha com o Modelo MSET com 5 Sensores




Figura A3.38. Correntes d-q com o modelo MSET com 5 Sensores




Figura A3.39. Torque com o Modelo MSET com 5 Sensores

- RNAA – 5 Sensores

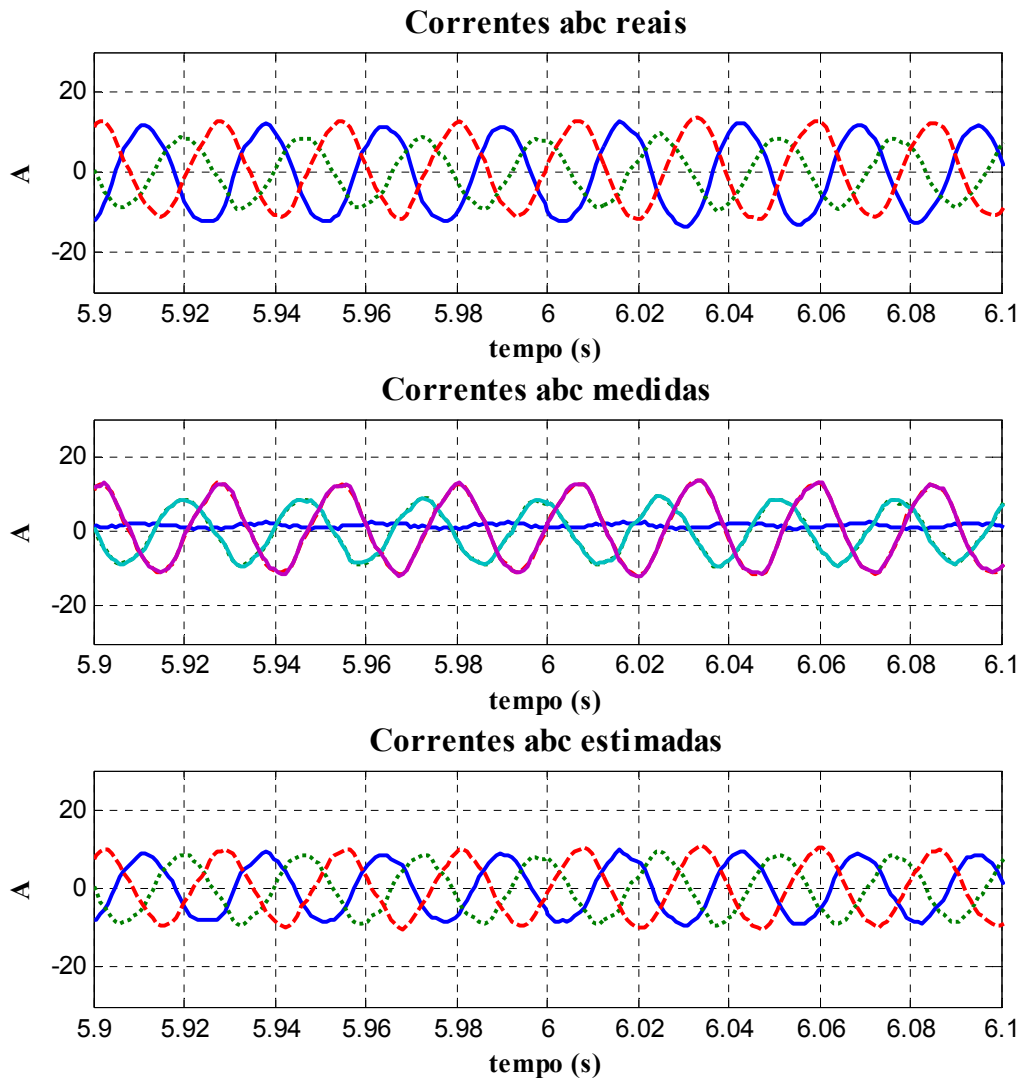


Figura A3.40. Correntes de Linha com o Modelo RNAA com 5 Sensores




Figura A3.41. Correntes d-q com o Modelo RNAA com 5 Sensores

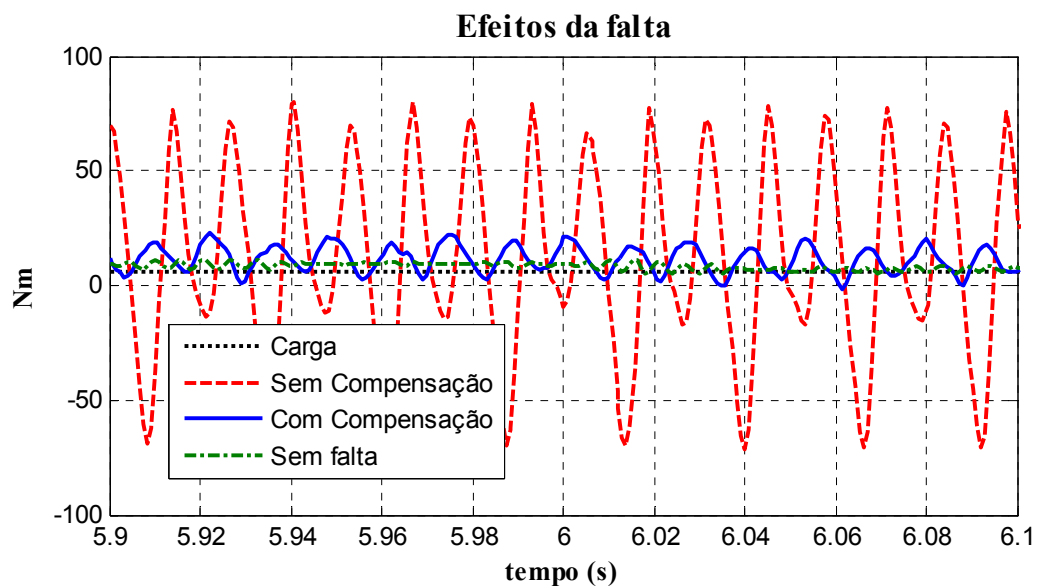


Figura A3.42. Torque com o Modelo RNAA com 5 Sensores

- **Parcial Linear – 5 Sensores**

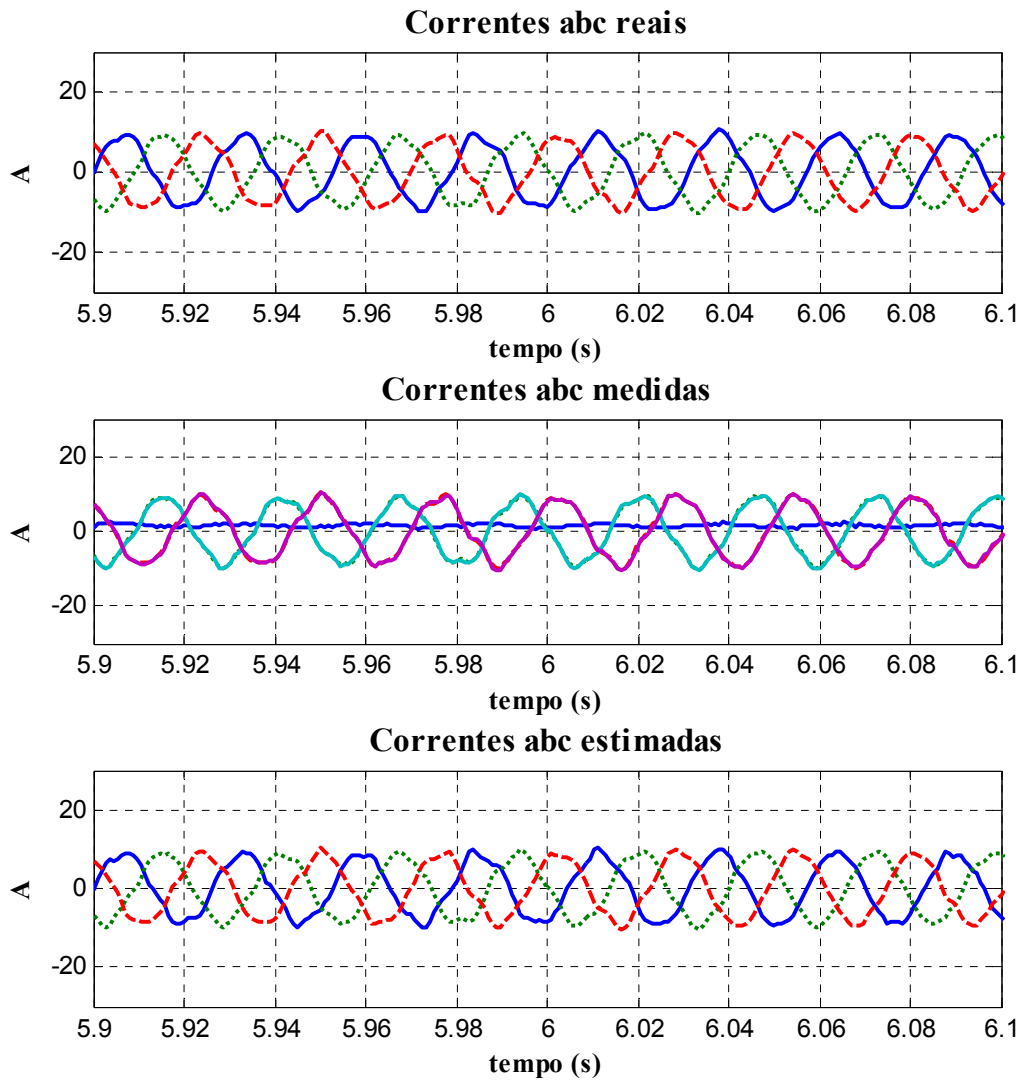


Figura A3.43. Correntes de Linha com o Modelo Parcial Linear com 5 Sensores




Figura A3.44. Correntes d-q com o Modelo Parcial Linear com 5 Sensores




Figura A3.45. Torque com o Modelo Parcial Linear com 5 Sensores

- **Linear – 6 Sensores**

Todos os modelos com seis sensores obtiveram uma qualidade muito boa das estimações em relação ao sinal real que devem ser os mais próximos possíveis.

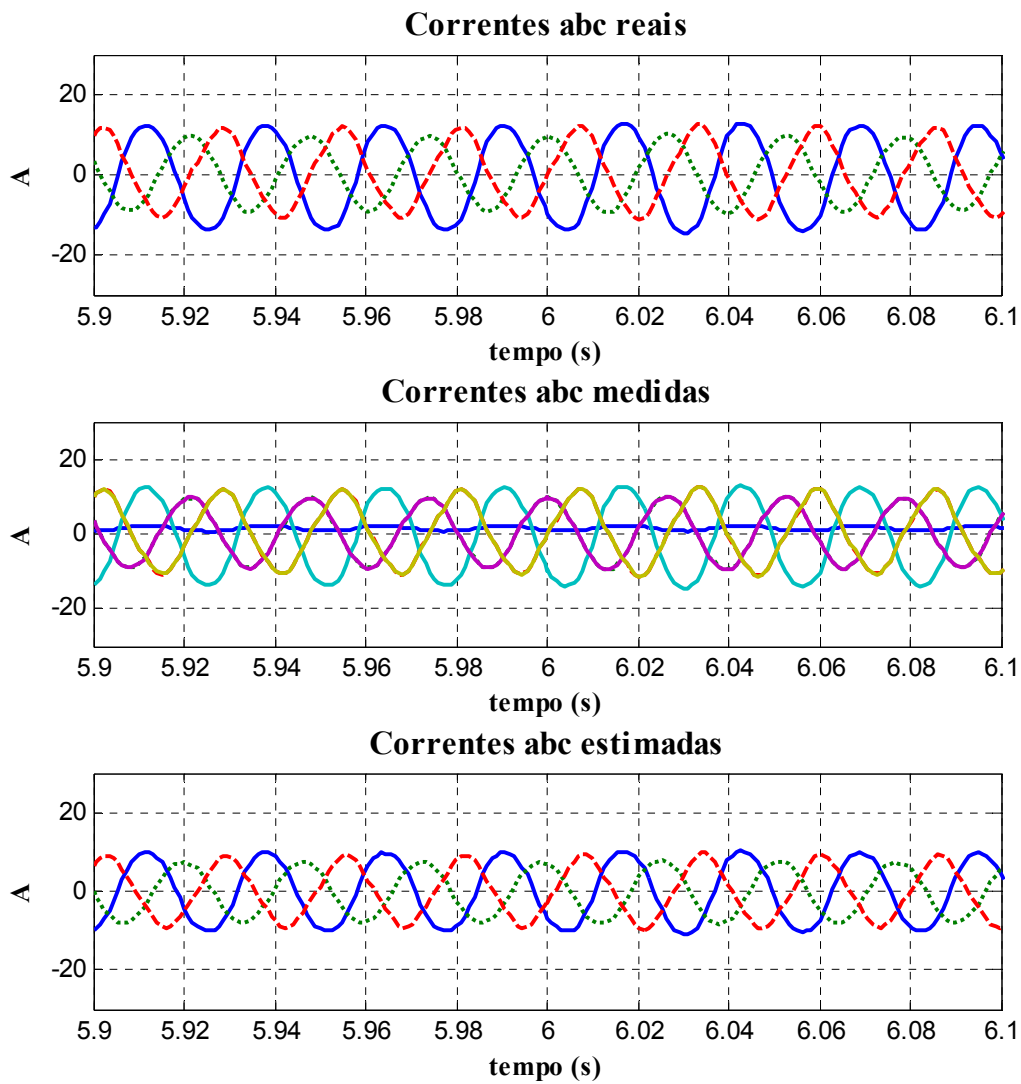


Figura A3.46. Correntes de Linha com o Modelo Linear com 6 Sensores




Figura A3.47. Correntes d-q com o Modelo Linear com 6 Sensores




Figura A3.48. Torque com o Modelo Linear com 6 Sensores

- Kernel – 6 Sensores

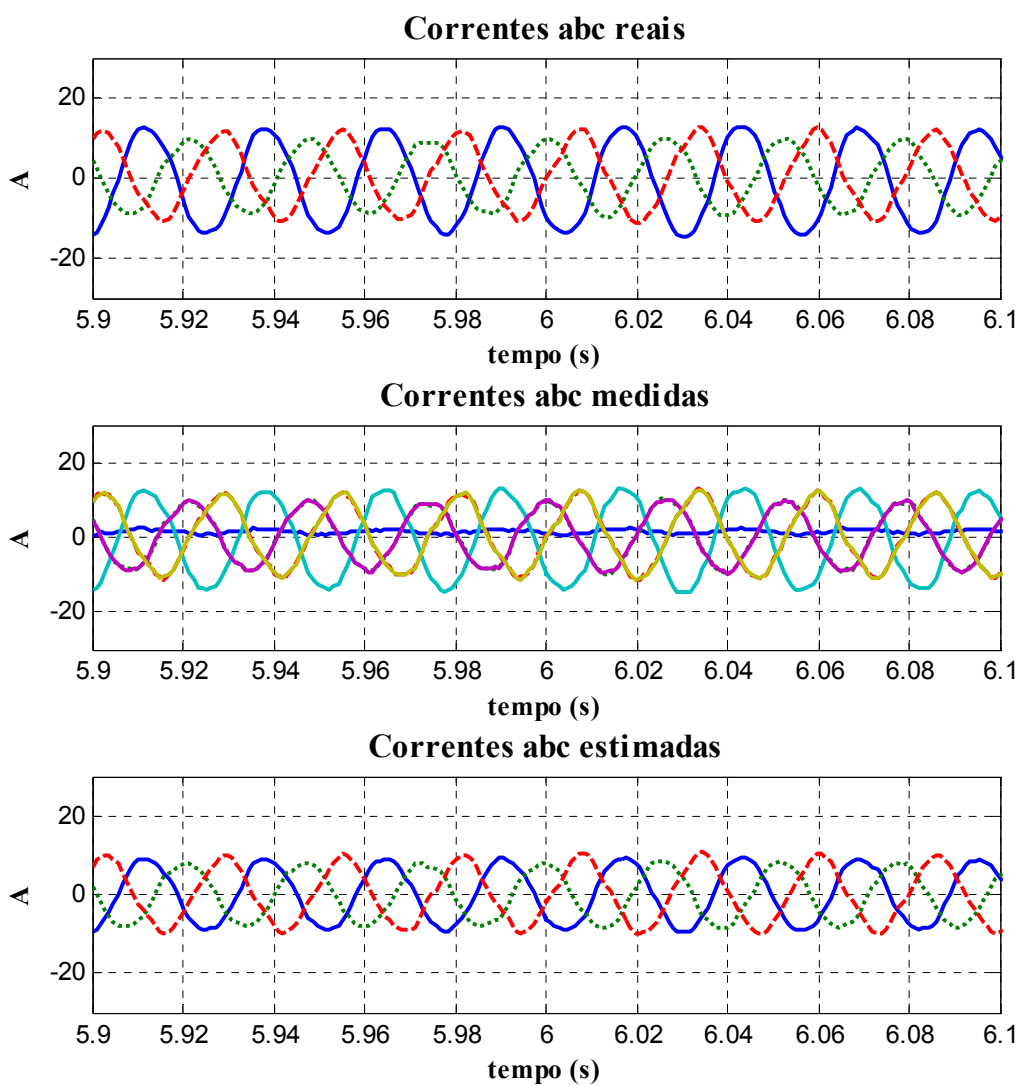


Figura A3.49. Correntes de Linha com o Modelo Kernel com 6 Sensores




Figura A3.50. Correntes d-q com o Modelo Kernel com 6 Sensores




Figura A3.51. Torque com o Modelo Kernel com 6 Sensores

- **MSET – 6 Sensores**

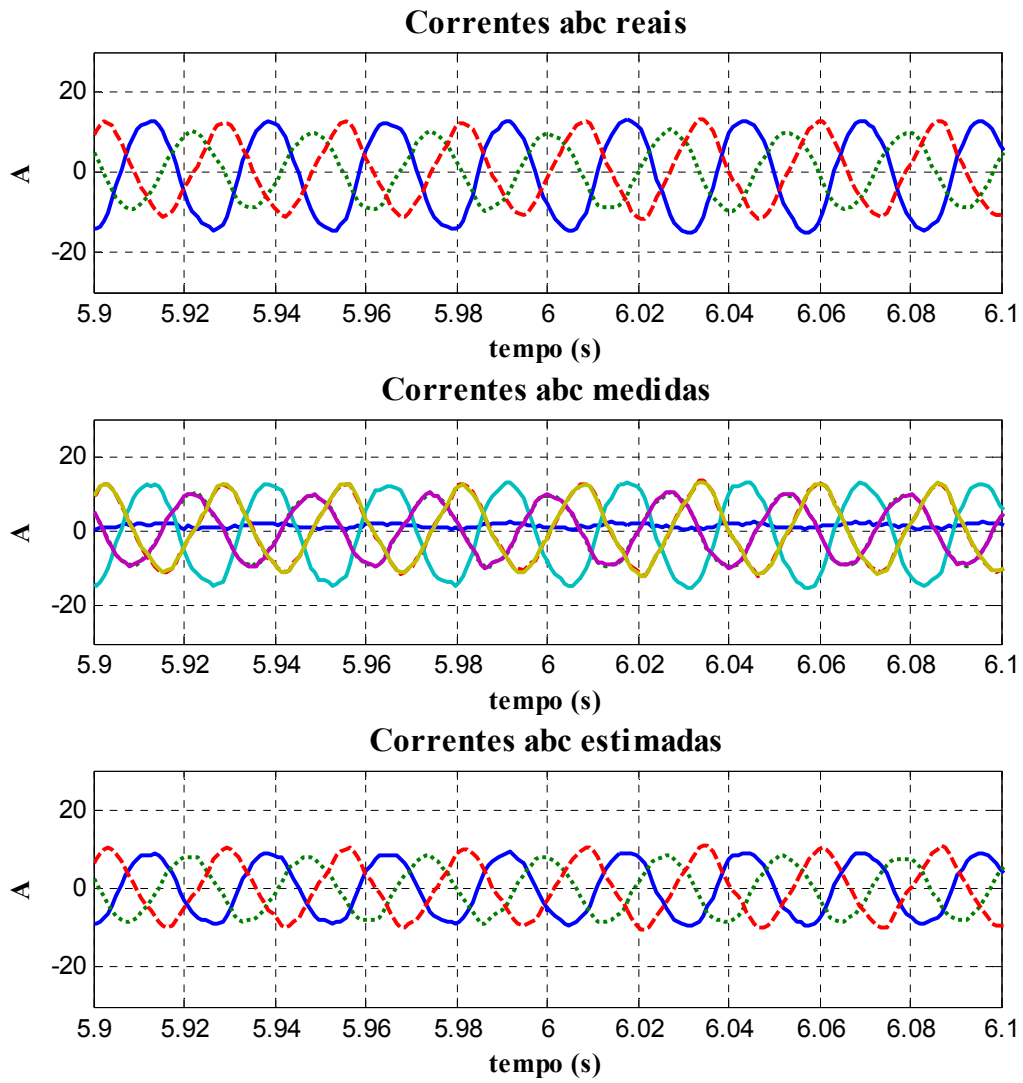


Figura A3.52. Correntes de Linha com o Modelo MSET com 6 Sensores




Figura A3.53. Correntes d-q com o Modelo MSET com 6 Sensores




Figura A3.54. Torque com o Modelo MSET com 6 Sensores

- RNAA – 6 Sensores

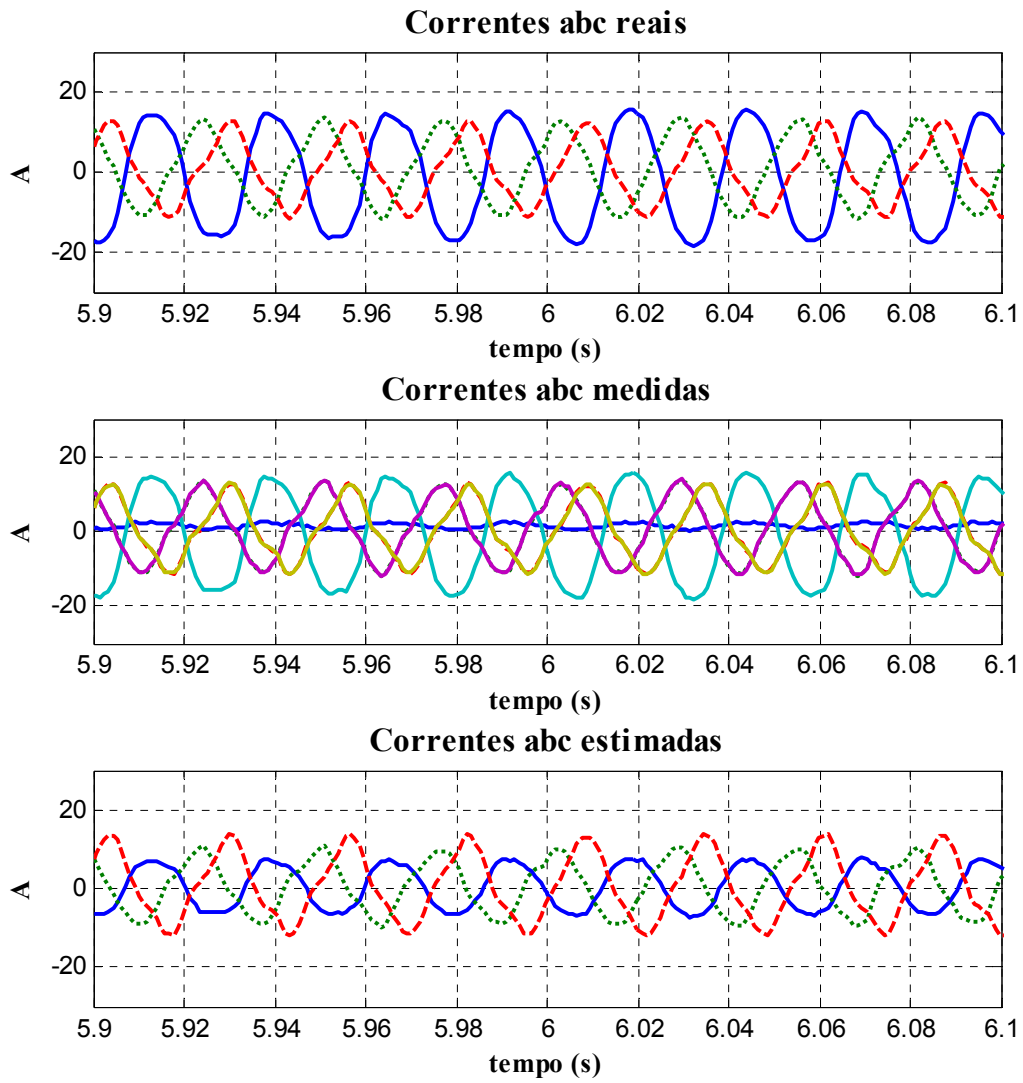


Figura A3.55. Correntes de Linha com o Modelo RNAA com 6 Sensores




Figura A3.56. Correntes d-q com o Modelo RNAA com 6 Sensores

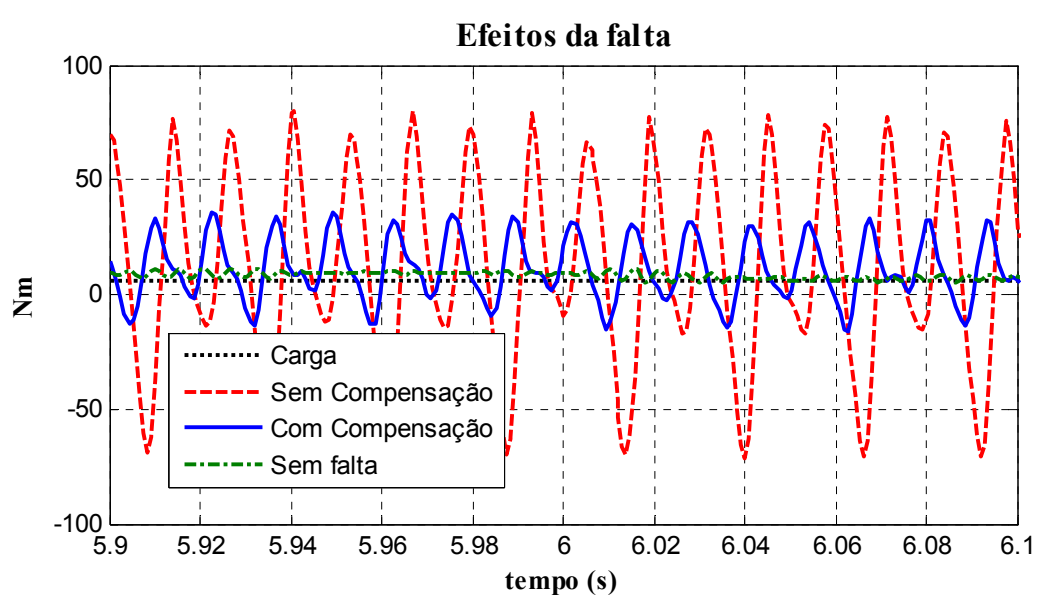


Figura A3.57. Torque com o Modelo RNAA com 6 Sensores

- **Parcial linear – 6 Sensores**

Para este modelo a estimação é aparentemente perfeita. O efeito da falta é praticamente imperceptível.

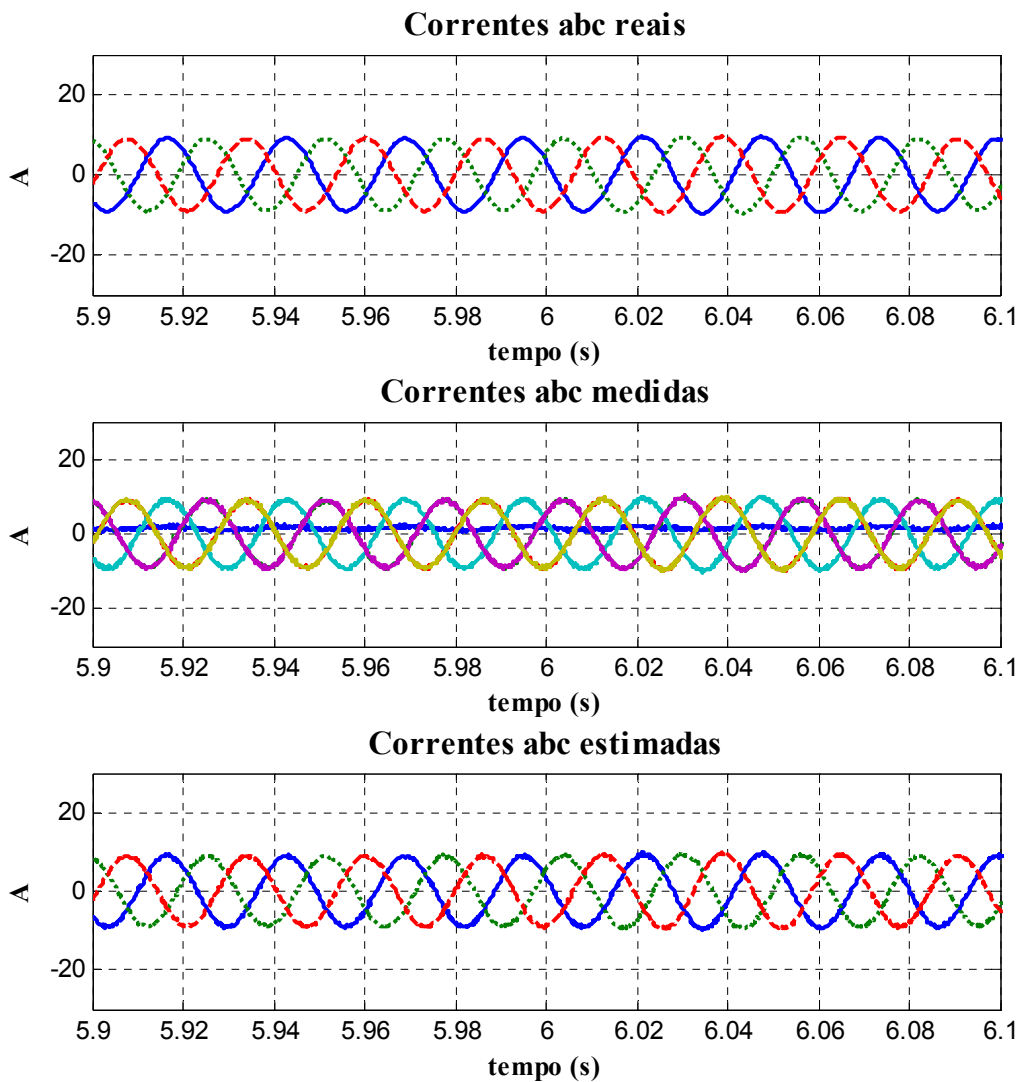


Figura A3.58. Correntes de Linha com o Modelo Parcial Linear com 6 Sensores

Pelas correntes d-q e pelo torque também é possível perceber a ausência das oscilações causadas pelo erro de medição. A resposta transitória com o modelo parcial linear pode ser ainda superior ao controle convencional mesmo em condições normais. Isso porque a

precisão da medição das correntes é aumentada devido à redução do ruído produzida pelo modelo.




Figura A3.59. Correntes d-q com o Modelo Parcial Linear com 6 Sensores




Figura A3.60. Torque com o Modelo Parcial Linear com 6 Sensores