

**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
DEPARTAMENTO DE ENGENHARIA ELÉTRICA**



**DIAGNOSE DE FALHAS E GESTÃO DE ALARMES
EM SISTEMAS DE INSTRUMENTAÇÃO E
CONTROLE INDUSTRIAIS**

GERÔNIMO BARBOSA ALEXANDRE

ORIENTAÇÃO:

PROF. Dr. ANTONIO MARCUS NOGUEIRA LIMA

CAMPINA GRANDE – PARAÍBA - BRASIL

2013

GERÔNIMO BARBOSA ALEXANDRE

**DIAGNOSE DE FALHAS E GESTÃO DE ALARMES EM
SISTEMAS DE INSTRUMENTAÇÃO E CONTROLE INDUSTRIAIS**

Campina Grande - PB

2013

GERÔNIMO BARBOSA ALEXANDRE

**DIAGNOSE DE FALHAS E GESTÃO DE ALARMES EM
SISTEMAS DE INSTRUMENTAÇÃO E CONTROLE INDUSTRIAIS**

Monografia submetida ao corpo docente do curso de graduação em Engenharia Elétrica da Universidade Federal de Campina Grande, como parte dos requisitos para obtenção do grau de Engenheiro Eletricista.

Orientador:

Prof. Dr. Antonio Marcus Nogueira Lima.

Campina Grande- PB

2013

GERÔNIMO BARBOSA ALEXANDRE

**DIAGNOSE DE FALHAS E GESTÃO DE ALARMES EM
SISTEMAS DE INSTRUMENTAÇÃO E CONTROLE INDUSTRIAIS**

Monografia submetida à banca examinadora designada pela Coordenação de Graduação em Engenharia Elétrica (CGEE) da Universidade Federal de Campina Grande, como parte dos requisitos necessários para obtenção do grau de Bacharel em Engenharia Elétrica.

Aprovada em 14 de outubro de 2013.

Por:

Antonio Marcus Nogueira Lima, Dr.
Prof. DEE/UFCG- Orientador
Presidente da banca examinadora

Marcos Ricardo Alcântara Morais, D. Sc.
Prof. DEE/UFCG- Avaliador

Agradecimentos

O autor agradece ao Departamento de Engenharia Elétrica do Centro de Engenharia Elétrica e Informática da Universidade Federal de Campina Grande. Ao grupo de Instrumentação e Controle, LIEC-UFCG, em especial ao orientador pela paciência e dedicação no desenvolvimento deste trabalho.

Agradeço a DEUS por estar comigo todas as horas. A minha família e a todos os colegas que acompanham minha trajetória.

Resumo

Neste trabalho apresentamos soluções para detecção, diagnóstico e mitigação de falhas em processos industriais, as soluções foram implementadas em ambiente MATLAB-Simulink®.

A primeira solução trata-se de uma metodologia para detecção e isolamento de falhas em processos industriais do tipo caixa-branca, fazendo uso de técnicas baseadas em modelos integradas para a detecção de falhas, uma lógica de decisão com limiares fixos para classificar e identificar o componente danificado e para mitigação da falha usa-se do módulo controlador tolerante a falhas no qual usa a severidade da falha e seu sinal lógico para a reprogramação da lei de controle. A estratégia proposta é aplicada a uma planta de nível e temperatura.

A segunda estratégia destina-se a processos do tipo caixa-preta, recorrendo ao histórico do processo para o monitoramento dos eventos anormais. A detecção, identificação e reconstrução de falhas no processo são computadas pela Análise de Componentes Principais (*PCA- Principal Components Analysis*); a detecção é feita através das estatísticas τ^2 e Q ; a identificação é feita verificando a contribuição das variáveis do processo ao modelo PCA no instante da ocorrência da falha e a reconstrução é realizada fazendo a correção do vetor de amostras, usando o valor da amplitude da falha e a direção da falha. A abordagem proposta é aplicada a uma coluna fracionadora de óleo cru (Processo da *Shell*).

A terceira estratégia trata-se de um sistema de monitoramento de eventos anormais, do ponto de vista energético do processo (variáveis energéticas), ou seja, das informações sobre energia contidas nos sinais medidos. Para sua implementação é necessário fazer a assinatura energética do processo, computando os aportes energéticos, de entrada, saída e consumida pelo processo, a eficiência energética da unidade e ações de otimização da energia envolvida na unidade processual. Este sistema diagnose interage com o sistema de monitoramento estatístico (PCA) de modo a reduzir a ocorrência de falsos alarmes ou a perda do alarme pelo sistema de monitoramento da unidade, dando mais confiança ao operador do processo. Esta estratégia foi avaliada para uma torre de fracionamento atmosférica. Propõe-se também uma metodologia para projetar limiares operacionais adaptativos as mudanças operacionais.

Ao final do trabalho serão apresentadas as especificações técnicas de *software* de monitoramento de falhas e gestão de alarmes. O *software* irá reunir todas as estratégias desenvolvidas em um único produto. O *software* deverá ser integrado ao supervisório da planta, auxiliando na operação e na manutenção rotineira da planta, dando suporte ao operador e ao mesmo tempo minimizando paradas não programadas.

As principais contribuições do trabalho são: roteiro metodológico para caracterização de limiares adaptativos, roteiro metodológico para caracterização do modelo PCA inicial, PCA como ferramenta para avaliação de projetos de instrumentação, metodologia para assinatura energética de unidades processuais.

Palavras-chaves: Detecção de falhas, Isolação de falhas, Mitigação de falhas, Controle tolerante a falhas, Gestão de alarmes, Assinatura energética.

Abstract

This work presents solutions for detecting, diagnosing and mitigating of failures in industrial processes, the solutions were implemented in MATLAB-Simulink®.

The first solution is an approach for detection and identification of fault in industrial processes type white-box, making use of techniques based models integrated for anomaly detection, a decision logic with fixed thresholds to classify and identify damaged component and mitigation failure uses a module fault tolerant controller which the severity of the fault and its logical signal for reprogramming of the control law. The proposed approach is applied to a level and temperature plant.

The second strategy intended to processes type black box, using the process history for the monitoring of abnormal events. The detection, identification and reconstruction process failures are computed by Principal Component Analysis (PCA); the detection is done through τ^2 e Q statistics; the identification is made by checking the contribution of process variables in the model PCA at the time of occurrence of failure and the reconstruction is carried out by the correction vector of samples, using the magnitude value of the fault and the direction of the fault. The proposed approach is applied to Fractionator column crude oil (Shell Process).

The third strategy describes a system of monitoring of abnormal events considering the process energy (energy variables), in other words, the energy information contained in measured signals. Its implementation is need to the energy signature of the process, computing input, output and consume energy intake by the process, the energy efficiency of unit and actions to optimize energy involved in procedural unit. This system diagnose interact with statistical monitoring system (PCA) to reduce the occurrence of false alarm or loss alarm monitoring system of the unit, giving more reliability to operator of the process. This strategy was evaluated for an atmospheric fractionator tower. It also proposes a methodology designer adaptive thresholds operational changes, organized a strategic policy management alarms.

By the end of work will be presented the technical specifications of software fault monitoring and alarms management. The software will gather all the strategies developed in one product. The software should be integrated into the plant supervisory, assisting in operation and routine maintenance of the plant supporting the operator while minimizing unscheduled shutdowns.

The main contributions are: methodological plan thresholds for characterizing adaptive, plan methodology for characterizing the initial model PCA, PCA as a tool for project evaluation instrumentation, strategy for energy signature of process unit.

Keywords: Failure detection, Failure isolation, Failure mitigation, Failure tolerant control, Alarms management, Energy signature.

Sumário

Capítulo 1	01
1. Introdução.....	01
1.1 Motivação.....	01
1.2 Objetivos.....	02
1.2.1 Objetivos gerais.....	02
1.2.2 Objetivos específicos.....	02
1.3 Justificativas.....	03
1.4 Metodologia.....	04
1.5 Organização do trabalho.....	05
Capítulo 2	06
2. Prognóstico de falhas em sistemas industriais baseados em modelos.....	06
2.1 Introdução.....	06
2.2 Descrição do cenário de falhas.....	08
2.3 Técnicas analíticas para detecção de eventos anormais em sistemas industriais.....	09
2.3.1 Geração de resíduos via observadores de estado.....	10
2.3.2 Geração de resíduos via equação de paridade.....	11
2.3.3 Geração de resíduos via filtro de Kalman discreto.....	12
2.3.4 Geração de resíduos via identificação paramétrica.....	14
2.3.4.1 Representação de sistemas em tempo discreto.....	15
2.3.4.2 O modelo ARMAX e o método dos mínimos quadrados linear.....	16
2.4 Detecção e isolamento de falhas em sensores e atuadores.....	20
2.4.1 Diagnóstico de falhas baseado em limiares fixos.....	20
2.4.2 Detecção e isolamento de falhas via observadores dedicados (<i>Dedicated Observer Scheme-DOS</i>).....	21
2.4.3 Detecção e isolamento de falhas via observadores estruturados (<i>Structured Observer Scheme</i>).....	22
2.5 Conclusões preliminares.....	23
Capítulo 3	24
3. Monitoramento de falhas em processos do tipo caixa- branca.....	24
3.1 Metodologia de projeto de sistemas de detecção, diagnóstico e mitigação de falhas.....	24
3.2 Monitoramento de falhas em sistemas lineares em malha aberta.....	25
3.3 Monitoramento de eventos anormais em uma planta de nível e temperatura.....	26
3.3.1 A planta de nível e temperatura.....	27
3.3.2 Estratégia de controle para o tanque de pré-aquecimento.....	28
3.3.3 Diagnosticador de falhas aplicado ao tanque de pré-aquecimento.....	30
3.3.4 Projeto dos <i>thresholds</i> adaptativos.....	33
3.3.5 Controle tolerante a falhas.....	34
3.3.6 Conclusões preliminares.....	37

Capítulo 4	38
4. Monitoramento de falhas em sistemas industriais baseado no histórico do processo.....	38
4.1 Introdução.....	38
4.2 Teoria de análise de componentes principais (PCA).....	39
4.3 Uso de PCA para diagnóstico de falhas.....	40
4.3.1 PCA no monitoramento de processos multivariados.....	40
4.3.2 Limite superior de controle.....	43
4.3.3 Identificação da falha.....	44
4.3.4 Reconstrução da falha.....	44
4.3.5 Descrição do modelo de uma fracionadora de óleo cru.....	45
4.4 Teoria de controle preditivo.....	48
4.4.1 Controle preditivo aplicado à coluna fracionadora de óleo pesado.....	51
4.5 Projeto do PCA inicial para fracionadora da <i>Shell</i>	53
4.5.1 Projeto experimental da construção do modelo PCA.....	54
4.5.1.1 Sinal perturbador.....	54
4.5.1.2 Amplitude do sinal perturbador.....	58
4.5.1.3 Frequência do sinal perturbador.....	58
4.5.1.4 Mudanças operacionais.....	58
4.5.1.5 Janela de atualização.....	59
4.5.1.6 Taxa de amostragem.....	59
4.6 Análise PCA aplicada à coluna da <i>Shell</i>	61
4.7 Monitoramento de falhas na coluna fracionadora de óleo cru.....	64
Capítulo 5	72
5. Mapeamento energético de plantas industriais e prognóstico de falhas numa perspectiva energética.....	72
5.1 Introdução.....	72
5.2 Descrição do funcionamento da seção de fracionamento.....	72
5.3 Assinatura energética da fracionadora de óleo da <i>Shell</i>	74
5.3.1 Formulação matemática.....	74
5.3.2 Mapeamento energético da coluna fracionadora.....	77
5.4 Medidas de otimização energética.....	80
Capítulo 6	82
6. Especificações técnicas de <i>software</i> comercial e gestão de alarmes.....	82
6.1 Introdução.....	82
6.2 Especificações técnicas do <i>software</i> comercial.....	83
6.3 Gerenciamento eficiente de alarmes.....	92
Capítulo 7	94
7. Conclusões e sugestões para trabalhos futuros.....	94
Referências bibliográficas.....	96
Indicadores de fluxo acadêmico.....	99
Apêndices.....	100

Lista de Figuras

Figura 2.1 Módulo de diagnóstico de falhas em sistemas industriais baseado em modelos.....	07
Figura 2.2 Diagrama de blocos da geração da geração de resíduos.....	07
Figura 2.3 Gerador de resíduos generalizado.....	07
Figura 2.4 Observador de estados em malha fechada e geração de resíduos.....	11
Figura 2.5 Diagrama de blocos da geração de resíduos via filtro de Kalman discreto....	13
Figura 2.6 Esquema da problemática da identificação paramétrica.....	15
Figura 2.7 Representação esquemática do modelo ARX.....	17
Figura 2.8 Representação esquemática do modelo ARMAX.....	17
Figura 2.9 Procedimento interativo na estimação de parâmetros.....	19
Figura 2.10 Diagrama de blocos da geração de resíduos via estimação parâmetros.....	20
Figura 2.11 Estrutura da isolação de falhas com limiares fixos.....	20
Figura 3.1 Módulo de prognóstico de falhas em sistemas industriais.....	24
Figura 3.2 Esquemática da instrumentação e controle do tanque de pré-aquecimento de água.....	28
Figura 3.3 Diagrama de blocos do sistema do controle do tanque de pré- aquecimento de água.....	29
Figura 3.4 Controle de nível do tanque de pré-aquecimento.....	30
Figura 3.5 Controle de temperatura da corrente de saída.....	30
Figura 3.6 Falhas aplicadas ao tanque de pré-aquecimento.....	31
Figura 3.7 Saídas controladas na presença de falhas.....	32
Figura 3.8 Detecção e isolação de falhas pelo sistema de monitoramento.....	33
Figura 3.9 Fluxograma para geração da lei de controle tolerante a falhas.....	35
Figura 3.10 Resposta da malha de nível ao sistema tolerante para o cenário de defeito.....	36
Figura 3.11 Resposta da malha de temperatura ao sistema tolerante para o cenário de falhas.....	37
Figura 4.1 Monitoramento de falhas via PCA.....	42
Figura 4.2 Monitoramento de falhas via MBPCA.....	42
Figura 4.3 Modelo da coluna fracionadora de óleo cru.....	46
Figura 4.4 Estrutura básica de um controlador preditivo.....	48
Figura 4.5 Esquemática do horizonte móvel no controle preditivo.....	49

Figura 4.6 Esquema da sequência de predição ótima.....	50
Figura 4.7 Simulador da fracionadora e o respectivo sistema de controle.....	52
Figura 4.8 Controle da fracionadora de óleo pesado.....	53
Figura 4.9 Gráfico de dispersão das variáveis do sistema, sinal perturbador: onda quadrada.....	55
Figura 4.10 Função de correlação cruzada: entrada u_1 versus entrada u_2 ; entrada u_1 versus entrada u_3 ; entrada u_2 versus entrada u_3 , sinal perturbador: onda quadrada.....	55
Figura 4.11 Gráfico de dispersão das variáveis do sistema, sinal perturbador: senoidal.....	56
Figura 4.12 Função de correlação cruzada: entrada u_1 versus entrada u_2 ; entrada u_1 versus entrada u_3 ; entrada u_2 versus entrada u_3 , sinal perturbador: senoidal.....	56
Figura 4.13 Gráfico de dispersão das variáveis do sistema, sinal perturbador: dente de serra.....	57
Figura 4.14 Função de correlação cruzada: entrada u_1 versus entrada u_2 ; entrada u_1 versus entrada u_3 ; entrada u_2 versus entrada u_3 - sinal perturbador, dente de serra.....	57
Figura 4.15 Entradas da coluna perturbada para geração do modelo PCA.....	62
Figura 4.16 Saídas controladas da fracionadora na presença da perturbação para gerar o modelo PCA.....	62
Figura 4.17 Saídas monitoradas da fracionadora na presença da perturbação para gerar o modelo PCA.....	63
Figura 4.18 (a) Autovalor característico para cada componente principal, (b) Variância percentual dos componentes principais.....	63
Figura 4.19 Variância percentual acumulada.....	64
Figura 4.20 Estatísticas SPE e T^2 para o processo operando em condições normais.....	65
Figura 4.21 <i>Boxplot</i> para coluna fracionadora de óleo cru operando em condições normais.....	65
Figura 4.22 Estatísticas SPE e T^2 para o processo operando em condições de falha (falha no atuador 1, u_1).....	66
Figura 4.23 Entrada com falhas e saídas controladas (falha em u_1).....	66
Figura 4.24 Estatísticas SPE e T^2 para o processo operando em condições de falha (falha no sensor 1, y_1).....	67
Figura 4.25 (a) Estatísticas SPE e T^2 para o processo operando em condições de falha (falha no sensor 6, y_6), (b) Zoom do gráfico da Figura 3.31(a).....	68
Figura 4.26 Estatísticas SPE e T^2 para o processo operando em condições de falhas múltiplas: situação 1.....	69

Figura 4.27 Estatísticas SPE e T^2 para o processo operando em condições de falhas múltiplas: situação 2.....	69
Figura 4.28 Identificação de falhas na coluna <i>Shell</i> , falhas simultâneas.....	70
Figura 4.29 Identificação de falhas na coluna <i>Shell</i> , falhas não simultâneas.....	70
Figura 4.30 Testes de detecção de falhas após reconstrução dos sinais, falhas simultâneas.....	71
Figura 4.31 Testes de detecção de falhas após reconstrução dos sinais, falhas não simultâneas.....	71
Figura 5.1 Modelo de uma torre de fracionamento atmosférica.....	73
Figura 5.2 Fluxograma descritivo da geração da assinatura energética da torre de fracionamento atmosférica.....	78
Figura 5.3 Energia de entrada da fracionadora de óleo cru.....	79
Figura 5.4 Energia consumida ao longo da fracionadora de óleo cru.....	79
Figura 5.5 Comportamento da energia entregue pela torre atmosférica, na ocorrência de falhas simultâneas.....	79
Figura 5.6 Eficiência energética da torre de fracionamento atmosférica operando em condições anormais.....	80
Figura 6.1 Arquitetura geral do <i>software</i> de diagnose de falhas e gestão de alarmes.....	83
Figura 6.2 Processo de engenharia de <i>software</i>	84
Figura 6.3 Configuração do sistema de gestão de alarmes.....	92

Lista de Tabelas

Tabela 3.1: Parâmetros de sintonia do sistema de controle da planta de nível e temperatura.....	30
Tabela 3.2: Cenário de falhas- Tanque de pré-aquecimento.....	31
Tabela 3.3: Intervalo de tempo para detecção e isolamento de falhas.....	33
Tabela 4.1: Descrição das variáveis da coluna fracionadora.....	46
Tabela 4.2: Funções de transferências das entradas monitoradas.....	47
Tabela 4.3: Funções de transferências das entradas perturbadas por todas as saídas.....	47
Tabela 4.4: Incerteza do ganho de cada função de transferência.....	47
Tabela 4.5: Parâmetros de sintonia do controlador preditivo para coluna <i>Shell</i>	52
Tabela 4.6: Parâmetros para escolha da frequência do sinal perturbador, ponto de operação sendo zero.....	58
Tabela 4.7: Faixa de operação da fracionadora.....	59
Tabela 4.8: Autovalores do modelo PCA para diferentes pontos de operação da unidade.....	59
Tabela 4.9: Componentes principais para diferentes janelas de atualização do modelo PCA.....	60
Tabela 4.10: Autovalores do modelo PCA para diferentes taxas de amostragem.....	61
Tabela 4.11: Autovalores da matriz de dados do processo.....	61
Tabela 4.12: Autovetores da matriz de correlação de dados do processo.....	62
Tabela 4.13: Cenário de falhas 1- falhas simples.....	64
Tabela 4.14: Cenário de falhas 2- falhas múltiplas.....	65
Tabela 5.1: Alimentação da fracionadora atmosférica.....	77
Tabela 5.2: Produtos de saída da atmosférica.....	77
Tabela 5.3: Dados relevantes à simulação da assinatura energética da fracionadora de olé cru.....	78
Tabela 6.1: Descrição técnica do sistema de diagnose de falhas em processos industriais.....	86
Tabela 6.2: Especificações técnicas: Módulo - processo do tipo caixa-branca.....	88
Tabela 6.3: Especificações técnicas: Módulo - processo do tipo caixa-preta.....	89

Nomenclatura

Variável	Descrição	Unidade
h	Nível do tanque	m
T_3	Temperatura do fluido de saída do tanque	$^{\circ}C$
T_2	Temperatura da corrente de água quente	$^{\circ}C$
T_1	Temperatura da corrente de água fria	$^{\circ}C$
W_3	Vazão do fluido de saída do tanque	l/s
W_2	Vazão de entrada de água quente	l/s
W_1	Vazão de entrada de água fria	l/s
L.T.	Transmissor de Nível	m
L.C.	Controle de Nível	-
T.C.	Controle de Temperatura	-
T.T	Transmissor de Temperatura	$^{\circ}C$
F.T	Transmissor de Fluxo	l/s

Lista de abreviaturas

ARMAX- Auto Regressive Moving Average with Exogenous Inputs
ARX- Auto Regressive with Exogenous Inputs
CLP- Controlador Lógico Programável
CUSUM- Cumulative Sum Control Chart (Carta de Controle das Somas Cumulativas)
DOS- Dedicated Observer Scheme
FTC- Fault Tolerant Control
GLP- Gás Liquefeito de Petróleo
HCO- Heavy Cycle Oil
ICA- Independent Components Analysis
IHM- Interface Human Machine
LCO- Light Cycle Oil
LSC- Limite Superior de Controle
MATLAB- MATrix LABoratory
MBPCA- Model Based Principal Component Analysis
MIMO- Multiple Input Multiple Output
MLP- Neural network Multi-Layer Perceptron
MPC- Model Predictive Control
ODE- Ordinary Differential Equation
OPC- Object for Process Control
PC- Principal Component
PCA- Principal Components Analysis
PCorrA- Partial Correlation Analysis
P&G&B- Setor de Petróleo, Gás e Biocombustíveis
PID- Controlador Proporcional, Integral e Derivativo
PLS- Partial Least Squares
PRBS- Pseudo Random Binary Signal
RS- Residual Space
SCADA- Supervisory Control and Data Acquisition
SISO- Single Input Single Output
SOS- Structured Observer Scheme
SPE- Squares Predictor Error
UI- User Interface

Capítulo 1

Introdução

1.1 Motivação

Plantas industriais são plantas altamente automatizadas, com vários componentes que interagem de forma complexa para o correto funcionamento da unidade. Neste cenário a falha de um componente pode levar a interrupção parcial da planta ou até mesmo total, degradando a qualidade do produto final, gerando prejuízos ou até mesmo acidentes ambientais ou pessoais. Devido a estas questões, restrições de segurança, ambientais e econômicas, a detecção, o diagnóstico e mitigação de falhas tornou-se um assunto de importância para qualquer indústria de processos. O diagnóstico precoce da falha pode reduzir a perda de produtividade e uma interrupção da unidade pode ser evitada. Um eficiente sistema de monitoramento de defeitos além de oferecer suporte ao operador no tocante à segurança, um procedimento de gestão eficiente de alarmes, como também a capacidade de informar o estado de energia do processo, monitorando não apenas os sinais medidos, mas também a energia transportada por estes sinais (Alexandre, Lima & Neto, 2013).

A procura por sistemas de monitoramento automático de defeitos pode ser explicada pelo fato de os processos industriais serem altamente instrumentados, tendo a disposição uma grande quantidade de dados disponíveis para utilização na monitoração. Estes dados ficam armazenados em computadores robustos, sob a forma de históricos do processo, e são necessários para análise da operação. Neste sentido pode-se utilizar ferramentas de detecção e diagnóstico baseadas na análise destes históricos, eliminando a necessidade de se utilizar modelagem do processo. Dentre estas ferramentas, pode-se citar as estatísticas multivariadas que serão abordadas nesta monografia.

A estatística multivariada trata-se da Análise de Componentes Principais utilizada para análise de correlação existente nas variáveis do processo. O objetivo principal de sua utilização nesta monografia foi a necessidade de se usar uma ferramenta com capacidade de identificação e classificação não somente do evento “falha”, como também do tipo da falha ocorrida.

O objetivo principal das ferramentas de detecção e diagnóstico é auxiliar na operação da planta. Sua utilização é necessária para coletar, analisar e interpretar os dados do processo disponíveis, de forma a realizar detecção e diagnóstico precoces das falhas e reduzir as paradas e condições de emergência na planta causadas pelas mesmas.

Nesta pesquisa foram desenvolvidos sistemas de prognósticos de falhas, ambos recorrendo ao método quantitativo. De forma geral dois módulos diagnosticadores: um no qual utiliza de técnicas analíticas baseadas no modelo do processo para geração de resíduos, lógica de decisão com limiares fixos na isolação da falha e a estimativa da falha e o sinal lógico da isolação da falha para a mitigação da falha, sendo aplicado a um modelo de um tanque de pré-aquecimento de água; o outro diagnosticador recorre ao histórico do processo, utilizando de cartas de controle estatístico para detecção de

anormalidades, a contribuição das variáveis do processos no instante da ocorrência da falha para isolamento do instrumento defeituoso e a estimativa da falha junto com o vetor direção de falha para a mitigação do evento anormal. Esta estratégia foi avaliada em uma fracionadora de óleo pesado.

Considerando que fracionadoras de óleo são unidades de suma importância no refino do petróleo, foi desenvolvida uma metodologia para realização da assinatura energética de processos industriais, em específico para estas unidades, computando os gastos energéticos, os aportes energéticos de entrada da unidade, os aportes energéticos de saída, a eficiência energética da unidade, bem como definições de medidas que conduzam a efficientização energética da unidade processual. Neste contexto foi proposto um diagnosticador de falhas numa perspectiva energética, no qual usa das variáveis energéticas para o monitoramento da unidade, auxiliando o operador no momento da ocorrência da falha.

Com base nas características expostas, nas necessidades operacionais e importâncias econômicas e ambientais, os processos de instrumentação e controle industrial poderão se beneficiar com a implementação de ferramentas de detecção e diagnóstico de falhas.

1.2 Objetivos

1.2.1 Objetivos Gerais

Neste Trabalho de Conclusão de Curso tem-se como objetivo geral o desenvolvimento de ferramentas que permitam o monitoramento de falhas em sensores e atuadores, de forma a auxiliar o operador na melhor condução da unidade processual.

Desenvolver roteiro metodológico para assinatura energética de unidades processuais, computando aportes energéticos, eficiência energética da unidade e definindo ações de otimização da energia envolvida na unidade.

Apresentar as especificações técnicas do software de monitoramento de falhas e gestão de alarmes, o software irá reunir todas as estratégias desenvolvidas em um único produto.

1.2.2 Objetivos Específicos

Como objetivos específicos destacam-se:

1. Estudo e simulação numérica de técnicas analíticas para geração de resíduos de variáveis em sistemas operando em malha aberta;
2. Estudo e simulação numérica de técnicas analíticas para detecção e isolamento de falhas em sensores e atuadores em sistemas operando em malha aberta;
3. Implementação de estratégia de detecção e isolamento de falhas com limiares fixos para uma planta de nível e temperatura operando em malha fechada;
4. Implementação de controle tolerante a falhas, reconfigurando automaticamente a lei de controle;

5. Desenvolver um roteiro metodológico para obtenção de limiares adaptativos em sistemas de prognósticos de falhas de sistemas industriais;
6. Utilizar a técnica PCA para desenvolvimento de relações entre as variáveis de um processo;
7. Avaliar o desempenho da técnica PCA no monitoramento e na detecção de falhas em processos industriais complexos (multivariáveis);
8. Desenvolver um roteiro metodológico para gerar o modelo PCA padrão, visto que os trabalhos da literatura tratam da aplicação específica do modelo PCA sem a metodologia de projeto que seria adotada nos testes experimentais tampouco enfatizam o uso da técnica PCA como alternativa para avaliação de projetos de sistemas de instrumentação em termos da quantidade de sensores/atuadores;
9. Realizar a assinatura energética de uma fracionadora atmosférica de óleo pesado;
10. Desenvolver e implementar um diagnosticador do ponto de vista da energia envolvida na fracionadora;
11. Estudo e modelagem de cenários de falhas para a fracionadora de óleo pesado.
12. Especificar a arquitetura do software de monitoramento de eventos anormais em sistemas industriais.
13. Proposta de sistema de gestão de alarmes em plantas industriais.
14. Roteiro metodológico para geração de limiares adaptativos as variações operacionais do processo;
15. Contribuir ao desenvolvimento de sistemas de gerenciamento de situações anormais em processos industriais.

Todas estas etapas poderão não seguir obrigatoriamente esta sequência, mas interagem harmoniosamente para o projeto e implementação do sistema automático de monitoramento falhas em sensores/atuadores e gestão eficiente de alarmes em sistemas industriais. As etapas de 1 a 5 faz referência ao desenvolvimento do sistema de monitoramento de falhas em processos com modelo conhecido, as etapas de 6 a 8 se faz necessárias para a diagnose de processos do tipo caixa-preta, as etapas não citadas envolve o produto em desenvolvimento com a energia envolvida no processo e com o supervisor.

1.3 Justificativas

De modo geral um sistema de controle industrial é constituído de múltiplas malhas de controle de processos e de equipamentos (instrumentação) que compõem a planta industrial. No caso do setor de Petróleo, Gás natural e Biocombustíveis (P&G&B) há estudos conclusivos demonstrando que o ajuste da sintonia dos controladores associados ao ajuste do ponto de operação da planta resulta em ganhos econômicos consideráveis e melhoria da estabilidade, bem como garantir a redução do consumo de energia e da emissão de substâncias tóxicas (Alexandre, Lima & Neto, 2011). Todavia, estudos relacionados com o consumo energético da unidade processual como um todo são poucos relatados. Deste modo, desenvolver soluções para otimizar o uso de energia

em sistemas de controle industriais, e na instrumentação utilizada, traz benefícios tangíveis para as indústrias de modo geral.

A detecção, isolamento e mitigação precoce da falha podem ajudar a evitar paradas inesperadas, acidentes e diminuir o tempo de *start-up* (tempo necessário para colocar a planta em operação, após uma parada) do processo. Deste modo, desenvolver sistemas de monitoramento automático de falhas, traz ganhos econômicos, sociais e ambientais contribuindo para a chamada manutenção preventiva inteligente da planta industrial.

1.4 Metodologia

A metodologia a ser utilizada para consecução dos objetivos deste projeto consiste das seguintes etapas:

- a) **Revisão da literatura:** Estudar as técnicas de detecção e isolamento de falhas em processos industriais; Estudo das técnicas de diagnóstico e mitigação de falhas em plantas industriais; Compreender as técnicas existentes de controle tolerante a falhas (abordagem ativa e passiva); Estudo das técnicas de otimização energética que podem ser utilizadas em processos industriais.
- b) **Avaliação das estratégias propostas na literatura:** Escolha do (s) processo (s) a ser trabalhado; Simulação numérica das técnicas encontradas na literatura; Escolha da melhor maneira de como interagir com as técnicas de detecção, diagnóstico e mitigação de falhas para projeto de um sistema de monitoramento eficiente e robusto; Validação do modelo desenvolvido.
- c) **Sistemas de monitoramento de falhas em unidades processuais:** Desenvolvimento de um sistema de monitoramento de defeitos baseado em modelo para uma planta de nível e temperatura; Desenvolvimento de um sistema eficiente de monitoramento de falhas em sensores e atuadores avaliado em uma torre de fracionamento de óleo pesado;
- d) **Roteiro metodológico:** Elaboração e aplicação de roteiro metodológico para assinatura energética em unidades processuais; Metodologia para geração do PCA padrão.
- e) **Gerenciamento eficiente de alarmes:** Implementação e comparação das lógicas de decisão propostas para gerenciamento eficiente de alarmes.
- f) **Controle tolerante:** Desenvolvimento de técnicas de controle tolerante para unidades processuais.
- g) **Especificações Técnicas de software:** Desenvolvimento de um cenário virtual para comunicação do módulo de monitoramento de defeitos ao supervisor da planta; Detalhar a arquitetura (definir todos os blocos, configurações, interface gráfica e o modo como interagem entre si) necessária para confecção de um *software*.
- h) **Indicadores de fluxo acadêmico:** Elaboração de relatório e publicações técnico-científicas; Elaboração de documentos para divulgação em congressos de Engenharia Elétrica; Participação em visitas técnicas, seminários, congressos e palestras.

Essas atividades são interativas e a cada novo conhecimento adicionado há uma realimentação que permite reavaliar os resultados anteriores.

1.6 Organização do Trabalho

Este trabalho encontra-se dividido em seis capítulos, organizado da seguinte forma:

Capítulo 1 – Neste capítulo encontram-se a caracterização da problemática de diagnosticar falhas em sistemas industriais, os objetivos e a estrutura do trabalho.

Capítulo 2 – São apresentadas as técnicas para geração de resíduos para processos com modelo conhecido, técnicas de detecção e isolamento de falhas.

Capítulo 3 – Avaliação das técnicas apresentadas no Capítulo 2 por meio de simulações de processos em malha aberta, proposta e avaliação de uma estratégia de monitoramento de falhas nos componentes de uma planta de nível e temperatura operando em malha fechada.

Capítulo 4 – É apresentado o modelo de um processo linear de uma coluna fracionadora de óleo pesado, o seu controle e os resultados obtidos pela aplicação da técnica PCA no monitoramento de eventos anormais neste processo. Bem como um roteiro técnico para gerar o PCA inicial.

Capítulo 5 – É apresentada a estratégia para assinatura energética da fracionadora de óleo, a eficiência energética e medidas de otimização energética da unidade (Processo da *Shell*).

Capítulo 6 – Apresenta-se as especificações técnicas do *software* de diagnose de falhas e gestão de alarmes, agregando todas as estratégias desenvolvidas ao longo do Trabalho em um único produto.

Capítulo 7 – São expostas as conclusões sobre os resultados obtidos no presente trabalho, além de propostas de trabalhos futuros.

Por fim apresentam-se as referências bibliográficas utilizadas.

O texto está organizado de forma que o leitor entenda cada técnica usada no monitoramento de falhas e gestão de alarmes, e que o produto final será um Software, que uni as estratégias estudadas, desenvolvidas e implementadas para cada tipo de processo.

Capítulo 2

Prognóstico de falhas em sistemas industriais baseado em modelos

2.1 Introdução

Sistemas de controle automático estão se tornando mais e mais complexos e os algoritmos de controle mais e mais sofisticados. Consequentemente, há uma crescente demanda por tolerância a falhas que pode ser alcançada, não apenas com a melhoria da confiabilidade das unidades funcionais, mas também por um sistema automático de detecção, acomodação e isolamento de falhas eficiente, integrado ao supervisor da planta, dando segurança, confiabilidade e suporte ao operador da unidade produtiva.

Neste contexto, a falha é entendida como qualquer tipo de desvio (mau funcionamento) na dinâmica atual do sistema. Em outras palavras um defeito na planta que leve à parada total ou parcial do processo. Tal falha pode ocorrer tanto nos sensores, ou atuadores, ou nos componentes do processo.

A pesquisa básica sobre diagnóstico de falhas em sistemas de instrumentação industrial vem ganhando consideração em todo o mundo, em especial na indústria de processos e petroquímica. A justificativa para tal fato advém de uma automação cada vez mais complexa, a crescente demanda por maior disponibilidade e segurança dos sistemas de controle e as restrições ambientais e econômicas impostas às unidades operacionais, auxiliado pelas técnicas avançadas de computação e de controle moderno.

Dentre as técnicas discutidas e implementadas por pesquisadores de várias instituições de pesquisa, vale ressaltar as técnicas baseadas em redundância analítica como uma metodologia para detecção e diagnósticos de falhas. É baseado no uso da redundância analítica (isto é, funcional), em vez da redundância física. O que implica que a redundância inerente contidas nas relações estáticas e dinâmicas entre as entradas e saídas do sistema medido é explorada para o diagnóstico de falhas. Em outras palavras, faz uso de um modelo matemático do sistema ou de partes dele.

Logicamente, quanto não é possível obter o modelo matemático da planta de teste, é necessário recorrer a técnicas baseadas no conhecimento do processo. Para muitos estudiosos da área uma arquitetura combinada por técnicas baseadas em conhecimento com técnicas analíticas, resultará num sistema de detecção e diagnóstico de falhas robusto e eficiente.

A tarefa de diagnosticar consiste em duas etapas (Chow & Willksy, 1984):

1. A detecção do mau funcionamento;
2. O isolamento do componente defeituoso (a localização de qual componente está defeituoso- sensor; atuador ou componentes do processo).

Enquanto as duas etapas podem ser executadas sequencialmente, na maioria dos algoritmos de diagnóstico de falhas a tarefa de detecção está implícita na tarefa de isolamento.

O módulo de diagnóstico de falhas em sensores e atuadores utilizando redundância analítica consiste em dois blocos, os quais programam as tarefas descritas anteriormente. Este modelo está apresentado na Figura 2.1.

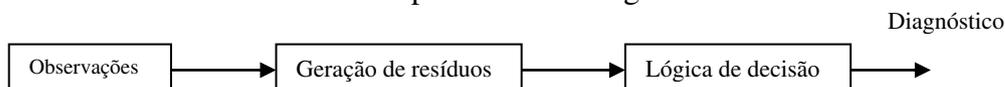


Figura 2.1- Módulo de diagnóstico de falhas em sistemas industriais baseado em modelos.

Em todas as técnicas de diagnósticos, a geração de resíduos está presente, estes são importantes, pois “medem” o desvio ocorrido no processo, ou seja, eles contêm informações sobre as falhas ocorridas no processo, sendo assim, resíduos são quantidades que representam a inconsistência entre as variáveis da planta real com as variáveis do modelo matemático, conforme apresentado na Figura 2.2. Eles são calculados a partir da planta "observável" e são idealmente zero.

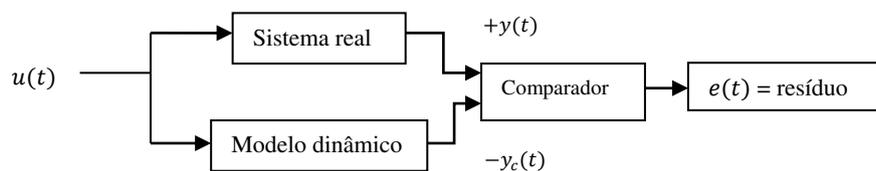


Figura 2.2 – Diagrama de blocos da geração de resíduos.

Do diagrama de blocos da Figura 2.2, $u(t)$, representa o sinal proveniente dos atuadores que alimentam a entrada da planta; $y(t)$, é o (s) sinal (ais) de saída da planta proveniente das medições realizadas pelos sensores; $y_c(t)$, representa o sinal de saída do modelo matemático que representa o comportamento da planta; $e(t)$, é resíduo, obtido fazendo a diferença entre o sinal de saída real da planta e o sinal de saída do modelo da planta ($e(t) = y(t) - y_c(t)$). O resíduo é utilizado para sinalizar a ocorrência de falha no processo, o bloco denominado por modelo dinâmico para sua consecução é necessário o uso de técnicas analíticas de modelagem de processos. Na Figura 2.3 é ilustrada a forma computacional do gerador de resíduos.

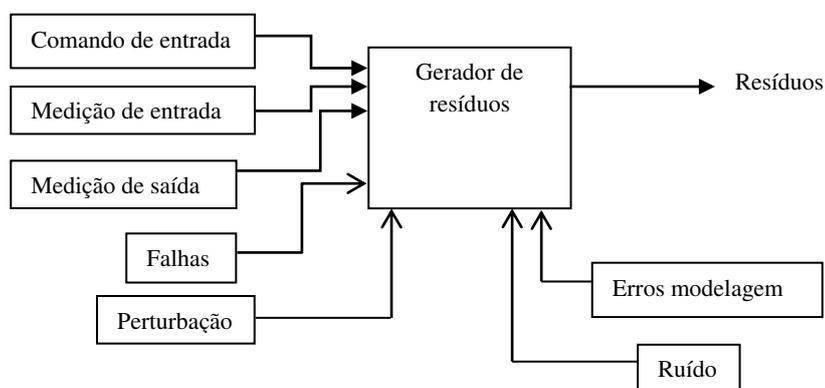


Figura 2.3 - Gerador de resíduos generalizado

Para sistemas estáticos, o gerador residual também é estático. Ele é simplesmente uma forma rearranjada de um modelo de entrada-saída, por exemplo, um conjunto de relações geométricas ou de equações de balanço de materiais. Para um sistema dinâmico, o gerador residual é dinâmico podendo ser construído por uma série de técnicas diferentes (Kinnaert, 2003). Neste trabalho são abordadas as técnicas analíticas, para detecção de falhas em sensores e atuadores, listadas a seguir:

1. Equações de paridade ou relações de consistência, obtido pela conservação direta do modelo de entrada-saída ou espaço de estado do sistema, desvio das equações do processo (Chow & Willksy, 1984; Gertler, 1991).
2. Geração de resíduos via observadores de estado;
3. Geração de resíduos via identificação paramétrica;
4. Geração de resíduos via filtro de Kalman discreto (Observador de Kalman).

Enquanto um único resíduo é suficiente para detectar falhas, um conjunto de resíduos é necessário para o isolamento de falhas, daí a ideia de resíduos estruturados, como uma matriz de resíduos e a ideia de resíduos direcionais, ou seja, um conjunto de vetores residuais em um espaço de direções. Para facilitar o isolamento, conjuntos de resíduos são geralmente organizados, em uma das seguintes formas:

- Em resposta a uma única falha, apenas um subconjunto específico de falha dos resíduos tornam-se não zero (resíduos estruturados);
- Em resposta a uma única falha, o vetor residual está confinado a uma direção específica (resíduos de direção fixa).

Finalmente, a função do bloco de tomada de decisões nos algoritmos de diagnóstico é analisar os resíduos, a fim de chegar a uma decisão de diagnóstico (a decisão e isolamento da falha). A implementação exata depende da natureza dos resíduos, sempre que a presença de ruído aleatório, a avaliação dos resíduos envolvem testes estatísticos. Os resíduos são analisados em termos da probabilidade de uma falha, e uma tomada de decisão lógica é aplicada tendo em vista decidir se a falha realmente ocorreu, evitando decisões erradas, tais como falso alarme e falha não detectada (Kinnaert, 2003). O processo de decisão pode consistir de uma simples decisão binária utilizando um limiar fixo ou adaptativo para uma função de avaliação de resíduos, ou pode consistir em métodos de decisão estatísticos como o teste da razão de probabilidade generalizada, o teste da razão de probabilidade sequencial, o teste qui-quadrado (χ^2) e o teste de somas cumulativas, ou ela também pode ser tratada com o auxílio da lógica *fuzzy* ou redes neurais.

2.2 Descrição do cenário de falhas

O elemento principal no desenvolvimento de um sistema de detecção e diagnóstico de falhas baseado em modelo é a construção de um modelo matemático do processo a ser monitorado. Considere que em condições normais (isento de falha), o processo pode ser representado pelo seguinte modelo em espaço de estado discreto no tempo,

$$\begin{aligned}x(k+1) &= Ax(k) + Bu(k) \\y(k) &= Cx(k) + Du(k),\end{aligned}\tag{2.1}$$

onde $x \in \mathfrak{R}^{n \times 1}$ é o vetor de estado, $u \in \mathfrak{R}^{m \times 1}$ é o vetor de entrada, e $y \in \mathfrak{R}^{l \times 1}$ é o vetor de saída. $A \in \mathfrak{R}^{n \times n}$ é a matriz do sistema, $B \in \mathfrak{R}^{n \times m}$ é a matriz de entrada, $C \in \mathfrak{R}^{l \times n}$ é a matriz de saída e $D \in \mathfrak{R}^{l \times m}$ é a matriz de transformação direta entrada- saída.

Embora as incertezas (distúrbios, ruídos e erros de modelagem) e as falhas (aditiva ou multiplicativa) têm efeitos diferentes sobre o desempenho do sistema, a fim de facilitar a aplicação dos conceitos do diagnosticador robusto, elas são representadas por entradas desconhecidas adicionadas ao modelo do processo. O sistema representado pela equação (2.1), na presença de falhas em sensores, atuadores e nos componentes do processo pode ser representado de acordo com Sotomayor e Odloak, 2005; Teixeira, 2007 e Yoneyama, 2009, como,

$$\begin{aligned}x(k+1) &= (A + \Delta A)x(k) + Bu(k) + Gw(k) + Ha(k) \\y(k) &= Cx(k) + Du(k) + v(k) + Ms(k),\end{aligned}\tag{2.2}$$

onde ΔA representa uma falha interna (falha no processo), $w(k)$ é o ruído de estado, $a(k)$ representa a falha no atuador, $v(k)$ é o ruído de medição e $s(k)$ representa a falha nos sensores. Os termos G, H, M são vetores que irão dar as devidas dimensões aos ruídos como também as falhas do sistema.

O cenário de falhas em tempo contínuo é descrito pela equação (2.3),

$$\begin{aligned}\frac{dx}{dt} &= (A + \Delta A)x(t) + Bu(t) + Gw(t) + Ha(t) \\y(t) &= Cx(t) + Du(t) + v(t) + Ms(t).\end{aligned}\tag{2.3}$$

Nas próximas seções serão discutidas as técnicas utilizadas para simular/emular o modelo de falhas descrito pelas equações (2.2) e (2.3).

2.3 Técnicas analíticas para detecção de eventos anormais em processos industriais

Nesta seção é apresentada a formulação matemática e a estrutura em diagrama de blocos de cada técnica utilizada para modelagem dinâmica do processo real (bloco denominado de *modelo dinâmico*, da Figura 2.2), bem como a maneira computacional para a implementação do bloco denominado por *comparador*, o qual computa a geração do resíduo entre a saída real anormal e a saída do modelo analítico sem falhas. A presença do ruído é o suficiente para caracterizar a ocorrência da falha. Na seção 2.4 será apresentada as estruturas DOS, baseada nas saídas estimadas e nas saídas medidas, a estrutura DOS baseada nos estados estimados e a estrutura SOS, usadas para computar as etapas de detecção e isolamento de falhas. Vale lembrar que haverá falha sempre que o resíduo gerado por qualquer uma das técnicas geradoras for superior ao seu limiar fixo correspondente para cada sensor.

No Capítulo 3 é apresentada uma proposta de estratégia de monitoramento de falhas em sensores e atuadores na qual usa de maneira combinada as técnicas geradoras de resíduos apresentadas nesta seção para obter uma matriz de resíduos que é avaliado por um classificador lógico para sinalizar a ocorrência da falha e sua localização. Daí a importância de testes individuais com cada uma das técnicas, para avaliar a sua sensibilidade a desvios na entrada e/ou desvios na saída da planta.

2.3.1 Geração de resíduos via observadores de estado

No estimador de estados apresentado no diagrama de blocos da Figura 2.4, é possível ajustar o valor estimado dos estados em função do erro entre o sinal de saída do processo e o sinal de saída estimado. É considerado então, um estimador de estados em malha fechada, cujas equações descritas a seguir podem ser encontradas em Ogata (2001). Da Figura 2.4,

$$\frac{dx_c}{dt} = Ax_c(t) + Bu(t) + L(y(t) - Cx_c(t)). \quad (2.4)$$

A equação (2.4) pode ser reescrita conforme equação (2.5),

$$\dot{x}_c(t) = (A - LC)x_c(t) + Bu(t) + Ly(t). \quad (2.5)$$

Definindo o erro de estimação como,

$$e_x(t) = x(t) - x_c(t). \quad (2.6)$$

Escrevendo a derivada do erro, tem-se,

$$\dot{e}_x(t) = \dot{x}(t) - \dot{x}_c(t) = Ax(t) + Bu(t) - (A - LC)x_c(t) - Ly(t) - Bu(t). \quad (2.7)$$

Considerando que $y(t) = Cx(t)$, pode-se reescrever a equação (2.8), como,

$$\dot{e}_x(t) = (A - LC)e(t), \quad (2.8)$$

portanto, se os autovalores de $(A - LC)$ tiverem parte real negativa, o erro em regime permanente tende para zero. Logo o estado estimado convergirá para o valor do estado verdadeiro, qualquer que seja o valor do sinal de entrada $u(t)$. Os autovalores de $(A - LC)$ podem ser arbitrariamente atribuídos, por escolha de L , se o processo representado pelas matrizes A , B e C for uma representação completamente observável. Normalmente a dinâmica do observador deve ser mais rápida do que os polos prescritos para o sistema compensado. Em geral é imposto a dinâmica do observador, ser 4 a 5 vezes mais rápido do que a do sistema em malha fechada, ou seja, dos polos especificados pelo projeto de alocação de polos.

Conforme esquema apresentado na Figura 2.4, o resíduo corresponde ao erro de estimação, neste caso o erro definido pela equação (2.6). Para o estudo de falhas o erro da técnica do observador de estado passa a ser dado pela expressão (2.9), como pode ser observado na Figura 2.4:

$$e(t) = y(t) - y_c(t) \quad (2.9)$$

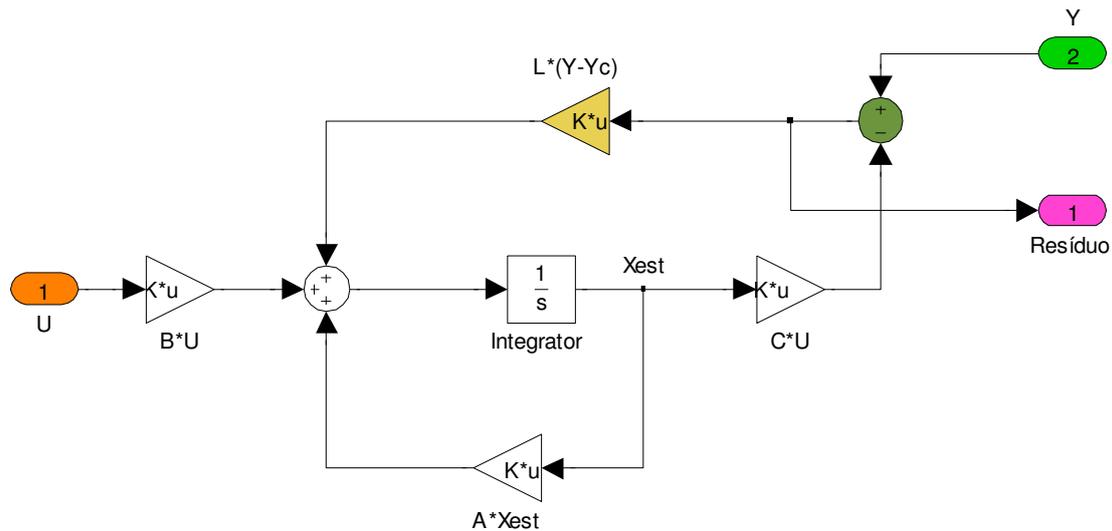


Figura 2.4 – Observador de estados em malha fechada e geração de resíduos.

2.3.2 Geração de resíduos via equações de paridade

A formulação matemática da problemática da relação de paridade foi apresentada por Chow & Willsky (1984), Kinnaert (2003) e Gertler (1991). Considere o modelo em espaço de estado (equação (2.1)), onde obtemos por sucessivas substituições a coleção de equações descritas por (2.10).

$$\begin{aligned}
 y(k) &= Cx(k) + Du(k) \\
 y(k+1) &= Cx(k+1) + Du(k+1) = CAx(k) + CBu(k) + Du(k+1) \\
 y(k+2) &= Cx(k+2) + Du(k+2) = CA^2x(k) + CABu(k) + CBu(k+1) + Du(k+2) \\
 &\vdots \\
 &\vdots \\
 y(k+i) &= CA^i x(k) + CA^{i-1}Bu(k) + \dots + CBu(k+i-1) + Du(k+i)
 \end{aligned} \tag{2.10}$$

Reescrevendo estas equações na forma matricial, obtemos a configuração da expressão (2.11).

$$\begin{bmatrix} y(k) \\ y(k+1) \\ y(k+2) \\ \vdots \\ y(k+i) \end{bmatrix} = \begin{bmatrix} C \\ CA \\ CA^2 \\ \vdots \\ CA^{i-1} \end{bmatrix} x(k) + \begin{bmatrix} D & 0 & \dots & 0 \\ CB & D & \dots & 0 \\ CAB & CB & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ CA^{i-1}B & CA^{i-2}B & \dots & D \end{bmatrix} \begin{bmatrix} u(k) \\ u(k+1) \\ u(k+2) \\ \vdots \\ u(k+i) \end{bmatrix} \tag{2.11}$$

$$Y = Tx(k) + QU$$

Para um sistema com k entradas e m saídas, o vetor y é de dimensão $(i+1) \times k$. A dimensão da matriz T é $[(i+1) \times m] \times n$ onde n é o número de equações homogêneas, enquanto que a matriz Q é $[(i+1) \times m] \times [(i+1) \times k]$.

Multiplicando cada lado da equação (2.11) por um vetor linha W de dimensão $(i+1) \times k$, resulta em uma equação escalar,

$$Wy(k) = WTx(k) + WQu(k). \tag{2.12}$$

Em geral, estas equações contém um conjunto de entradas, saídas e variáveis de estado, e elas tornam-se equações de paridade se as variáveis de estado são eliminadas. Assumindo que as amostras de $u(k)$ e $y(k)$ podem ser obtidas por medições, e somente o vetor de estado $x(k)$ é desconhecido, a seguinte condição é forçada,

$$WT = 0, \quad (2.13)$$

e a equação (2.12), pode ser escrita como,

$$Wy(k) - WQu(k) = 0. \quad (2.14)$$

A equação (2.14) é uma relação de redundância analítica, ou seja, é uma relação que envolve apenas variáveis conhecidas e as derivadas conhecidas. Logo o resíduo pode ser definido como,

$$r(k) = W(y(k) - Qu(k)). \quad (2.15)$$

Na presença de falhas este resíduo é modificado visto que as condições de operação da planta são modificadas, a equação correspondente a (2.11) na presença de falhas é modificada para,

$$Y(k) = Tx(k) + QU(k) + QF(k), \quad (2.16)$$

onde Q é uma matriz triangular inferior com primeira coluna $[D^T (CB)^T \dots (CA^{(i-1)}B)^T]^T$ e F é o vetor de falhas e suas derivadas são de ordem i . Substituindo (2.16) para $y(k)$ em (2.15), resulta,

$$r(k) = WQF(k). \quad (2.17)$$

A função $r(k)$ é um indicador da presença da falha. As expressões (2.15), (2.16) e (2.17) definem a função de paridade ou de verificação de paridade, $r(k) = f(y(k), u(k))$, ou seja, é uma função da entrada e saída do processo. Suas derivadas são zero na ausência de falhas e são diferentes de zero na presença de uma falha.

2.3.3 Geração de resíduos via filtro de Kalman discreto

Uma forma de observação de estados que pode ser utilizada para sistemas com ruído é através do filtro de Kalman discreto, sendo este um conjunto de equações matemáticas, que implementam um estimador do tipo preditor-corretivo, ótimo no sentido que minimiza o erro de covariância estimado, quando encontra algumas condições presumidas, como as variáveis aleatórias com distribuição Gaussiana. O filtro de Kalman tem sido extensivamente pesquisado e aplicado, principalmente devido a sua simplicidade e natureza robusta; ainda que raramente haja as condições ótimas necessárias, o filtro funciona bem para muitas situações.

O filtro de Kalman pode ser visto como um conjunto de equações matemáticas que provêm uma maneira eficiente de se estimar os estados de um processo, de maneira que minimize o erro médio quadrado (Welch & Bishop, 2006). O algoritmo é muito poderoso em vários aspectos:

- Suporta estimação de estados passados, presentes e até mesmo futuros;

- Funciona mesmo quando a natureza precisa do sistema modelado é desconhecida.

A geração de resíduos via filtro de Kalman, dar-se conforme a Figura 2.5 onde o filtro é utilizado para dar o estado estimado, bem como a saída estimada, vista que esta é uma função do vetor de estados. Na Figura 2.6, $\Delta u(k)$, representa falha nos atuadores + ruído de estado, $\Delta y(k)$ representa falha nos sensores + ruído de medição.

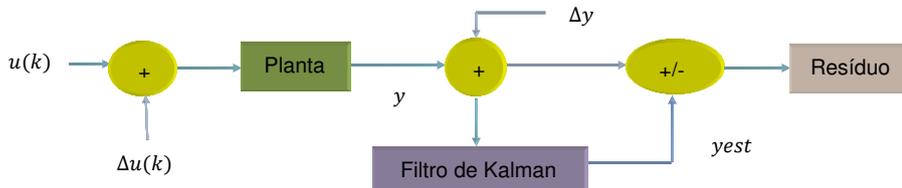


Figura 2.5 – Diagrama de blocos da geração de resíduos via filtro de Kalman.

Um sistema linear estocástico é simplesmente um processo que pode ser descrito pelas equações (2.18) e (2.19):

Equação de estado:

$$x(k+1) = Ax(k) + Bu(k) + w(k) \quad (2.18)$$

Equação de saída:

$$y(k) = Cx(k) + Du(k) + z(k) \quad (2.19)$$

Nas equações (2.18) e (2.19), A , B , C e D são matrizes, k é o índice de tempo discreto, x é chamado estado do sistema, y é a medição de saída e w e z são ruído de estado e ruído de medição, respectivamente. Cada um desses termos pode ser um escalar ou um vetor; o vetor x contém todas as informações sobre o estado atual do sistema, mas não podemos medir x diretamente. Em vez disso, medido y , que é uma função de x que está corrompido pelo ruído de medição ($z(k)$), podemos usar y para nos ajudar a obter uma estimativa de x , mas não podemos necessariamente levar a informação de y no seu valor nominal, visto que está corrompido por ruído.

O filtro de Kalman discreto consiste de três equações, cada uma envolvendo manipulações de matrizes (Haykin, 2001; Welch & Bishop, 2006), dadas por (2.20),

$$\begin{aligned} K(k) &= AP(k)C^T (CP(k)C^T + S(z))^{-1} \\ x_c(k+1) &= (Ax_c(k) + Bu(k) + K(k)(y(k+1) - Cx_c(k))) \\ P(k+1) &= AP(k)A^T + S(w) - AP(k)C^T S(z)^{-1} CP(k)A^T \end{aligned} \quad (2.20)$$

na equação (2.20), o subscrito -1 indica a inversão da matriz e o subscrito T indica transposição da matriz, K é a matriz de ganho do filtro de Kalman e a matriz P é chamada de matriz de estimativa de covariância de erro.

A equação de estimativa do estado ($x(k)$) é bastante intuitiva. O primeiro termo é usado para derivar a estimativa de estado no tempo $k+1$ é igual à matriz A vezes o estado no tempo atual, $x_c(k)$, mais a matriz B vezes a entrada conhecida no tempo atual. Esta seria a estimativa de estado se não houvesse uma medição posterior, em outras palavras, a estimativa de estado iria propagar no tempo, assim como o vetor de

estado no modelo do sistema. O segundo termo da equação de x_c é chamado de termo de correção de estimativa e que representa a quantidade necessária para corrigir a estimativa de estado propagada, devido à medição seguinte.

Por inspeção a equação do cálculo do ganho do filtro, K , mostra que, se o ruído de medição (z) é grande, $S(z)$ será grande, visto que a variância do ruído será grande e o sinal medido está muito corrompido por ruído, assim K será pequeno e não vamos dar muita credibilidade à medição de y no cálculo do próximo x_c . Por outro lado, se a medição apresentar um ruído de medição pequeno, $S(z)$ será pequeno, pois a variância de ruído é pequena e o sinal medido apresenta baixo ruído, logo K será grande e nós vamos dar muita credibilidade à medição ao calcular o próximo valor de x_c .

Vale lembrar que, no modelo do sistema linear estocástico, w é o ruído de estado (processo) e z é o ruído de medição, ambas variáveis aleatórias, temos que assumir que o valor médio de w e z é zero, visto que a média das amostras obtidas do processo real está bem próxima de zero; temos que ainda supor que a correlação não existe entre w e z , ou seja, em qualquer tempo k , $w(k)$ e $z(k)$ são variáveis aleatórias independentes, pois podem ser descritas por funções de probabilidade gaussiana. Sendo assim podem-se definir as matrizes de covariância de ruído $S(z)$ e $S(w)$, como:

Covariância do ruído de processo (estado):

$$S(w) = E(w(k) w(k)^T) \quad (2.21)$$

Covariância do ruído de medição (estado):

$$S(z) = E(z(k) z(k)^T) \quad (2.22)$$

onde w^T e z^T indicam a transposta dos vetores aleatórios de ruído e $E(.)$ significa o valor esperado.

O diagrama de blocos da Figura 2.5, foi implementado em ambiente Simulink-MATLAB[®], para o filtro de Kalman discreto, foi utilizado um bloco já disponibilizado no ambiente computacional chamado de *Kalman Filter do Toolbox Signal Processing*.

2.3.4 Geração de resíduos via identificação paramétrica.

Segundo Aguirre (2004), identificação de sistemas é um procedimento alternativo que se propõe a obter um modelo matemático que explique a relação causa e efeito presente nos dados. Tenta-se responder à pergunta: Que modelo há que, ao ser excitado pela entrada $u(k)$, resulta na saída $y(k)$?

As principais etapas de um problema de identificação são:

1. Testes dinâmicos e coleta de dados;
2. Escolha da representação da estrutura matemática a ser utilizada;
3. Determinação da estrutura do modelo;
4. Estimação dos parâmetros;
5. Validação do modelo.

O esquema do problema de identificação de sistemas é ilustrado na Figura 2.6.

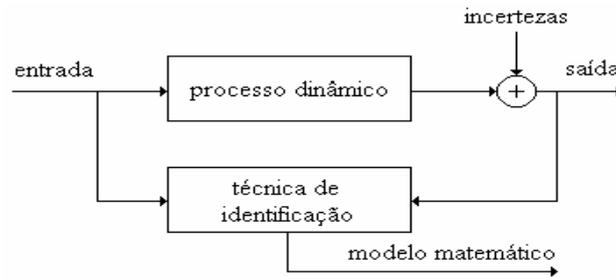


Figura 2.6 - Esquema da problemática de identificação paramétrica.

Fonte: Aguirre (2004); Yoneyama (2009).

2.3.4.1 Representação de sistemas em tempo discreto

Existem algumas representações matemáticas que são especialmente adequadas à identificação de sistemas através do uso de algoritmos estimadores de parâmetros. Nesta seção apresentaremos algumas dessas representações matemáticas, conforme descritas por Ljung (1999) e Aguirre (2004).

Considerando o seguinte modelo geral:

$$A(q)y(k) = \frac{B(q)}{F(q)}u(k) + \frac{C(q)}{D(q)}v(k)$$

$$y(k) = \frac{B(q)}{A(q)F(q)}u(k) + \frac{C(q)}{A(k)D(q)}v(k)$$

$$y(k) = G(q)u(k) + V(q)v(k)$$

(2.23)

Onde $A(q)$, $B(q)$, $C(q)$, $D(q)$ e $F(q)$ são polinômios definidos como:

$$A(q) = 1 - a_1q^{-1} - \dots - a_{ny}q^{-ny}$$

$$B(q) = b_1q^{-1} - \dots - b_{nu}q^{-nu}$$

$$C(q) = 1 - c_1q^{-1} - \dots - c_{nv}q^{-nv}$$

$$D(q) = 1 - d_1q^{-1} - \dots - d_{nd}q^{-nd}$$

$$F(q) = 1 - f_1q^{-1} - \dots - f_{nf}q^{-nf}$$
(2.24)

Sendo q^{-1} o operador de atraso, de forma que $y(k)q^{-1} = y(k-1)$ e $v(k)$ é o ruído branco. As funções $G(q)$ e $V(q)$ são referidas como funções de transferências do processo e do ruído, respectivamente.

MODELO ARX

O modelo auto-regressivo com entradas exógenas (ARX, do Inglês *Autoregressive with Exogenous Inputs*), pode ser obtido a partir do modelo geral (2.23), assumindo que $C(q) = D(q) = F(q) = 1$, sendo $A(q)$ e $B(q)$ polinômios arbitrários, o que resulta em:

$$A(q)y(k) = B(q)u(k) + v(k) \quad (2.25)$$

Que pode ser reescrita como segue:

$$y(k) = \frac{B(q)}{A(q)}u(k) + \frac{1}{A(q)}v(k) \quad (2.26)$$

Que coloca em evidência as funções de transferências do sistema $H(k) = \frac{B(q)}{A(q)}$ e de ruído $\frac{1}{A(q)}$, como pode ser visto na Figura 2.7.

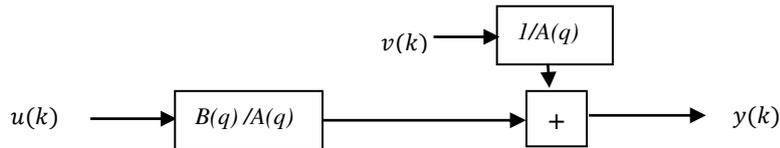


Figura 2.7 - Representação esquemática do modelo ARX.

MODELO ARMAX

O modelo auto-regressivo com média móvel e entradas exógenas (ARMAX, do Inglês *Auto Regressive Moving Average with Exogenous Inputs*), também pode ser obtido a partir do modelo geral (2.23), fazendo $D(q) = F(q) = 1$, sendo $A(q)$, $B(q)$ e $C(q)$ polinômios arbitrários, o que resulta em:

$$A(q)y(k) = B(q)u(k) + C(q)v(k) \quad (2.27)$$

ou

$$y(k) = \frac{B(q)}{A(q)}u(k) + \frac{C(q)}{A(q)}v(k); \quad (2.28)$$

$$y(k) = H(q)u(k) + e(k)$$

sendo $e(k)$ um ruído não branco como ilustrado na Figura 2.8.

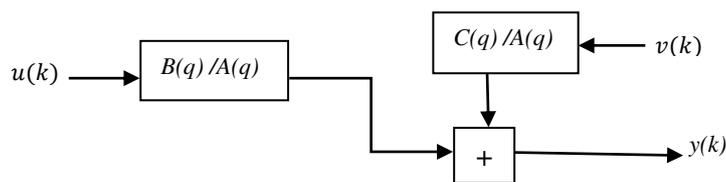


Figura 2.8 - Representação esquemática do modelo ARMAX.

Nesse caso, o erro é modelado como um processo de média móvel (MA) e o ruído adicionado à saída, $e(k)$, é modelado como ruído branco filtrado por $C(q)/A(q)$ (um filtro ARMA).

2.3.4.2 O modelo ARX e o método dos mínimos quadrados linear

O modelo:

Considere um sistema de entrada $u(k)$ e saída $y(k)$, dado pela equação linear de diferenças (2.29),

$$y(k) + a_1 y(k-1) + \dots + a_n y(k-n) = b_1 u(k-1) + \dots + b_m u(k-m) + e(k) \quad (2.29)$$

onde todas as amostras de entrada e saída são conhecidas. A amostragem é feita desta forma, $T, 2T, 3T \dots NT$ onde T é o período de amostragem, no caso do período de amostragem unitário, $T = 1, 1, 2, 3 \dots N$, onde N é o número de amostras.

Reescrevendo (2.29), isolando $y(k)$, temos,

$$y(k) = -a_1 y(k-1) - \dots - a_n y(k-n) + b_1 u(k-1) + \dots + b_m u(k-m) + e(k) \quad (2.30)$$

A expressão (2.30) pode ser escrita de forma compacta, introduzindo os vetores:

$$\theta = \begin{bmatrix} a_1 & \dots & a_n & b_1 & \dots & b_m \end{bmatrix}^T \quad (2.31)$$

$$\phi(k) = \begin{bmatrix} -y(k-1) & \dots & -y(k-n) & u(k-1) & \dots & u(k-m) \end{bmatrix}^T \quad (2.32)$$

Com base nas equações (2.31) e (2.32), podemos escrever (2.33), denominado de modelo de regressão linear.

$$y(k) = \phi^T(k)\theta + e(k) \quad (2.33)$$

onde θ é o vetor de parâmetros desconhecido (vetor estimado), de dimensão $(n+m) \times 1$, $\phi(k)$ é o vetor de medição entrada/saída do sistema (conhecido) e o sinal $e(k)$ representa o erro de modelagem, erro de medição ou ruído na saída do tipo estocástico, determinístico ou *off-set*. Sabendo o valor do vetor de parâmetros θ , teremos a saída estimada pelo identificador, necessária para geração de resíduos da problemática de falhas. Tal saída é dada como:

$$y_c(k|\theta) = \phi^T(k)\theta \quad (2.34)$$

Método dos mínimos quadrados não recursivo:

Suponha que, para um determinado sistema, não se sabe os valores dos parâmetros do modelo matemático do processo (vetor de parâmetros θ), mas tem-se as medições de entrada e saída durante um intervalo de tempo $1 \leq k \leq N$, N é número de amostras. Pode-se definir o conjunto de dados:

$$Z^N = \{u(1), y(1), \dots, u(N), y(N)\} \quad (2.35)$$

Uma abordagem é comparar a saída estimada a partir do vetor θ com a saída medida, gerando um erro de previsão, de modo que este seja mínimo. Para tal deve-se recorrer ao método dos mínimos quadrados, para fazer a estimativa de θ , conforme a expressão (2.36),

$$\min_{\theta} V_N(\theta, Z^N) \quad (2.36)$$

onde

$$V_N(\theta, Z^N) = \frac{1}{N} \sum_{k=1}^N (y(k) - y_c(k|\theta))^2 = \frac{1}{N} \sum_{k=1}^N (y(k) - \phi^T(k)\theta)^2 \quad (2.37)$$

logo o $\theta(N)$ estimado deve ser:

$$\theta(N) = \arg \min_{\theta} V_N(\theta, Z^N) \quad (2.38)$$

(“arg min” significa o argumento que minimiza θ dado V_N). Uma vez que V_N é quadrático em θ , pode-se determinar o valor mínimo fazendo a derivada primeira igual à zero.

$$0 = \frac{\partial V_N(\theta, Z^N)}{\partial \theta} = \frac{2}{N} \sum_{k=1}^N \phi(k)(y(k) - \phi^T(k)\theta) \quad (2.39)$$

logo:

$$\frac{1}{N} \sum_{k=1}^N \phi(k)y(k) = \frac{1}{N} \sum_{k=1}^N \phi(k)\phi(k)^T \theta \quad (2.40)$$

ou

$$\theta(N) = \left[\sum_{k=1}^N \phi(k)\phi(k)^T \right]^{-1} \sum_{k=1}^N \phi(k)^T y(k) \quad (2.41)$$

A equação (2.41) permite o cálculo da estimativa do vetor θ , pelo método dos mínimos quadrados não recursivo.

A representação matricial da expressão (2.30), admitindo N medições realizadas e suficientes para determinar os parâmetros $a_i, i = 1, \dots, n$ e $b_j, j = 1, \dots, m$, é dado como:

$$\begin{bmatrix} y_n \\ y_{n+1} \\ y_{n+2} \\ \cdot \\ \cdot \\ y_N \end{bmatrix} = \begin{bmatrix} -y_{n-1} \cdots & -y_0 & u_{n-1} \cdots & u_{n-m} \\ -y_n \cdots & y_1 & u_n \cdots & u_{n-m+1} \\ -y_{n+1} \cdots & y_2 & u_{n+1} \cdots & u_{n-m+2} \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ -y_{N-1} \cdots & -y_{N-n} & u_{N-1} \cdots & u_{N-m} \end{bmatrix} \begin{bmatrix} a_1 \\ \cdot \\ a_n \\ b_1 \\ \cdot \\ b_m \end{bmatrix} + \begin{bmatrix} e_n \\ e_{n+1} \\ e_{n+2} \\ \cdot \\ \cdot \\ e_N \end{bmatrix} \quad (2.42)$$

$$Y = \Phi \theta + E$$

Uma vez que o cálculo do vetor θ é dado por:

$$\theta = [\Phi \Phi^T]^{-1} \Phi^T Y \quad (2.43)$$

A equação (2.43) é o estimador não recursivo de parâmetros.

Método dos mínimos quadrados recursivo:

Muitas vezes o processo de inversão de matrizes pode ser complicado e a necessidade de se utilizar os dados sequencialmente para atualizar o vetor de parâmetros de um determinado modelo, torna-se vital para algumas aplicações. Na implementação de controle adaptativo em tempo real o algoritmo do estimador de parâmetros deve ser iterativo, onde o modelo do sistema é atualizado a cada período de amostragem quando

novas medidas estão disponíveis. Daí surge à necessidade do estimador recursivo, cujo procedimento pode ser ilustrado pela Figura 2.9.

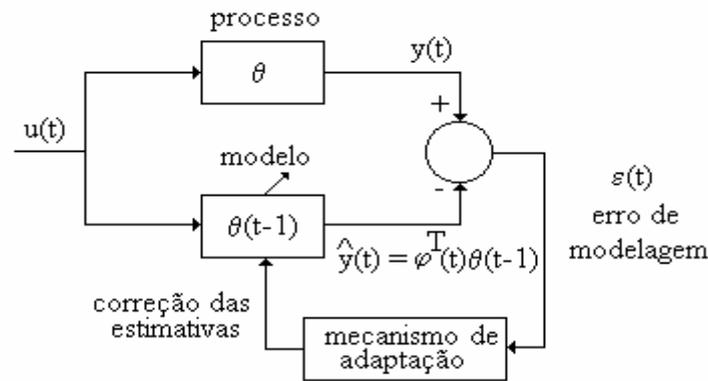


Figura 2.9 - Procedimento iterativo na estimação de parâmetros.

Fonte: Aguirre (2004).

O algoritmo do estimador de mínimos quadrados recursivo pode ser descrito pelos seguintes passos:

- i. Medir a saída e entrada do sistema;
- ii. Atualizar o vetor de medidas, com base na equação (2.44);

$$\phi^T(k+1) = [-y(k) \quad -y(k-1) \dots \quad u(k-d) \dots \quad u(k-d-1)] \quad (2.44)$$

onde d é um atraso.

- iii. Calcular o erro de previsão (estimação) usando a equação (2.45);

$$\varepsilon(k+1) = y(k+1) - \phi^T(k+1)\theta_c(k) \quad (2.45)$$

- iv. Calcular o ganho do estimador conforme equação (2.46);

$$K(k+1) = \frac{P(k)\phi(k+1)}{1 + \phi^T(k+1)P(k)\phi(k+1)} \quad (2.46)$$

onde $P(k)$ é a matriz de covariância, que deve ser inicializada corretamente e calculada no passo (vi).

- v. Calcular o vetor de parâmetros estimados utilizando a equação (2.47);

$$\theta_c(k+1) = \theta_c(k) + K(k)\varepsilon(k+1) \quad (2.47)$$

- vi. Calcular a matriz de covariância com base na equação (2.48).

$$P(k+1) = P(k)[1 - K(k+1)\phi^T(k+1)] \quad (2.48)$$

Lembrando que a dimensão de $P(k)$ é de $(n+m) \times (n+m)$ e deve ser inicializado como, $P=AI_{(n+m) \times (n+m)} = 100eye((n+m), (n+m))$, A grande, (sendo este último o comando no MATLAB); o vetor θ também deve ser inicializado. A geração de resíduos utilizando identificação paramétrica é alcançada conforme diagrama de blocos da Figura 2.10.

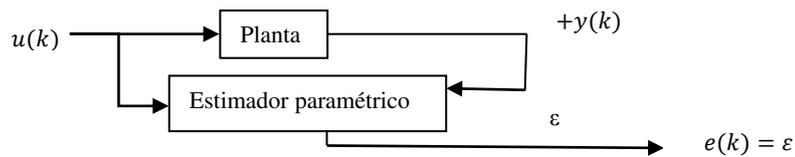


Figura 2.10 – Diagrama de blocos da geração de resíduos via estimação de parâmetros.

Do diagrama de blocos da Figura 2.10, $u(k)$ é o sinal de entrada da planta, $y(k)$ é o sinal de saída medido pelos sensores e ε é o erro de estimação, para a problemática de falhas corresponde ao resíduo.

2.4 Detecção e isolamento de falhas em sensores e atuadores

Depois dos resíduos gerados, segue-se a sua avaliação para que se possa distinguir uma falha em particular. Pode-se estabelecer um conjunto estruturado de resíduos que são sensíveis para uma falha específica e insensíveis para outras (Gertler, 1988). Outra maneira é projetar um vetor residual direcional, que fixa uma direção que corresponde a uma falha particular no espaço residual.

Nesta seção apresentaremos a lógica de decisão do diagnóstico de falhas. Será apresentado o esquema dos observadores dedicados (*DOS- Dedicated Observer Scheme*), baseada em funções de decisão e o diagnóstico de falhas baseado em banco de resíduos estruturados com limiares fixos.

2.4.1 Diagnóstico de falhas baseado em limiares fixos

A ideia principal desta técnica na isolamento da falha é usar um banco de resíduos, ou seja, um conjunto de resíduos provenientes de várias técnicas de geração de resíduos organizados em uma matriz de resíduos. Cada um dos resíduos é sensível a uma falha específica e insensível as outras falhas possíveis (Figura 2.11) (Neto, 2006). A tarefa da isolamento de falha pode ser alcançada através da comparação de cada resíduo com um limiar e uma resultante tabela de decisão booleana. A lógica da isolamento da falha pode ser expressa como:

$$\begin{aligned} r_i(k) > T_i &\Rightarrow f_i(k) \neq 0; i = 1, 2, \dots, q. \\ r_i(k) \leq T_i &\Rightarrow f_i(k) = 0; \end{aligned} \quad (2.49)$$

onde T_i é um limiar, q é o número de saídas dos observadores. Se $f_i(k) \neq 0$, significa que houve falha (nível alto, “0”), se $f_i(k) = 0$, significa que não houve falha (nível lógico baixo, “1”).

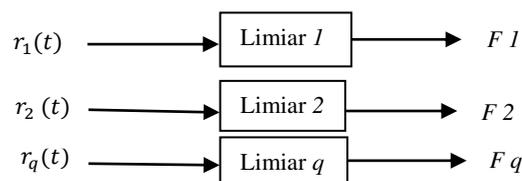


Figura 2.11 – Estrutura da isolamento de falhas com limiares fixos.

Este esquema é conveniente somente para uma falha sensível ao estimador. Todavia não é um esquema robusto para sinais desconhecidos, tais como distúrbios (Neto, 2006).

Vale observar neste caso que a adoção de um limiar T_i pequeno aumenta a indicação de alarme falso. Quando T_i possui um valor maior, o sistema pode falhar na detecção de falha. Isto é, a falha está ocorrendo e não se consegue detectá-la, no outro caso ele indica a existência de uma falha quando na realidade é um ruído.

2.4.2 Detecção e isolamento de falhas via observadores dedicados (*DOS- Dedicated Observer Scheme*)

Nesta configuração há a necessidade de uma assinatura da falha de cada sensor, por meio de um sinal de decisão, funções não lineares, sua avaliação é utilizada para sinalizar a ocorrência de falha e ao mesmo tempo a localização do defeito, visto que haverá uma função de decisão para cada sensor. Tais funções são denominadas de funções de decisão dos sensores. O projeto das funções de decisão apresentadas em Oliva (1998) é baseado na técnica de Patton (1989) para uma estrutura DOS. Elas são funções não lineares compostas pelo produto do módulo de resíduos, onde cada resíduo é o erro entre a medida fornecida por um sensor e o seu respectivo valor estimado por um dos observadores controlado por outro sensor. Estas funções de decisão são dadas por (no caso considerado em que há três saídas do sistema):

$$\left. \begin{array}{l} f_{y_2|y_1} = \|y_2 - (y_2|y_1)\| \\ f_{y_3|y_1} = \|y_3 - (y_3|y_1)\| \end{array} \right\} \eta_{y_1} = f_{y_2|y_1} * f_{y_3|y_1}; \quad (2.50)$$

$$\left. \begin{array}{l} f_{y_1|y_2} = \|y_1 - (y_1|y_2)\| \\ f_{y_3|y_2} = \|y_3 - (y_3|y_2)\| \end{array} \right\} \eta_{y_2} = f_{y_1|y_2} * f_{y_3|y_2}; \quad (2.51)$$

$$\left. \begin{array}{l} f_{y_1|y_3} = \|y_1 - (y_1|y_3)\| \\ f_{y_2|y_3} = \|y_2 - (y_2|y_3)\| \end{array} \right\} \eta_{y_3} = f_{y_1|y_3} * f_{y_2|y_3}; \quad (2.52)$$

onde, η_{y_i} , representa a função de decisão para o sensor, $y_i, i = 1,2,3$ e $\|\cdot\|$ é a métrica/norma euclidiana.

Para a estrutura DOS, de acordo com Patton (1989), é necessário ter um observador para cada sensor do sistema. Para identificar qual é o sensor que controla o observador que gera os sinais estimados, é utilizada a identificação '|'. Sendo assim, temos os seguintes sinais estimados:

$y_i|y_j$ é o valor estimado da saída y_j obtida a partir das medidas fornecidas pelo sensor y_i .

Utilizando as funções de decisão dadas pelas Equações (2.50), (2.51) e (2.52), é possível construir uma lógica de decisão. Fazendo uma análise qualitativa, se, por

exemplo, o sensor correspondente à saída y_3 falhar, as funções $f_{y_1|y_3}$ e $f_{y_2|y_3}$ crescerão rapidamente e η_{y_3} crescerá ainda mais rapidamente. Já para as outras funções de decisão somente as funções $f_{y_3|y_1}$ e $f_{y_3|y_2}$ crescerão, enquanto que $f_{y_2|y_1}$ e $f_{y_1|y_2}$ permanecerão com valores bem pequenos, resultando que η_{y_1} e η_{y_2} terão valores bem menores do que o de η_{y_3} . Este fato permite identificar que o sensor correspondente à saída y_3 falhou. É então necessário encontrar qual é o valor apropriado para o limiar de decisão para cada função de decisão para identificar o sensor que falhou. Deve ser levado em consideração que este valor deve ser tal que minimize a taxa de falso alarme e a de perda de alarme (Neto, 2006).

Podemos utilizar os estados estimados para obter uma lógica de decisão semelhante (função de decisão modificada) à descrita anteriormente, conforme equação (2.53).

$$\begin{aligned}\varphi_{1,2}(k) &= \|x_{i,1}(k) - x_{i,2}(k)\| \\ \varphi_{1,3}(k) &= \|x_{i,1}(k) - x_{i,3}(k)\| \\ \varphi_{2,3}(k) &= \|x_{i,2}(k) - x_{i,3}(k)\|\end{aligned}\tag{2.53}$$

onde $x_{i,1}$, $x_{i,2}$ e $x_{i,3}$ representam a estimativa do i -ésimo estado x_i por cada um dos observadores, no caso de três observadores; $\varphi_{i,j}$ representa o resíduo entre o vetor de estado estimado pelo observador i com o vetor de estado estimado pelo observador j . As funções de decisão são dadas como:

$$\begin{aligned}\eta_1(k) &= \varphi_{1,2}(k) \cdot \varphi_{1,3}(k) \\ \eta_2(k) &= \varphi_{1,2}(k) \cdot \varphi_{2,3}(k) \\ \eta_3(k) &= \varphi_{1,3}(k) \cdot \varphi_{2,3}(k)\end{aligned}\tag{2.54}$$

Ocorrerá falha no sensor correspondente a saída 1, quando a função η_1 crescer, η_2 for aproximadamente zero e η_3 for aproximadamente zero. Haverá falha na saída correspondente a saída 2 se η_2 crescer, η_1 e η_3 forem aproximadamente zero, de maneira análoga temos para a saída 3.

Vale ressaltar que a lógica baseada nos estados estimados (2.53) e (2.54) só é válida para o caso em que a matriz de saída for igual à matriz identidade ($C = I$).

2.4.3 Detecção de falhas e isolamento via observadores estruturados (SOS- *Structured Observer Scheme*)

Esta lógica de decisão foi proposta por Patton (1999), e apresentada em Teixeira (2007). As funções de decisão são projetadas para gerar um padrão de assinatura de falhas, o qual pode auxiliar na detecção e identificação de falhas no sensor. De acordo com os estudos feitos em Teixeira, Souza e Oliva (2005), verificou-se que o desempenho para detecção e identificação de falhas pode ser aumentado quando se trabalha com um vetor de funções de decisão, sendo que cada uma delas é dada pelo

módulo do resíduo entre a medida fornecida pelo sensor e o respectivo valor redundante fornecido por um dos observadores. A função decisão assim descrita é dada por:

$$\eta_{i,j} = \|r_{ij}\| = \|y_i - (y_j | y_i)\| \begin{cases} i = 1, \dots, p \\ j = 1, \dots, p \end{cases} \quad (2.55)$$

onde $\eta_{i,j}$ é o i -ésimo elemento do vetor da função de decisão para o sensor j ; $r_{i,j}$ é o i -ésimo elemento do vetor de resíduos entre a medida i , e o respectivo valor estimado/redundante dado pelo observador j ; $(y_j | y_i)$ é o valor redundante da medida j fornecido pelo observador controlado por i ; p é o número de sensores do processo e y_i é a medida fornecida pelo sensor j .

Uma falha pode ser declarada quando todos os elementos $i \neq j$ de um vetor de funções de decisão tiverem um valor superior ao do limiar de decisão pré-determinado. Deste modo, é possível detectar e identificar até $p-2$ falhas múltiplas simultâneas.

2.5 Conclusões preliminares

No capítulo 2 apresentou-se a formulação matemática e a estrutura em diagramas de blocos das técnicas geradoras de resíduos baseada em modelos. No capítulo 3 cada técnica será avaliada individualmente, visando avaliar a sensibilidade de cada uma a desvios na entrada e na saída, para identificar qual das técnicas é melhor para detectar falhas em sensores e quais detectam melhor falhas em atuadores em malha aberta e em malha fechada. Visto que se propõe uma estratégia na qual combina todas as técnicas apresentadas. Tal estratégia é avaliada a uma planta de nível e temperatura operando em malha fechada.

Capítulo 3

Monitoramento de falhas em processos do tipo caixa-branca

3.1 Metodologia de projeto de sistemas de detecção, diagnóstico e mitigação de falhas

Para detalhar a metodologia proposta, na Figura 3.1 ilustra-se o arranjo do sistema de monitoramento. Continuamente o sistema em operação inter atua com o módulo controlador e suas variáveis são medidas (entrada e saída) e organizadas pelo sistema de aquisição de dados. O sistema de aquisição processa os dados na forma de uma matriz de dados que são enviados ao módulo de diagnose de falhas. A assinatura de anormalidade é caracterizada observando os resíduos gerados pelas técnicas clássicas de controle. As etapas da *detecção* e do *diagnóstico* são alcançadas utilizando *lógica de decisão com limiares fixos*, que avalia o banco de resíduos gerado e indica a ocorrência de defeito e onde aconteceu o defeito. Já a etapa da mitigação é computada executando o algoritmo recursivo para reprogramação da lei de controle, tomando como entradas o sinal lógico de ocorrência de falha ($S(k)$) e a estimativa da magnitude da falha ($f(k)$), ambos fornecidos pelas etapas de *detecção* e *diagnóstico*.

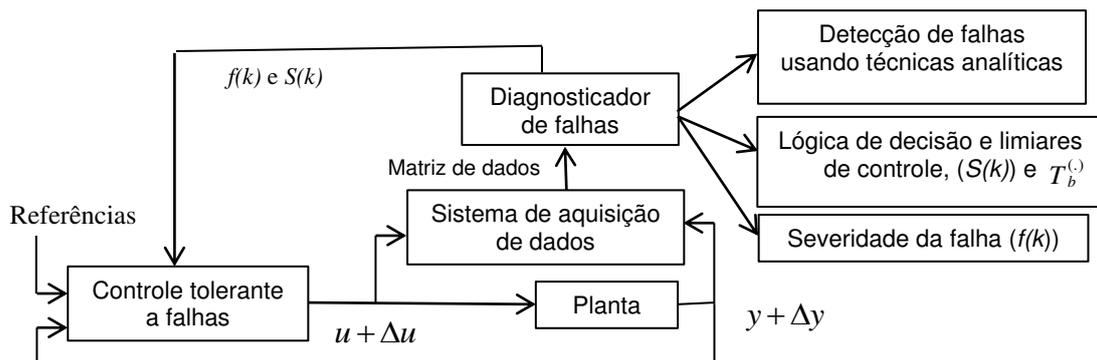


Figura 3.1 - Módulo de prognóstico de falhas em sistemas industriais.

Vale ressaltar que o *controle tolerante* é alcançado pelo algoritmo da reprogramação da lei de controle, $f(k)$, é a estimativa da severidade da falha (magnitude), $S(k)$, é o sinal lógico da ocorrência de falha (nível alto “1”, houve falha ou nível baixo “0”, não houve falha) proveniente do diagnosticador de falhas, $u(k)$, é o sinal de entrada da planta provenientes das leituras dos atuadores, $y(k)$, é o sinal de saída da planta, proveniente dos sensores, $\Delta u(k)$, corresponde a falhas aditivas ocorridas nas leituras dos atuadores e $\Delta y(k)$, corresponde a falhas aditivas ocorridas nos sensores presentes na instrumentação da planta.

A metodologia usada na simulação do sistema de monitoramento de falhas em sensores e atuadores em unidades processuais consiste na sequência de passos:

1. Escolha do processo a ser monitorado;
2. Construção do módulo gerador de falhas;
3. Estudo e implementação da estratégia de controle;

4. Modelar cada componente do sistema, atuadores, sensores e controladores;
5. Implementação das técnicas geradoras de resíduos;
6. Implementação da lógica de decisão para classificar o banco de resíduos;
7. Realimentação dos sinais lógicos gerados pela lógica de decisão;
8. Estimativa da magnitude da falha;
9. Desenvolvimento do algoritmo recursivo da reprogramação da lei controle;

A simulação foi realizada em *software* de simulação matemática, ambiente MATLAB-Simulink[®], versão 7.6 (versão 2008), com o objetivo de validar a metodologia proposta, foram realizadas simulações de processos em malha aberta e de uma planta de nível e temperatura operando em malha fechada.

3.2 Monitoramento de falhas em sistemas lineares em malha aberta

As simulações em malha aberta objetivam identificar as características de cada técnica quanto à sensibilidade a desvios de entrada e saída da planta, e tendo como intuito de obter um sistema de monitoramento em malha fechada híbrido no qual use as técnicas de maneira combinadas e ótima, cada qual atuando na sua especialidade, gerando um banco de resíduos hierárquicos que serão classificados pelo classificador com limiares fixos. Vale destacar que na literatura encontra-se casos de geração de resíduos de maneira individual, mas não de forma combinada como proposto neste trabalho.

Antes de apresentarmos as discussões dos resultados das técnicas analíticas aplicadas em processos operando em malha aberta, ressalta-se a importância de algumas definições com respeito aos tipos de falhas e a sua representação matemática (sinais usuais). As falhas em um processo industrial podem ser classificadas em relação a vários aspectos, dentre eles estão o tempo e a localização. Em se tratando de tempo, as falhas podem ser abruptas, incipientes ou intermitentes.

- a) Falhas abruptas: são aquelas que surgem repentinamente, podendo ser decorrentes de imprevistos ou até mesmo de acidentes. Essas falhas mudam o comportamento do processo rapidamente, exigindo contra ações velozes e eficazes que possam minimizar as consequências do ocorrido. Podem ser modeladas por uma função degrau. Podem ser falhas aditivas ou multiplicativas.
- b) Falhas incipientes: são falhas iniciadas a partir de pequenos desvios do comportamento normal do sistema. Elas podem ser mascaradas pelos controladores, e muitas vezes passam despercebidas pelos operadores ou até mesmo pelos sistemas de monitoramento de falhas. Podem ser modeladas por funções rampas, visto que pode-se variar a inclinação da rampa de modo a emular o comportamento análogo da falha incipiente.
- c) Falhas intermitentes: são aquelas que se alternam no tempo. Podem ser causadas por alguma perturbação periódica, ou por alguma situação que se repita ciclicamente, caracterizando um cenário de falha. Podem ser modeladas por um sinal senoidal ou um sinal PRBS (*Pseudo Random Binary Signal*).

Quanto à localização refere-se onde ocorreu a falhas na planta industrial: Falhas nos sensores, falhas nos atuadores e falhas estruturais.

O cenário de falhas e seu respectivo diagnóstico foi simulado/emulado no Simulink®-*Dynamics Systems*, cuja modelagem foi descrita nas seções anteriores. Vale ressaltar que falhas internas ou estruturais não foram emuladas neste trabalho.

Foram simulados vários processos em malha aberta, bem como diferentes técnicas de detecção e diagnóstico de anormalidades, os resultados são omitidos, visto que o intuito é conhecer as peculiaridades de cada técnica, para ser aplicada na planta de nível e temperatura. As principais conclusões de tais experimentos, são detalhadas nos parágrafos seguintes.

Dentre as técnicas de geração de resíduos apresentadas todas foram satisfatórias, mas não se pode dizer que uma é melhor que a outra. O interessante seria termos todas as técnicas operando sobre a mesma planta gerando um banco de resíduos, o qual passe por um classificador (classificador neural) e depois o isolamento das falhas (*fuzzy*, rede neural, diagnosticadores inteligentes). Desta forma a confiabilidade do diagnosticar seria robusta.

Para o caso das técnicas de diagnósticos baseadas na estrutura *DOS*, as funções de decisão foram bastante eficientes. Visto que estamos tratando com funções, o monitoramento delas é mais fácil, elas mudarão sempre que houver falhas, sendo rápido a detecção e o isolamento da falha. A técnica de diagnóstico baseada no banco de resíduos estruturados, com limiares fixos, é eficaz, mas estes limiares devem ser bem definidos. O interessante é termos limiares auto ajustáveis às condições de operação do processo, limiares inteligentes (limiares gerados por técnicas inteligentes).

Diagnosticadores de falhas em sensores e atuadores baseados em modelos apresentam como principal vantagem a simplicidade, entretanto esta configuração apresenta alguns pontos negativos. Os principais aspectos negativos constituem em que tais técnicas de detecção e isolamento de falhas não se adequam a plantas industriais com muitas variáveis ou em plantas industriais onde o modelo matemático não é conhecido (grande parte das plantas industriais do setor de P&G&B), neste caso deve-se recorrer a outras técnicas de detecção e isolamento tais como Análise por Componentes Principais (PCA), ou técnicas baseadas no histórico do processo (caixa preta do modelo) como redes neurais artificiais, lógica nebulosa e/ou algoritmos genéticos (técnicas inteligentes). Todavia técnicas de diagnóstico de falhas podem interagir com o controlador em um esquema de controle tolerante a falhas (*“Fault Tolerant Control”*).

3.3 Monitoramento de Eventos Anormais em uma Planta de Nível e Temperatura

Nesta seção será apresentada a estratégia para prognóstico de eventos anormais em sistemas industriais, a qual faz uso de técnicas analíticas para geração de resíduos e em seguida a detecção de falhas em sensores e atuadores: Equações de paridade ou relações de consistência, obtido pela conservação direta do modelo de entrada-saída ou espaço de estado do sistema; observadores de estado; identificação paramétrica e o filtro de Kalman. Para a isolamento da anormalidade é usado um classificador lógico com limiares

fixos e para o controle tolerante é utilizada a estimativa da severidade (magnitude) da falha para a reconfiguração da lei de controle. Vale destacar que na literatura encontram-se estratégias de monitoramento que envolve apenas uma das técnicas de detecção. Aqui tais técnicas serão utilizadas em conjunto, gerando um banco de resíduos, os quais serão classificados pelo classificador lógico. O banco de resíduos dará informações ricas do processo. Conseqüentemente um diagnóstico mais preciso, robusto e eficiente será alcançado, minimizando a ocorrência de alarmes falsos. Cada técnica foi testada individualmente, para determinarmos qual (ais) técnica (as) é (são) sensível (eis) a desvios de entrada e quais delas são sensíveis a desvios de saída ou ambos. Concluída esta etapa definiu-se uma metodologia híbrida para detecção e diagnóstico de falhas. A metodologia é avaliada em uma planta de nível e temperatura. Bem como é proposto um roteiro para a definição de limiares adaptativos para unidades processuais.

A planta de nível e temperatura foi escolhida entre outros processos simulados, visto que é um sistema linear bem comportado do ponto de vista de controle, com resposta rápida ao degrau unitário, totalmente estável e controlável e com banda de passagem estreita e por se tratar de um processo comumente encontrado nos complexos industriais.

3.3.1 A Planta de Nível e Temperatura

Processos industriais que envolvem controle de nível e temperatura são muito comuns no setor de Petróleo, Gás e Biocombustíveis (P&G&B), como por exemplo, em tanques de aquecimento ou de misturas, colunas de destilação, caldeiras, fornos entre outros. Outro setor comumente encontrado é nas indústrias alimentícias. Neste setor é muito comum à necessidade de manter a temperatura em um reservatório ao mesmo tempo em que os fluxos de entrada e de saída são determinados pelos processos anteriores e posteriores.

Na Figura 3.2 ilustra-se um exemplo de uma planta industrial para controle de nível e temperatura, um tanque de pré-aquecimento de água para uma caldeira de vapor. Trata-se de uma planta na qual se deseja controlar a temperatura da vazão de saída de um sub-processo para ser utilizado em outro sub-processo e o nível da solução presente no tanque de pré-aquecimento.

Essa planta mostra um sub-processo que deve fornecer água a uma temperatura especificada para um sub-processo seguinte. A vazão de saída é dada a partir de um reservatório cujo nível é mantido constante devido à ação de controle.

A temperatura da água no interior do reservatório é determinada a partir da mistura de água quente e fria de dois outros reservatórios. O elemento L. C. (*Level Control*) é responsável pelo controle de nível atuando sobre a válvula W3. O elemento T. C. (*Temperature Control*) é responsável pelo controle da temperatura de saída T3 e atua sobre a válvula de água quente W2. Os controles das válvulas W1 e W2 são complementares de forma a manter a vazão de saída constante.

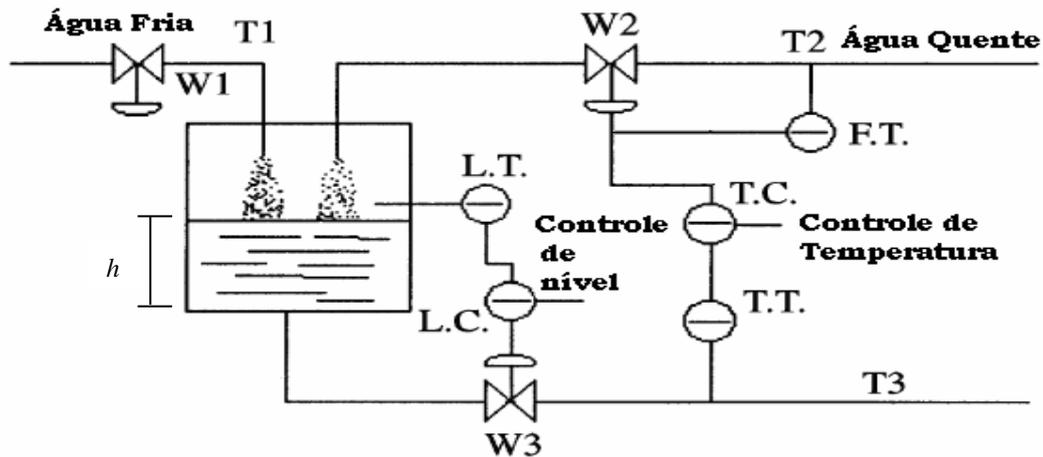


Figura 3.2 – Esquemático da instrumentação e controle do tanque de pré- aquecimento de água.

Fonte: Tarantino e Szigeti, 2000.

O modelo matemático deste processo é obtido pelo balanço de massa e de energia e por leis da hidrodinâmica (escoamento nas válvulas), tratando-se de um sistema não linear, cuja representação em espaços de estados após linearização e substituição dos dados constantes nas equações dinâmicas, é dada por:

$$\frac{d}{dt} \begin{bmatrix} h \\ T_3 \end{bmatrix} = \begin{bmatrix} -0,2 & 0 \\ 0 & -0,3 \end{bmatrix} \begin{bmatrix} h \\ T_3 \end{bmatrix} + \begin{bmatrix} 1 & 0,25 & -0,03 \\ 0,2 & 0,1 & 0 \end{bmatrix} \begin{bmatrix} W_1 \\ W_2 \\ W_3 \end{bmatrix}$$

$$y(t) = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} h \\ T_3 \end{bmatrix}. \quad (3.1)$$

O tanque de pré-aquecimento, por ter múltiplas entradas (W_1, W_2, W_3) e múltiplas saídas (h, T_3), pode ser considerado como um sistema multivariável.

3.3.2 Estratégia de Controle para o Tanque de Pré- aquecimento

Um problema de controle consiste em determinar uma forma de afetar um dado sistema físico de modo que seu comportamento atenda às especificações de desempenho previamente estabelecidas. Como, normalmente, não é possível alterar a estrutura funcional do sistema físico em questão, a satisfação das especificações de desempenho é atingida mediante o projeto e implementação de controladores (compensadores). Também sabemos que, apesar de todo o avanço tecnológico dos últimos anos, com o surgimento de soluções avançadas, tanto em termos de algoritmos de controle quanto de *hardware*, os controladores PID (Proporcional- Integral-Derivativo), e suas variações, ainda são, com larga vantagem, os mais usados na indústria. Os argumentos, para essa massiva predominância do PID, vão desde a simplicidade, à facilidade de implementação e manutenção. A maioria desses argumentos se justifica pelo número reduzido de parâmetros sintonizáveis existentes nos PIDs. Embora, algumas versões de PIDs, trazidas em CLPs (Controlador Lógico Programável) e instrumentos de redes industriais, apresentem um número elevado de parâmetros a serem ajustados, a estrutura básica de um PID contém apenas três parâmetros: O ganho proporcional, k_p , a

constante de tempo integral, τ_i , (ou o ganho integral, k_I), e, a constante de tempo derivativo, τ_d , (ou o ganho derivativo, k_D).

O ajuste dos parâmetros de um controlador é chamado de sintonia (*tuning*). Quando se tem um modelo matemático, representativo, do sistema, a escolha dos parâmetros do controlador recai no desenvolvimento de um projeto, que pode ser feito com base no método do lugar geométrico das raízes, dentre outros. Como, nem sempre é possível se obter um modelo, que represente, adequadamente, a dinâmica que se deseja controlar, se fez necessário o surgimento de técnicas, que não dependam do modelo, para sintonia do controlador.

Os controladores PIDs possuem parâmetros ajustáveis que permitem alterar seu comportamento de modo a obter o melhor desempenho para uma dada aplicação, bem como as características supracitadas. Essa é a justificativa para os controladores PIDs serem utilizados como estratégia de controle para as malhas de nível e temperatura do tanque de pré-aquecimento.

Os parâmetros de sintonia do controlador de nível e do controlador de temperatura, ambos obtidos por técnicas clássicas de sintonia, Ziegler & Nichols, estão dispostos na Tabela 3.1. Os valores nominais das entradas manipuladas e das saídas controladas são: $u_0 = [0 \ 0 \ 0]^T$ e $y_0 = [0 \ 0]^T$. O diagrama de blocos do simulador do processo junto com o controlador de nível e o de temperatura pode ser visualizado na Figura 3.3.

O nível do tanque foi ajustado para 3 m e a temperatura do fluído de saída do tanque para $75 \text{ }^\circ\text{C}$, a entrada de água fria é modelada por uma função degrau, $W_1(t) = 5 u(t) \text{ l/s}$, e a dinâmica das válvulas é descrita por equações diferenciais de primeira ordem. As saídas controladas podem ser observadas nas Figuras 3.4 e 3.5. Vale ressaltar que a malha de temperatura apresenta dinâmica mais rápida do que a dinâmica da malha de nível, com um tempo de assentamento de 30 segundos contra 35 segundos da malha de nível.

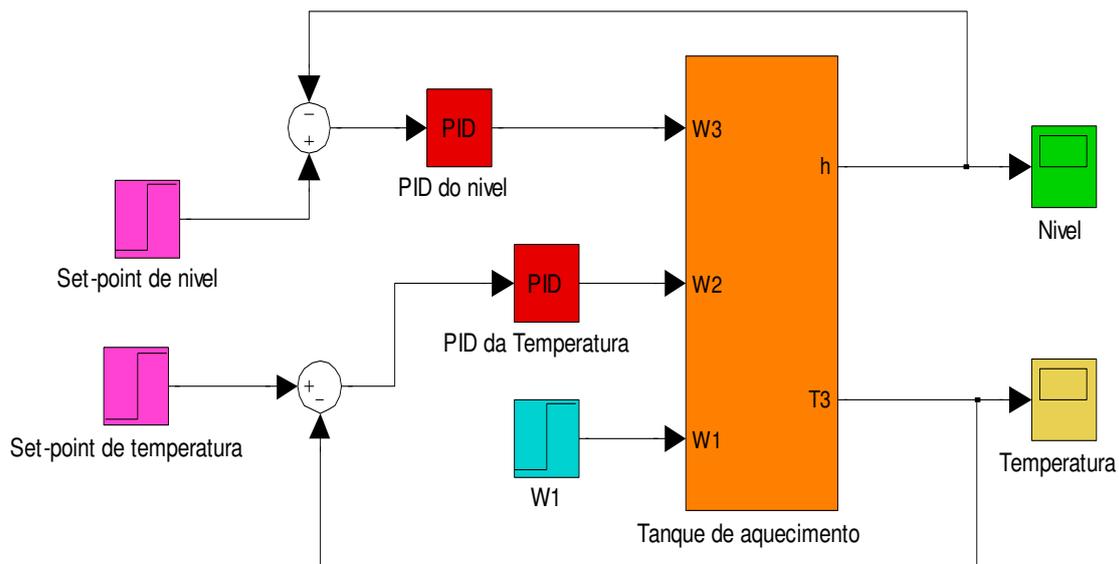


Figura 3.3 - Diagrama de blocos do sistema de controle do tanque de pré-aquecimento de água.

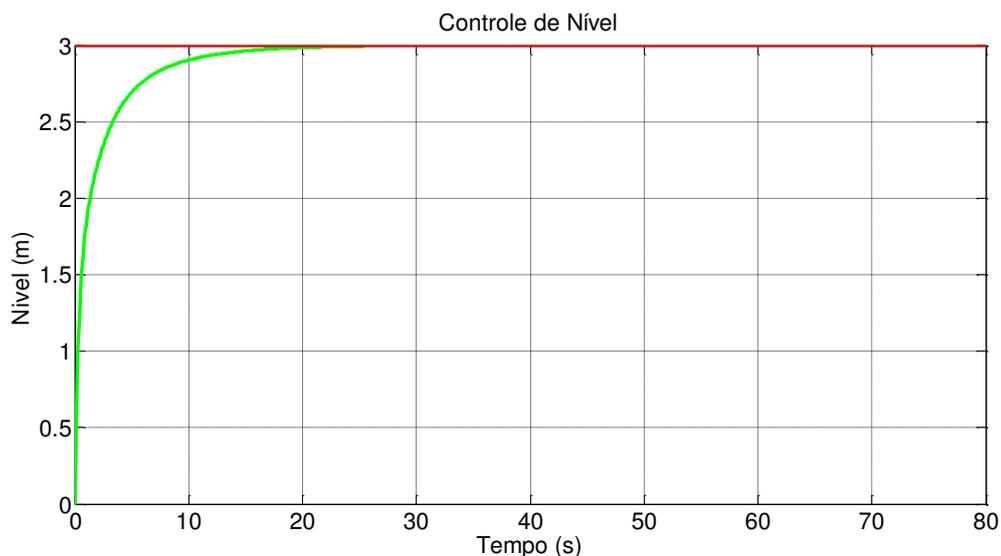


Figura 3.4 - Controle de nível do tanque de pré-aquecimento.

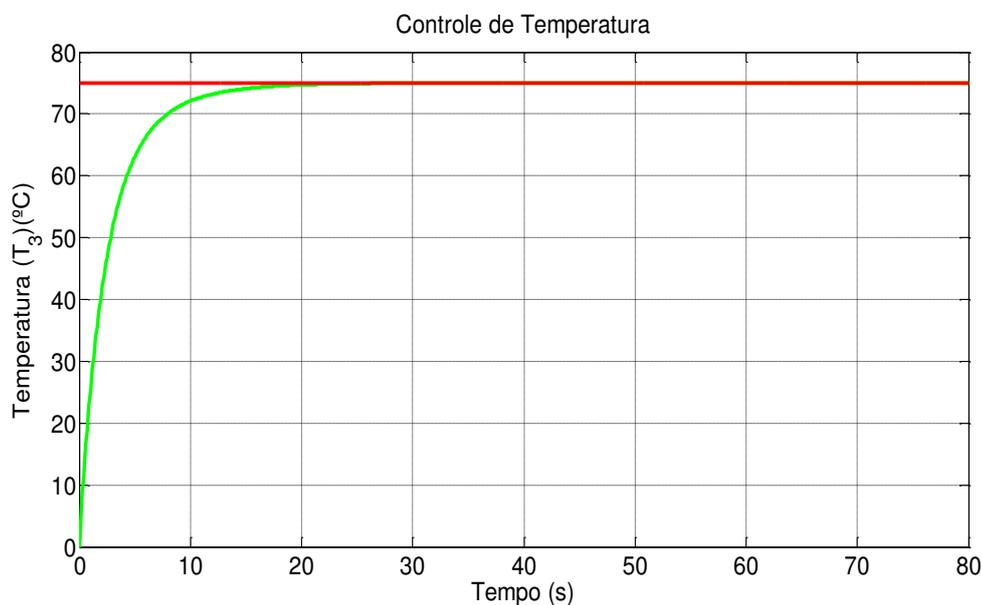


Figura 3.5 - Controle da temperatura do fluido de saída do tanque (T_3).

Tabela 3.1: Parâmetros de sintonia do sistema de controle da planta de nível e temperatura.

Controlador de nível			Controlador de temperatura		
Ganho proporcional	Ganho integral	Ganho diferencial	Ganho proporcional	Ganho integral	Ganho diferencial
$K_p = 5$	$K_I = 1$	$K_D = 0.5$	$K_p = 4$	$K_I = 1$	$K_D = 0.4$

3.3.3 Diagnosticador de Falhas Aplicado ao Tanque de Pré-aquecimento

O sistema de monitoramento irá detectar e identificar falhas nos instrumentos de medição (sensor de nível e sensor de temperatura) e nos instrumentos de atuação (válvula de entrada de água fria, válvula de entrada de água quente e válvula da corrente de saída). Falhas internas ou estruturais não serão diagnosticadas visto que produzem um pequeno efeito no resíduo. O sistema de prognóstico de falhas em sistemas industriais pode ser visualizado na Figura 3.1.

A metodologia utilizada para a reprogramação da lei de controle será discutida na Seção 3.6.5. A lógica utilizada no classificador é descrita como,

Proposição 1. Se $r_b^{pa} > T_b^{pa}$, então, “há falha no atuador b ”;

Proposição 2. Se " $r_b^{obs} > T_b^{obs}$ " & " $r_b^{Kal} > T_b^{Kal}$ " & " $r_b^{Ident} > T_b^{Ident}$ ", então, “há falha no sensor b ”;

Se “proposição 1” \vee “proposição 2 verdade”, então, “há falha no processo”.

Onde $r_b^{(.)}$, $T_b^{(.)}$, é o resíduo gerado pela técnica detecção (equação de paridade (*pa.*), observador de estados (*obs.*), filtro de Kalman (*Kal.*), identificação paramétrica (*Ident.*)) e o limiar fixo para o b sensor respectivamente.

As falhas consideradas no presente texto são as abruptas aditivas intermitentes e abruptas aditivas permanentes, tendo em vista serem mais usuais e deletérias ao processo do que as falhas incipientes. As falhas abruptas, devido a sua forma, são mais fáceis de detectar que as falhas incipientes, que produzem um pequeno efeito nos resíduos. O cenário de falhas é descrito na Tabela 3.2. Os ruídos inseridos são ruído branco, contaminando todas as frequências.

Tabela 3.2: Cenário de falhas – Tanque de pré-aquecimento.

Componente	Tipo de falha	Tempo (s)	Amplitude da falha
Sensor de nível (h)	Abrupta: degrau	100 – 250	+60% no valor de operação normal
	Ruído de medição	0 – 300	Média nula e variância 0.00001
Sensor de temperatura (T_3)	Abrupta: degrau	100 – 300	5°C no valor de operação normal
	Ruído de estado	0 – 300	Média nula e variância 0.00001

Para exibir o desempenho do diagnosticador de falhas foram simuladas as falhas intermitentes e permanentes do cenário da Tabela 3.2 e visualizadas na Figura 3.6. A simulação foi feita no Simulink® - *Dynamics Systems*, do ambiente MatLab® versão 7.6 (versão 2008), usando passo de integração fixo, tolerância de 0,001, método de integração *ODE45-Dormand-Prince solver*, duração de 300 segundos.

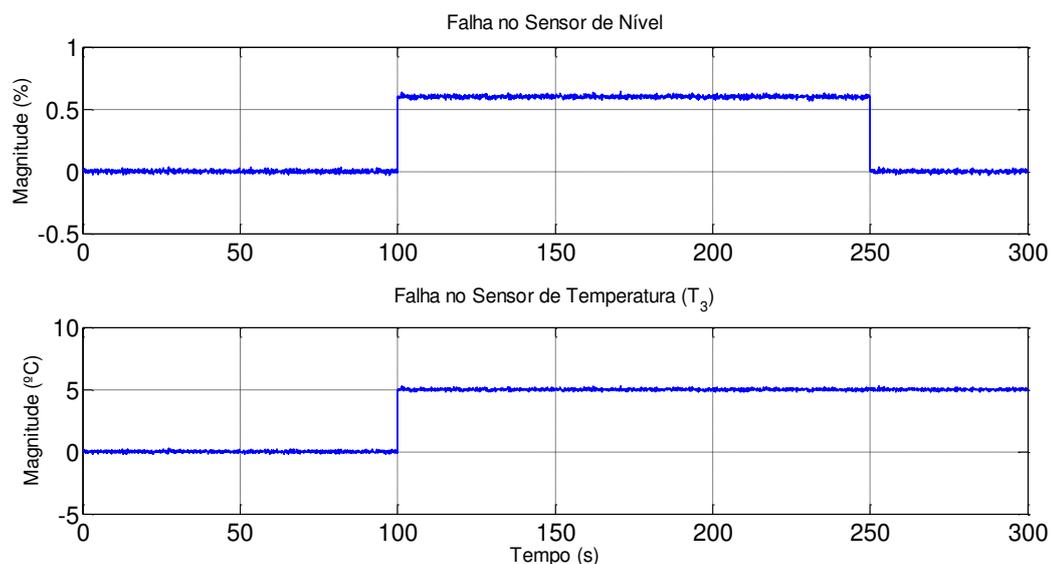


Figura 3.6 - Falhas aplicadas ao tanque de pré-aquecimento.

O comportamento das saídas controladas na presença de falhas é ilustrado na Figura 3.7. Pode-se observar que a dinâmica das malhas é alterada no instante da ocorrência da falta e a ação de controle não é suficiente para manter a saída no ponto de operação desejado.

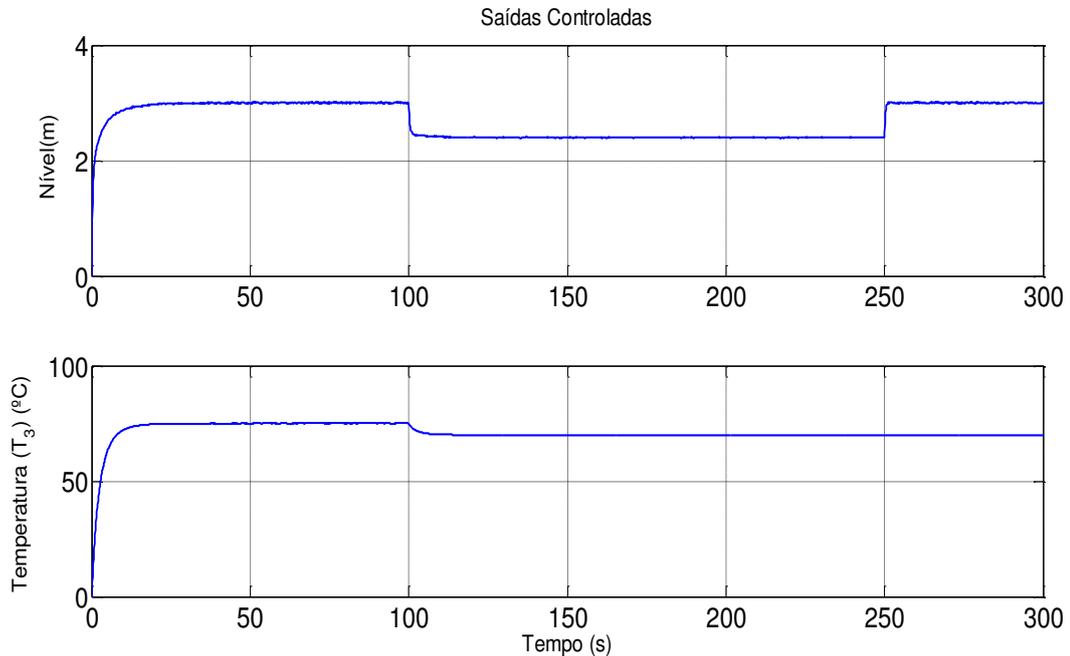


Figura 3.7 - Saídas controladas na presença de falhas.

Os valores dos limiares de decisão utilizados no classificador lógico devem ser escolhidos de forma a minimizar a ocorrência do falso alarme e a perda de alarme. Assim, o valor do *threshold* (limiar) deve ser escolhido entre o valor máximo de resíduos, quando não existem falhas, ao valor de erro máximo aceitável na medição. Na ocorrência de múltiplas falhas é necessário definir os limitadores do sinal de amplitude: o limiar de decisão para evitar falsos alarmes; e os limitadores de diminuição do sinal, para evitar perda de alarmes. Devendo ser feito para cada resíduo gerado por qualquer uma das técnicas de detecção e para cada ponto de operação da unidade industrial.

Para evitar o problema de falsos alarmes ou a perda do alarme, devem-se usar limiares adaptativos baseados nas estatísticas do processo ou em algoritmos inteligentes que se baseiam no histórico (passado) do processo para realizar uma assinatura de padrão, tal questão é discutida na seção 3.6.4.

A detecção e identificação de falhas na unidade pela lógica de decisão com limiares fixos podem ser visualizadas na Figura 3.8 e na Tabela 3.3 temos os intervalos de tempo para a detecção e isolamento do sistema de monitoramento de anomalias da unidade.

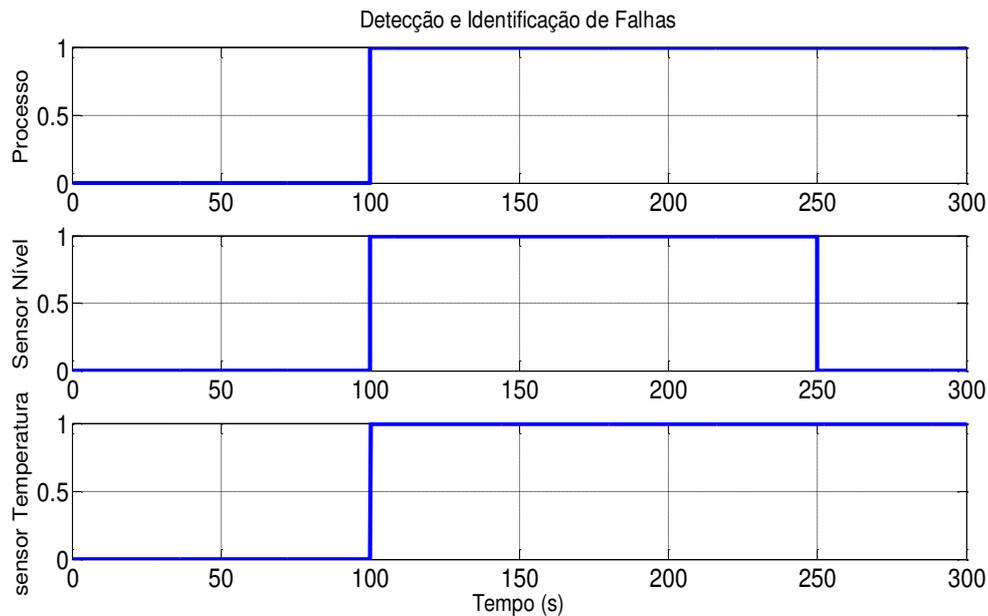


Figura 3.8 - Detecção e Identificação de falhas pelo sistema de monitoramento.

Tabela 3.3: Intervalo de tempo para detecção e isolamento de falhas.

Instrumento	Tipo de falha	Intervalo da falha	Intervalo para detecção e isolamento da falha
Sensor de nível (h)	Abrupta, intermitente: <i>off-set</i>	100 s a 250 s	100.04 s a 250.02 s
Sensor de temperatura (T_3)	Abrupta, permanente: constante.	100 s a 300 s	100.1 s

3.3.4 Projeto dos *Thresholds* Adaptativos

O objetivo desse projeto é gerar limiares que sejam ajustáveis às mudanças de operação da planta, minimizando a ocorrência de falsos alarmes ou a perda do alarme pelo sistema de monitoramento. Para sua consecução propõe-se o seguinte roteiro:

1. Escolha do teste/modelo de geração de *thresholds*: estatístico ou inteligente.
2. Caso seja escolhido testes estatísticos.
 - a. Usar como modelo de geração de *thresholds*: teste da razão de probabilidade generalizada, teste de razão de probabilidade sequencial, teste qui-quadrado e cartas estatísticas das somas cumulativas.
 - b. Definir os limitantes superiores e inferiores para cada teste ajustado a planta.
 - c. Aplicar cada modelo à planta em operação, testar a sensibilidade de cada teste a mudanças no ponto de operação da unidade.
 - d. Escolher como teste padrão para geração de *thresholds* aquele que obtiver menor grau de sensibilidade às mudanças operacionais.
3. Caso seja escolhido testes inteligentes.
 - a. Usar como modelo de geração de *thresholds*: lógica *fuzzy* ou redes neurais.
 - b. Utilizar de algoritmos para assinatura de padrão, no caso de redes neurais (*Hopfield*, *MLP* e/ou *blackpropagation*).
 - c. Treinamento do algoritmo inteligente na unidade processual.

A escolha enfocada no passo 1 do roteiro deve ser feita com base nas informações do histórico do processo.

3.3.5 Controle Tolerante a Falhas

A problemática do controle tolerante a falhas (do Inglês *FTC- Failure Tolerant Control*) surgiu na indústria nuclear, aeronáutica e em plantas químicas e petroquímicas onde a estratégia de controle tradicional *feedback* apresentava desempenho ruim na ocorrência de falhas em sensores, atuadores ou em componentes do processo, comprometendo a qualidade do produto final devido a paradas não programadas (Alexandre, Lima & Neto, 2012, b)..

A ideia principal do controle tolerante é que na ocorrência de falhas no sistema, este possa progredir com sua operação com um desempenho reduzido, mas dentro dos limites aceitáveis (operando com segurança, sem perigo para os operadores humanos ou aos equipamentos), não comprometendo a qualidade do produto final e sem que haja uma parada total da planta (Alexandre, Lima & Neto, 2012, b).

Na literatura o controle tolerante está dividido em duas categorias: abordagem ativa, alcançada pela reconfiguração de controladores ou pela reprogramação da lei de controle e a abordagem passiva que pode ser implementada pelo reprojeto do controlador. Neste trabalho abordaremos a reprogramação da lei de controle para as malhas de nível e temperatura do tanque de pré-aquecimento, visto ser de fácil implementação e por considerarmos que o defeito ocorre na camada de instrumentação e não no controle da planta.

As principais características da reprogramação da lei de controle são: A. Uso do sistema de diagnóstico de falhas; B. Informações da estimação dos estados usada para a reconfiguração do controlador; C. Lei de controle pré-computada (ganhos ou estrutura).

A arquitetura da nova lei de controle pode ser entendida como um sistema de controle com realimentação onde o ganho da realimentação é ajustado pela compensação *feedforward*. Em outras palavras o sucesso da reprogramação da lei de controle depende da robustez do sistema de detecção e diagnóstico de falhas. Qualquer falso alarme ou perda de alarme, ou isolamento incorreta pode levar a instabilidade do sistema em malha fechada.

A estimativa da severidade da falha (magnitude da falha) e o cálculo do sinal lógico de ocorrência de falha feita pelo diagnosticador é de primordial importância para compensar essa falha e para preservar o desempenho do sistema. A estratégia ativa elencada para mitigação de falhas deve ser feita pelo ajuste ou modificação *on-line* da lei de controle nominal, a fim de manter a segurança dos operadores e da confiabilidade do processo. Com a estimativa da severidade da falha e com o sinal lógico de falhas obtidos pelo sistema de detecção e diagnóstico de faltas, uma nova lei de controle pode ser computada para contrariar e aniquilar o efeito da falha sobre o sistema. Esta nova lei de controle aplicada ao sistema é dada pela lei de controle anterior subtraída da magnitude da falha determinada pelo sistema de diagnóstico de anomalias durante a estimação da falha, para o caso de falhas na entrada do processo e alterando a expressão do erro, somando a estimativa da falha feita pelo diagnosticador ao *set-point* de malha,

caso a falha seja na saída do processo. O fluxograma da Figura 3.9 explica a lógica da geração da nova lei de controle.

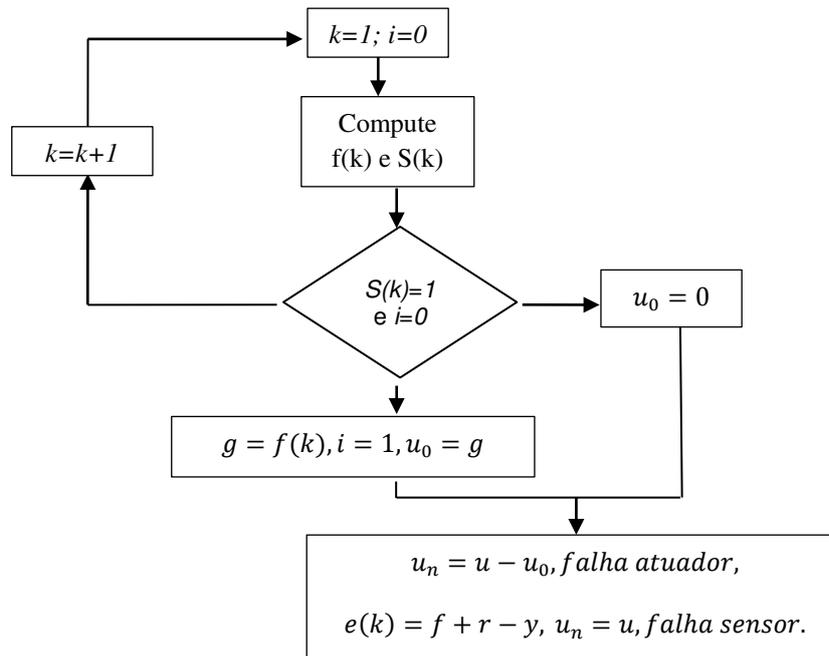


Figura 3.9 - Fluxograma para geração da lei de controle tolerante.

Fonte: adaptado de Santana, 2009 e Alexandre, Lima & Neto, 2012, b.

sendo f é a magnitude da falha (estimada) dada como,

$$f(k) = x_i(k) - x_i(k-1), i = 1, 2, \dots, n, \quad (3.2)$$

onde $x_i(k)$ a amostra no instante em que houve a falha obtido pelos testes de detecção e $x_i(k-1)$ é a amostra anterior a falha (amostra normal, sem anomalia), n é numero de amostras, k é o instante de tempo da ocorrência da falha, S é o sinal lógico produzido pelo sistema de detecção de falhas, u é lei de controle do controlador PID discretizado dada por,

$$u(k) = u(k-1) + k_p \left[e(k) - e(k-1) + \frac{T_s}{\tau_i} (e(k)) + \tau_d T_s (e(k) - e(k-1)) \right], \quad (3.3)$$

onde k_p é o ganho proporcional, T_s é tempo de amostragem por se tratar de um sistema discretizado, τ_i constante do ganho integral, τ_d é a constante de tempo do ganho derivativo, $e(k)$ é o sinal de erro e u_n é a nova lei de controle.

O sistema descrito pela Figura 3.1 ilustra o sistema tolerante simulado no Simulink[®]-*Dynamics Systems* para o cenário de falhas descrito na Tabela 3.2. O sistema de controle tolerante a falhas age somente quando a falha é detectada, isolada e identificada, onde ele computa a nova lei de controle, sendo capaz de reduzir os efeitos da falha no sistema. Uma vez identificada, o sistema tolerante soma a magnitude estimada da falha a referência, gerando a nova lei de controle que é usado pelo sistema. Daí a importância da estimação da falha.

A habilidade do método de acomodação de falha é apresentada na Figura 3.10 e 3.11. Uma vez que a falha é isolada e estimada, a nova lei de controle é computada de forma a reduzir o efeito da falha sobre o sistema. Na Figura 3.10 é visto a lei de controle (ações de controle) da variável controlada, nível. Em ponto-traço mostra a lei de controle anterior à reprogramação, e em pontilhado, a lei de controle reconfigurada, pode-se notar que o sistema de controle tolerante a falhas consegue acomodar a falha aplicada, a resposta do controle tolerante a falhas aplicado a malha de temperatura pode ser visualizada na Figura 3.11.

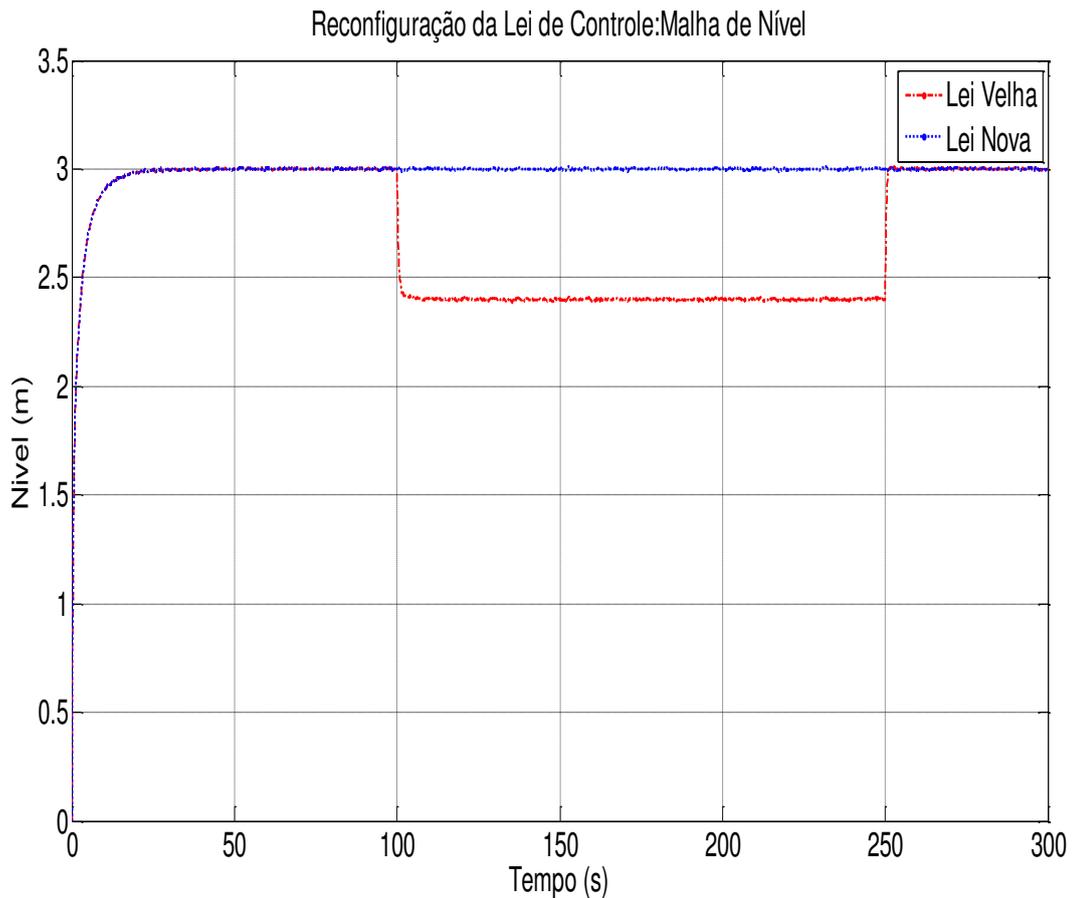


Figura 3.10 - Resposta da malha de nível ao sistema tolerante para o cenário de defeitos.

A mitigação de falha nas malhas de controle não foi total, visto que não podemos estimar os ruídos de estado e de medição inseridos no processo, ao menos que seja feita uma filtragem ou um tratamento estatístico de alto desempenho, fato este que compromete a qualidade da estimativa da falha.

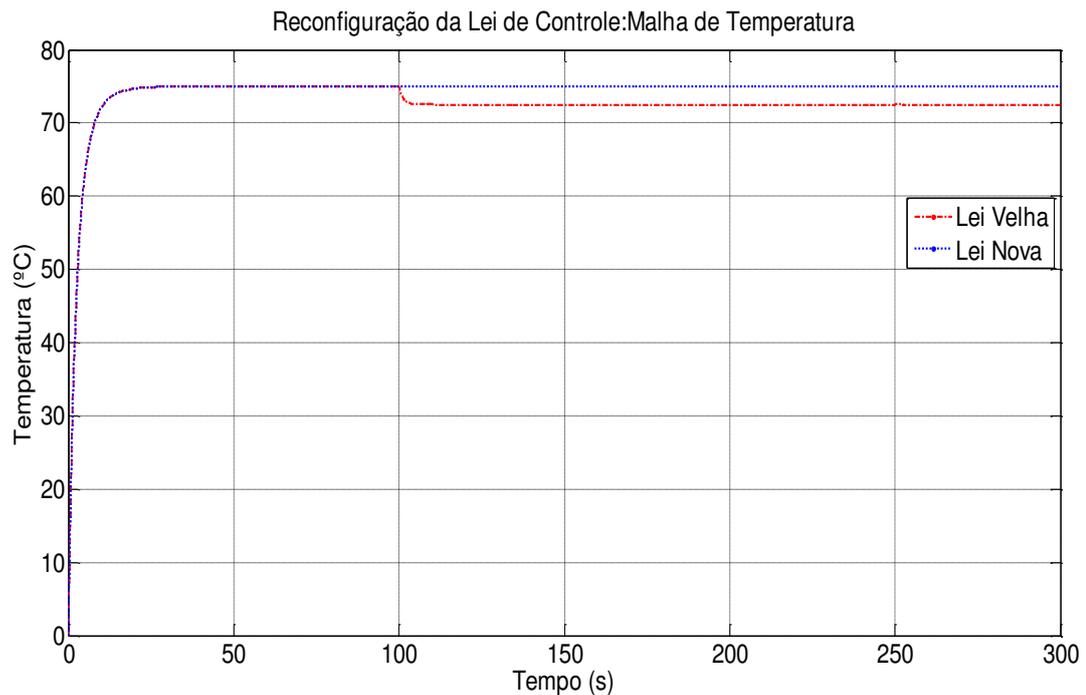


Figura 3.11 - Resposta da malha de temperatura ao sistema tolerante para o cenário de falhas

3.3.6 Conclusões Preliminares

A solução proposta para detecção, isolamento de falhas mostrou-se eficiente quando avaliada para o tanque de pré-aquecimento de água operando em malha fechada, em termos da identificação de condições anormais de funcionamento, bem como a metodologia para reconfiguração da lei de controle quando da ocorrência de falhas em sensores e atuadores.

Tendo em vista, o classificador lógico está utilizando limiares fixos discutiu-se uma metodologia para consecução de limiares adaptativos, os quais devem ser definidos pelas informações estatísticas e históricas do processo, de modo a minimizar a ocorrência de falsos alarmes ou a perdas de alarmes (fato que compromete o controle tolerante). Ainda que no estudo realizado tenha sido utilizada uma lei de controle clássica para controlar a planta, o procedimento para diagnose de falhas em sistemas industriais proposto é relativamente independente, sendo possível utilizá-lo no caso de outras estratégias de controle.

Capítulo 4

Monitoramento de falhas em sistemas industriais baseado no histórico do processo

4.1 Introdução

A medida que os processos químicos e petroquímicos se tornam mais complexos, o monitoramento destes vem ganhando grande importância no sentido de melhorar a eficiência do processo e a qualidade do produto. A detecção precoce da falha pode ajudar a evitar paradas inesperadas, acidentes e diminuir o tempo *start-up* do processo. Em geral quatro tarefas estão envolvidas no monitoramento do processo: (1) detecção da falha, que fornece uma indicação de que algo está errado no processo; (2) identificação da falha, determina onde houve o defeito; (3) estimativa da falha, que avalia a amplitude da falha; (4) reconstrução da falha, eliminar a falha para que a informação correta seja enviada para o (s) controlador (es) (Alexandre, Lima & Neto, 2012, a).

A técnica denominada de análise de componentes principais (*PCA - Principal Component Analysis*) é uma das alternativas promissoras para projetar sistemas de diagnóstico de falhas em sistemas de instrumentação e controle de processos industriais, tendo em vista que permite implementar todas as etapas descritas anteriormente num mesmo arcabouço matemático. Quando aplicadas a processos industriais, soluções baseadas em PCA capturam as correlações existentes entre os dados do processo e mediante alterações destas correlações permitem identificar a presença de anomalias operacionais.

Técnicas de detecção e isolamento de falhas baseadas em PCA têm sido utilizadas em sistemas de instrumentação industrial. Jeng (2007), propõe uso da técnica PCA linear recursiva para detecção após uma filtragem dos sinais provenientes dos instrumentos operantes, Shen (2010), apresenta um diagnosticador inteligente utilizando PCA para detecção e um classificador neural para a isolamento, Bhattacharjee (2010) propôs uma técnica baseada em PCA para um sistema de interação de tanques, Bin (2011), introduziu uma estratégia na qual usa PCA para detecção de falhas combinada com o método de somas cumulativas (CUSUM), para a isolamento da anomalia, Halligan (2011) trata do prognóstico de falhas para um sistema de bombas comparando o desempenho para detecção da falha utilizando PCA linear e método de Kernel PCA. Vale destacar que de modo geral, os trabalhos tratam da aplicação específica sem a metodologia de projeto que seria adotada nos testes experimentais, tampouco enfatizam o uso da técnica PCA como alternativa para avaliação de projetos de sistemas de instrumentação em termos da quantidade de sensores/atuadores.

A detecção da ocorrência de situações anormais por modelos PCA enseja duas fases: A. O ajuste do modelo PCA aos dados do processo, ou seja, obtém-se um modelo PCA que represente corretamente a condição de operação normal; B. Fase de vigília, na qual a observa-se a operação do sistema para detectar ocorrência de uma falha

operacional tomando por base um modelo PCA que represente o comportamento correto e normal de operação do processo e qualquer desvio significativo observado, teria sido provocado por um comportamento anormal na planta, tratando-se, assim, de uma falha operacional, (Kano, 2000).

Tão relevante quanto detectar uma anomalia é localizá-la. Um sistema capaz de identificar com precisão a origem do problema permite reduzir significativamente o tempo de manutenção da unidade, colaborando para o imediato retorno à operação normal. Identificados os sensores/atuadores defeituosos a tarefa imediata seria a reconstrução do sinal perdido devido à ocorrência da falha, usando para isso a magnitude da falha e a direção da falha (Dunja 1996 a, b).

4.2 Teoria da Análise de Componentes Principais (PCA)

A técnica PCA é uma ferramenta de estatística multivariável que permite transformar um conjunto de p variáveis correlacionadas num conjunto de k , ($k < p$), variáveis não correlacionadas denominadas de componentes principais (PCs). Os PCs são, de fato, combinações lineares das p variáveis originais (Montgomery, 2004).

Considerando que os dados coletados de um determinado processo industrial são armazenados na matriz $X \in \mathfrak{R}^{n \times m}$, na qual as n linhas representam as amostras e as m colunas representam as variáveis mensuráveis da planta. A utilização da técnica PCA requer, inicialmente, o cálculo da matriz de covariância dos dados do processo, definida por (Ku, 1995):

$$\text{cov}(X) = \frac{1}{n-1} (X^T X). \quad (4.1)$$

O modelo PCA é obtido pela decomposição dos autovalores dessa matriz de covariância. Este modelo divide o espaço de monitoramento em dois subespaços ortogonais; o subespaço de componentes principais (PC) e o subespaço residual (RS). A variação normal de dados será capturada pelo subespaço PC e variações como ruídos aleatórios e erro de predição são capturados pelo subespaço RS. A matriz de transformação $P \in \mathfrak{R}^{m \times a}$ é gerada escolhendo-se a autovetores ou as q colunas correspondentes aos a autovalores principais. A matriz P transforma o espaço das variáveis medidas no novo espaço de dimensão reduzida,

$$T = XP. \quad (4.2)$$

As colunas da matriz P são denominadas de vetores de carregamento e a matriz T é denominada de matriz de *scores*. Os *scores* são os valores das variáveis originais medidas que foram transformadas no espaço de dimensão reduzida. Se todos os autovalores forem selecionados do conjunto de dados originais, então

$$X = TP^T, \quad (4.3)$$

e se alguns autovetores forem desprezados, o espaço de dados original pode ser calculado por

$$X = TP^T + E. \quad (4.4)$$

Nesse caso a matriz E representa o resíduo, ou se já, a informação não capturada pelo modelo.

Os primeiros PCs capturam a maior variância das medições. Desse modo, é importante escolher o número adequado de PCs para representar o sistema de forma compacta, observando os autovalores característicos para cada componente principal, a variância percentual dos PCs e a variância percentual acumulada dos PCs.

A função PRINCOMP, do MATLAB, foi utilizada para fazer a transformação linear, para cada um dos conjuntos de dados foram calculados os componentes principais utilizando-se a função *PRINCOMP*.

$$[COEFF, SCORE, LATENT, TSQUARED] = PRINCOMP(zscore(X));$$

Conforme descrição do MATLAB (www.mathworks.com), a primeira saída desta função (*coeff*) corresponde aos autovetores da matriz X , isto é, são os componentes principais calculados para os dados da matriz X . Estes valores são resultados de combinações lineares das variáveis originais. A segunda saída, *scores*, corresponde às novas variáveis (variáveis originais no novo sistema de coordenadas definido pelos componentes principais) e possui a mesma dimensão da matriz X . A terceira saída, *latent*, corresponde aos autovalores da matriz X , ou seja, é um vetor que contém a variação explicada pelo componente principal correspondente. Através deste dado é possível calcular o percentual da variabilidade total que cada componente principal é responsável. O gráfico de Pareto é utilizado para ilustrar a contribuição que cada componente principal tem sobre o resultado final e desta forma escolher/determinar os componentes principais mais importantes para o processo, ou seja, os componentes principais que respondem pela maior variabilidade do processo. A quarta saída corresponde à estatística de Hotelling, variável pela qual será feito o monitoramento, cuja definição matemática será definida na seção 4.3.1. O comando $zscore(X)$, é utilizado para normalizar os dados e obtermos a matriz de covariância, de média nula e variância um.

4.3 Uso de PCA para Diagnóstico de Falhas

A monitoração pode ser reduzida a duas variáveis, a carta de controle multivariadas baseada na distribuição T^2 de Hotelling e a carta de controle estatístico baseada na Estatística Q , caracterizando dois subconjuntos ortogonais do espaço original.

4.3.1 PCA no monitoramento de processos multivariados

A implementação de um sistema de monitoramento e diagnóstico de falhas baseado em PCA, consiste de duas tarefas:

- a) OFF-LINE

Obter série de dados do processo operando em condições normais, em seguida faz-se a normalização dos dados subtraindo-se a média \bar{x} das amostras de cada

variável e dividindo pelo desvio padrão dos dados s . Determinar os autovalores e autovetores correspondentes da matriz de covariância, determinar o número de componentes principais e o limite superior de controle para as estatísticas T^2 e Q .

b) ON-LINE

- i. Obter a mostra $x(t + 1)$, em seguida normalizá-la;
- ii. Computar a estatísticas τ^2 e Q , obtido usando PCA. Se um destes exceder o limite superior de controle, esta medição é considerada um alarme, se houver consecutivos /sucessivos alarmes, um evento incomum ocorreu;
- iii. Repetir a etapa ii.

Ao utilizar PCA para monitoramento de falhas pelo uso de cartas de controle é necessário definir as variáveis de monitoramento, a estatística τ^2 e Q (SPE- *Square Predictor Error*). A estatística τ^2 de Hotelling mede a variação dentro do modelo PCA, já SPE mede a variação do erro quadrado entre o valor verdadeiro da amostra com o valor predito da variável no novo espaço linear.

A estatística τ^2 é a soma dos quadrados normalizados dos *scores*, definido como,

$$\tau_i^2 = y_i(C_k^T C_k)^{-1} y_i^T, \quad (4.5)$$

onde o índice i indica que o cálculo é feito para cada amostra do vetor X , y_i é o vetor linha da matriz de *scores* e C_k é a matriz de transformação, o termo entre parêntese é uma matriz diagonal de autovalores da matriz de covariância de X .

A estatística Q também é conhecida (referida) como o erro de previsão ao quadrado (SPE), quando um novo tipo de evento ocorre, este tipo de evento pode ser detectado pelo cálculo do SPE das novas observações, a estatística Q é definida por,

$$Q_i = e_i e_i^T = x_i(I - C_k C_k^T) x_i^T \quad (4.6)$$

ou,

$$Q_i = \sum_{j=1}^p e_j^2(i), \quad (4.7)$$

na qual, e_i é o vetor de resíduos, uma projeção do vetor de observação X dentro do espaço residual, I é a matriz identidade de ordem compatível (matriz quadrada). O vetor de resíduos pode ser obtido utilizando a função $PCARES(X)$, pré-definido no ambiente MATLAB.

A estrutura para monitoramento de processos multivariados do tipo caixa preta (o modelo que descreve o processo não é conhecido) pode ser observada na Figura 4.1.

Quando é conhecido o modelo do processo a estrutura é modificada, na qual o PCA é utilizado para tratar o resíduo entre o valor real e o valor predito da variável, esta configuração é apresentada na Figura 4.2 e é conhecida como *Model Based PCA-MBPCA* (PCA baseado em modelo).

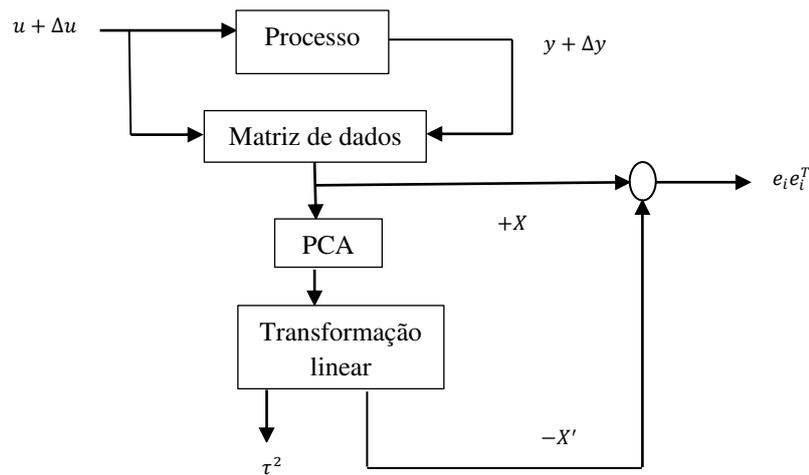


Figura 4.1 - Monitoramento de falhas via PCA.

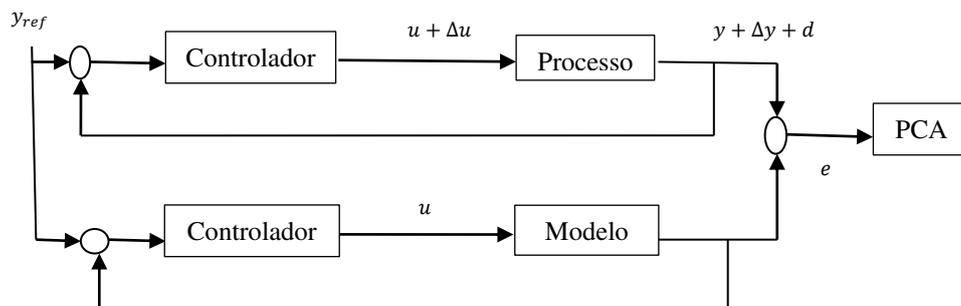


Figura 4.2 - Monitoramento de falhas utilizando MBPAC.

Do diagrama de blocos da Figura 4.1, $u + \Delta u$, representa o sinal de entrada da planta proveniente do atuador acrescido de uma falha, y , sinal de saída da planta correspondente às leituras dos sensores instalados, Δy , corresponde a uma falha aditiva ocorrida nos medidores. Os dados de entrada e saída são processados pelo sistema de aquisição de dado e organizados numa matriz de dados do processo, a qual é processada pelo modelo PCA, transformando-a numa nova matriz de dados decorrelacionados ao mesmo tempo o modelo já fornece a carta de controle de Hotelling (ou τ^2). O resíduo entre a nova matriz de dados e matriz de dados antiga, quando computado de maneira correta fornece a estatística Q (*SPE- Square Predictor Error*).

Na Figura 4.2 é ilustrado o uso do modelo PCA, para processos do tipo caixa branca, ou seja, processos cujo modelo matemático que descreve a dinâmica do sistema é conhecido. O modelo pode obtido por qualquer uma das técnicas apresentadas na Seção 2.3; d , representa um distúrbio não caracterizado, y_{ref} , representa os *set-points* da planta, e , é o resíduo entre o sinal de saída do sistema real danificado e o sinal de saída do modelo sem falhas. Vale ressaltar que o modelo PCA é usado para processar o resíduo e gerar as cartas de controle, diferentemente da situação apresentada na Figura 4.1.

4.3.2 Limite Superior de Controle

Para uma detecção confiável é necessário definir o limite superior de controle da carta, definido em condições normais de operação. Para estatística T^2 , o limite superior de controle (LSC) para um nível de confiança de $\alpha = 95\%$ é definido como (Montgomery, 2004),

$$LSC = \frac{K(N-1)}{N-K} F(K, N-K, \alpha), \quad (4.8)$$

onde o termo $F(K, N-K, \alpha)$, corresponde a pontos de probabilidade da distribuição de Fisher (F) com $(K, N-K)$ graus de liberdade e α é o nível de confiança da carta, K é o número de componentes principais e N é o número de observações (amostras). O script em MATLAB a seguir pode ser usado para calcular o LSC para a estatística T^2 .

```
>> T2lim=np*(N-1)/(N-npc)*finv(0.95,np,N-npc);
```

Para uma saída/score individual, o limite para um nível de confiança de $\alpha = 95\%$ é dado,

$$LSC(pc_i) = \pm\sqrt{\lambda_i} * T(N-1, \alpha), \quad (4.9)$$

sendo λ_i corresponde ao i -ésimo autovalor da matriz de covariância de X , $t(N-1, \alpha)$, corresponde a pontos de probabilidade da distribuição T com $(N-1)$ graus de liberdade e área $\alpha/2$. Um script em MATLAB pode ser usado para calcular o limite de confiança conforme texto:

```
>> T2lim_1=sqrt(sigma(1,1))*tinv(0.95,N-1); %Para o primeiro componente principal.
```

onde $\sigma = C_k C_k^T$ ou:

$$\sigma = \begin{bmatrix} \lambda_1 & 0 & \cdots & 0 \\ 0 & \lambda_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \lambda_k \end{bmatrix} \quad (4.10)$$

O limite superior de controle para a estatística Q pode ser obtido a partir da sua distribuição de probabilidade proposta por Jackson e Mudholkar (1979),

$$LSC_{(SPE)} = \theta_1 \left[\frac{h_0 c \sqrt{2\theta_2}}{\theta_1} + 1 + \frac{\theta_2 h_0 (h_0 - 1)}{\theta_1} \right]^{1/h_0}, \quad (4.11)$$

sendo $\theta_i = \sum_{j=K+1}^N \lambda_j^i$; $h_0 = 1 - \frac{2\theta_1\theta_3}{3\theta_2^2}$ e c é o desvio normal.

4.3.3 Identificação da Falha

Segundo Bose, Kuma & Venkateswarlu (2005), quando ocorre falha de um sensor haverá uma mudança na correlação do sensor defeituoso com os outros sensores. Este fenômeno pode ser utilizado para encontrar qual sensor está defeituoso (condição de identificabilidade). Se b é o número de componentes principais e c é o número de componentes principais retidos (retirados), então, a dimensão do subespaço residual é $b - c$. Assim o grau máximo de liberdade disponível para qualquer vetor de observação é $b - c$. Logo a condição necessária para identificabilidade é $b - c \geq 2$.

Uma vez que a falha é detectada pelos testes de estatística multivariada, a tarefa seguinte é isolar os sensores defeituosos. Quando estes testes violarem os limites de controle de confiança a contribuição das variáveis individuais podem ser plotadas/tabuladas e as variáveis com maiores contribuições são examinadas para identificar os sensores defeituosos. Os gráficos das contribuições podem revelar as variáveis do processo que tem maior participação para o modelo PCA (T^2) e/ou os resíduos (SPE). Quando a estatística SPE viola seu limite de controle, a contribuição das variáveis individuais podem ser plotadas e as variáveis de maior contribuição são examinadas para computar/indicar os sensores defeituosos. Similarmente, se a variação no espaço do modelo (T^2) torna-se grande e extrapola o limite de controle, pode-se usar o mesmo raciocínio anterior. A contribuição de cada variável (x_i), de um valor grande do j PC escore suspeito (y_i) é dada por,

$$con^{T^2}(x_i) = C_{i,j}x_i, \quad (4.12)$$

$$con^{SPE}(x_i(k)) = x_i(k) - x_i(k-1) \text{ ou } con^{SPE}(x_i(k)) = (x_i(k) - x_i(k-1))^2, \quad (4.13)$$

sendo $C_{i,j}$ é o peso da i -ésima variável, x_i , e do j -ésimo autovalor corresponde ao respectivo PC suspeito, sendo C a matriz de transformação e x_i é o vetor de observação durante o período de tempo em consideração, para o caso da contribuição no espaço de resíduos $x_i(k)$ representa a mostra no instante de ocorrência da falha e $x_i(k-1)$ amostra anterior à falha (saudável) e k representa o instante de tempo que ocorreu a falha; estes valores são plotados contra o número de variáveis (sensores).

4.3.4 Reconstrução da Falha

Uma vez que os sensores defeituosos são identificados, a tarefa imediata é corrigir a falha, antes que seja enviado o sinal para os controladores ou para uma estimativa de estado atual do processo. Neste trabalho a informação da falha no sensor é utilizada para fazer a reconstrução dos sensores anormais. A tarefa de reconstrução consiste em fazer uma nova e melhor estimativa x das variáveis no espaço do PCA, utilizando o modelo PCA e a direção da falha ξ . O vetor de amostras em funcionamento normal é indicado por x' que é desconhecido quando ocorre uma falha, na presença de uma falha, o vetor x de amostras pode ser representado usando o vetor de direção da falha ξ_i o que caracteriza o efeito da falha nas medições reais,

$$x = x' + f\xi_i, \quad (4.14)$$

sendo ξ_i é o vetor normalizado e f é um escalar que representa a magnitude (amplitude) da falha. O vetor x_i reconstruído é obtido através da correção de x na direção de ξ_i :

$$x_i = x - f_i \xi_i, \quad (4.15)$$

sendo f_i é uma estimativa da magnitude da falha f que mede o deslocamento na direção ξ_i .

A viabilidade do cálculo de f_i assegura a existência de x_i , que é a melhor estimativa para x' por reconstrução na direção ξ_i .

4.3.5 Descrição da Coluna Fracionadora de Óleo Cru

A teoria de PCA no monitoramento de processos multivariados será aplicada no modelo de uma coluna fracionadora de óleo cru, conhecido na literatura como *Process Shell*, inicialmente introduzido por Prett & Morari (1987). Como explicado em Prett & Morari (1987), esta coluna não representa um processo real, mas foi projetada para conter todos os elementos importantes de problemas de fracionadoras reais.

Na Figura 4.3 ilustra-se um esquema simplificado da coluna fracionadora. Como pode ser observada, a coluna possui três vazões de saída (produto de topo, produto lateral, e produto de fundo) e três malhas de circulação lateral para a remoção de calor. O calor necessário entra pelo fundo da coluna, juntamente com a alimentação que é gasosa. As especificações dos produtos de topo e lateral são determinadas por necessidades econômicas e os valores dessas composições são medidos pelos analisadores localizados nos pontos de remoção dos produtos de topo e lateral, respectivamente. Para o produto de fundo não existem especificações, porém há uma restrição de operação sobre a temperatura na parte inferior da coluna. As três malhas de circulação removem o calor a fim de alcançar a separação apropriada do produto. O calor removido nestas malhas aquece outras partes da coluna, as quais têm necessidades de taxas de calor diferentes. Assim, os fluxos de calor nessas malhas são considerados variantes no tempo. A malha de fundo possui um controlador de entalpia que regula a remoção de calor através do controle de refluxo. A remoção de calor nas outras duas malhas atua como perturbação na coluna (Ansari & Tadé, 2000).

De forma resumida, o modelo da coluna fracionadora de óleo cru possui sete saídas ($y_1, y_2, y_3, y_4, y_5, y_6, y_7$) e cinco entradas (u_1, u_2, u_3, d_1, d_2). Três dessas entradas (u_1, u_2, u_3) podem ser utilizadas para fins de controle e duas (d_1, d_2) são consideradas perturbações, uma mensurável e a outra não mensurável. Das sete saídas, três (y_1, y_2, y_7) estão envolvidas nos objetivos de controle e as outras quatro (y_3, y_4, y_5, y_6) são consideradas auxiliares (Ansari & Tadé, 2000). A Tabela 4.1 apresenta as variáveis do modelo da coluna fracionadora.

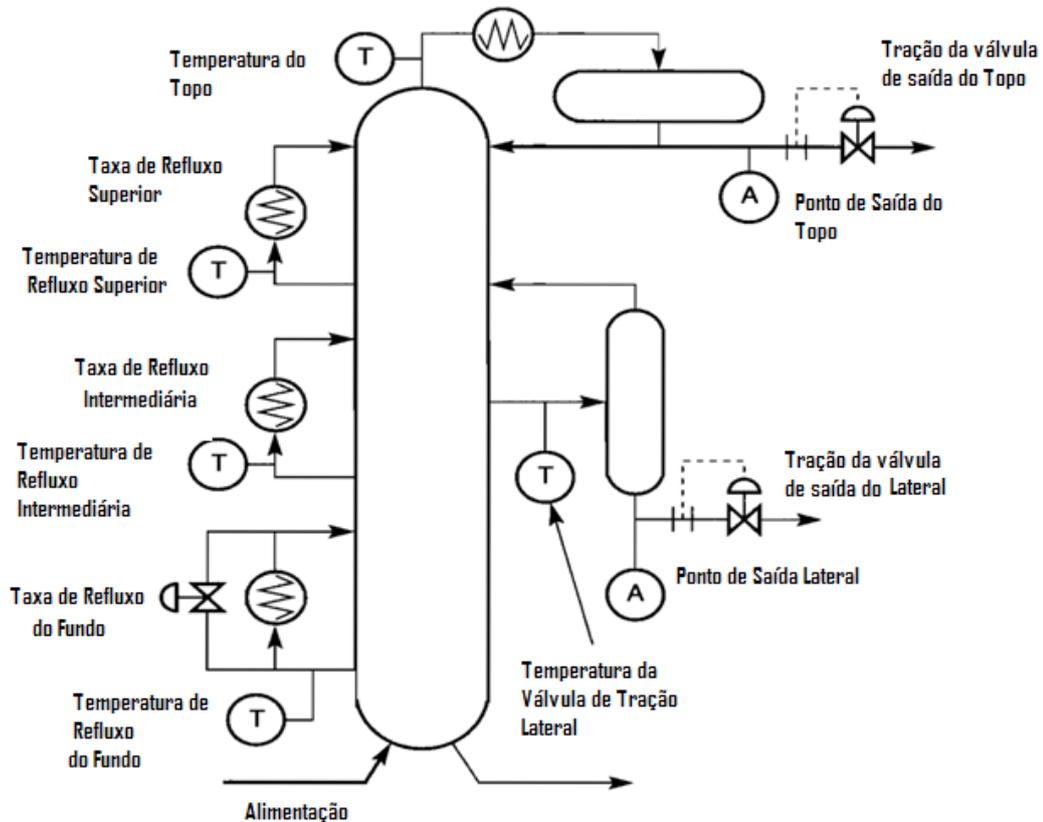


Figura 4.3 - Modelo da coluna fracionadora de óleo cru (Prett & Morari, 1987).

Tabela 4.1: Descrição das variáveis da coluna fracionadora.

Variável	Função	Símbolo
Tração da válvula de saída de topo	Entrada controlada	u_1
Tração lateral	Entrada controlada	u_2
Taxa de refluxo do fundo	Entrada controlada	u_3
Taxa de refluxo do intermediário	Perturbação mensurável	d_1
Taxa de refluxo do superior	Perturbação não mensurável	d_2
Ponto de saída do topo	Saída controlada e monitorada	y_1
Ponto de saída lateral	Saída controlada e monitorada	y_2
Temperatura do topo	Saída monitorada	y_3
Temperatura de refluxo superior	Saída monitorada	y_4
Temperatura de refluxo lateral	Saída monitorada	y_5
Temperatura de refluxo intermediária	Saída monitorada	y_6
Temperatura de refluxo do fundo	Saída controlada e monitorada	y_7

A função de transferência para cada entrada e saída é modelada como função de primeira ordem defasada com um tempo de atraso. Estas funções de transferência podem ser vistas na Tabela 4.2. As funções de transferências das entradas de controle (variáveis monitoradas) pelas saídas são mostradas na Tabela 4.2. É importante ressaltar que os valores de constantes de tempo e atraso são expressos em minutos. As funções de transferência das duas entradas perturbadas pelas saídas são mostradas na Tabela 4.3. Estas tabelas mostram as funções de transferência nominal. O ganho em cada função de transferência é incerto, as incertezas se devem pelo fato de que as entradas são correlacionadas entre si. A Tabela 4.4 especifica as incertezas em cada ganho. O modelo

nominal é obtido quando $\delta_i = 0$ para cada j , mas assume-se que cada δ_i pode variar entre -1 e $1 u_1$.

A resposta ao degrau unitário do processo é apresentada no apêndice, mostrando que a planta é assintoticamente estável e que os tempos de estabilização variam de aproximadamente 10 segundos até 250 segundos.

Tabela 4.2: Funções de transferências das entradas monitoradas

	u_1	u_2	u_3
y_1	$\frac{4.05e^{-27s}}{50s + 1}$	$\frac{1.77e^{-28s}}{60s + 1}$	$\frac{5.88e^{-27s}}{50s + 1}$
y_2	$\frac{5.39e^{-18s}}{50s + 1}$	$\frac{5.72e^{-14s}}{60s + 1}$	$\frac{6.9e^{-15s}}{40s + 1}$
y_3	$\frac{3.66e^{-2s}}{9s + 1}$	$\frac{1.65e^{-20s}}{30s + 1}$	$\frac{5.53e^{-2s}}{40s + 1}$
y_4	$\frac{5.92e^{-11s}}{12s + 1}$	$\frac{2.54e^{-12s}}{27s + 1}$	$\frac{8.1e^{-2s}}{20s + 1}$
y_5	$\frac{4.13e^{-5s}}{8s + 1}$	$\frac{2.38e^{-7s}}{19s + 1}$	$\frac{6.23e^{-2s}}{10s + 1}$
y_6	$\frac{4.06e^{-8s}}{13s + 1}$	$\frac{4.18e^{-4s}}{33s + 1}$	$\frac{6.53e^{-1s}}{9s + 1}$
y_7	$\frac{4.38e^{-20s}}{33s + 1}$	$\frac{4.42e^{-22s}}{44s + 1}$	$\frac{7.2}{19s + 1}$

Tabela 4.3: Funções de transferências das entradas perturbadas por todas as saídas.

	d_1	d_2
y_1	$\frac{1.2e^{-27s}}{45s + 1}$	$\frac{1.44e^{-27s}}{40s + 1}$
y_2	$\frac{1.52e^{-15s}}{25s + 1}$	$\frac{1.83e^{-15s}}{20s + 1}$
y_3	$\frac{1.16}{11s + 1}$	$\frac{1.27}{6s + 1}$
y_4	$\frac{1.73}{5s + 1}$	$\frac{1.79}{19s + 1}$
y_5	$\frac{1.31}{2s + 1}$	$\frac{1.26}{22s + 1}$
y_6	$\frac{1.19}{19s + 1}$	$\frac{1.17}{24s + 1}$
y_7	$\frac{1.14}{27s + 1}$	$\frac{1.26}{32s + 1}$

Tabela 4.4: Incerteza do ganho de cada função de transferência.

	u_1	u_2	u_3	d_1	d_2
y_1	$4.05 + 2.11\delta_1$	$1.77 + 0.39\delta_2$	$5.88 + 0.59\delta_3$	$1.20 + 0.12\delta_4$	$1.44 + 0.16\delta_5$
y_2	$5.29 + 3.29\delta_1$	$5.72 + 0.57\delta_2$	$6.90 + 0.89\delta_3$	$1.52 + 0.13\delta_4$	$1.83 + 0.13\delta_5$
y_3	$3.66 + 2.29\delta_1$	$1.65 + 0.35\delta_2$	$5.53 + 0.67\delta_3$	$1.16 + 0.08\delta_4$	$1.27 + 0.08\delta_5$
y_4	$5.92 + 2.34\delta_1$	$2.54 + 0.24\delta_2$	$8.10 + 0.32\delta_3$	$1.73 + 0.02\delta_4$	$1.79 + 0.04\delta_5$
y_5	$4.13 + 1.71\delta_1$	$2.38 + 0.93\delta_2$	$6.23 + 0.30\delta_3$	$1.31 + 0.03\delta_4$	$1.26 + 0.02\delta_5$
y_6	$4.06 + 2.39\delta_1$	$4.18 + 0.35\delta_2$	$6.53 + 0.72\delta_3$	$1.19 + 0.08\delta_4$	$1.17 + 0.01\delta_5$
y_7	$4.38 + 3.11\delta_1$	$4.42 + 0.73\delta_2$	$7.20 + 1.33\delta_3$	$1.14 + 0.18\delta_4$	$1.26 + 0.18\delta_5$

4.4 Teoria de Controle Preditivo

Controle preditivo (*MPC-Model Predictive Control*) é uma estratégia de controle ótimo baseada em otimização numérica. Entradas de controle futuras e respostas futuras da planta são previstas usando um modelo do sistema otimizado e em intervalos regulares com relação ao índice de desempenho. É uma técnica computacional criada para melhorar o desempenho de algumas aplicações de controle dentro de indústrias de processo e petroquímica. Controle preditivo tornou-se a mais difundida metodologia de controle avançado atualmente (2013) em uso na indústria.

Apesar de ser simples projetar e implementar algoritmos MPC, estes podem controlar sistemas de grande escala, além do mais fornecem um método sistêmico de lidar com as restrições nas entradas e nos estados da planta. Essas restrições estão presentes em todas as aplicações de engenharia de controle e representam limitações em atuadores e nos estados da planta resultantes da física do processo, impondo restrições econômicas ou de segurança. No MPC estas restrições são contabilizadas explicitamente através da resolução de um problema de otimização restrita em tempo real para determinar a entradas ótimas preditas. Dinâmica de planta não lineares pode ser igualmente incorporada ao modelo de previsão.

O tradicional controle realimentado funciona regulando a ação de controle a qualquer mudança da saída em frente à referência. A técnica de controle preditivo focaliza na construção de um controlador capaz de ajustar a ação de controle antes que ocorra realmente uma mudança no valor nominal da saída. Esta capacidade de previsão, quando combinada com o tradicional controle por realimentação, permite obter um controlador capaz de fazer ajustes que são mais suaves e mais próximos dos valores ótimos de ação de controle. O diagrama de blocos da Figura 4.4 ilustra a estrutura básica de um controlador preditivo.

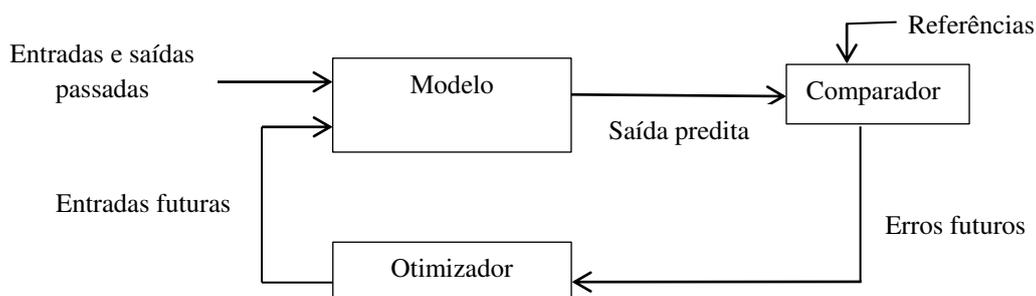


Figura 4.4- Estrutura básica de um controlador preditivo.

O modelo usa dados de entrada e saída passadas e combina com as entradas de previsões futuras, e dá uma saída predita para o passo de tempo. Esta saída predita (estimada) é combinada com a referência dando os erros de previsão futuros do sistema. Estes erros são transmitidos a um otimizador incluindo as restrições do sistema (por exemplo, assegurar que o cálculo da taxa de fluxo para o modelo não seja maior que o fluxo máximo permitido) com os resultados previstos, minimizando a função custo operacional. Esta dará as entradas previstas futuras, que são alimentadas de volta para o modelo, reiniciando o ciclo.

Controle preditivo (MPC) é uma estratégia de controle ótimo que consiste em uma otimização a cada instante de tempo discreto, k . O ponto principal deste problema de otimização é calcular o novo sinal de controle, u_k , que alimenta o sistema e ao mesmo tempo levar em consideração as restrições do processo (restrições sobre as variáveis do processo). Um algoritmo MPC consiste em: uma função custo; as restrições da planta e o modelo do processo.

Horizontes de controle e de predição

Horizonte de predição (N_p) é o número de amostras futuras que o controlador prevê a saída da planta.

Horizonte de controle (N_c) é o número de amostras, dentro do horizonte de predição, onde o controlador MPC pode afetar a ação de controle ($N_c \leq N_p$).

A Figura 4.5 ilustra a esquemática dos horizontes de um controlador preditivo.

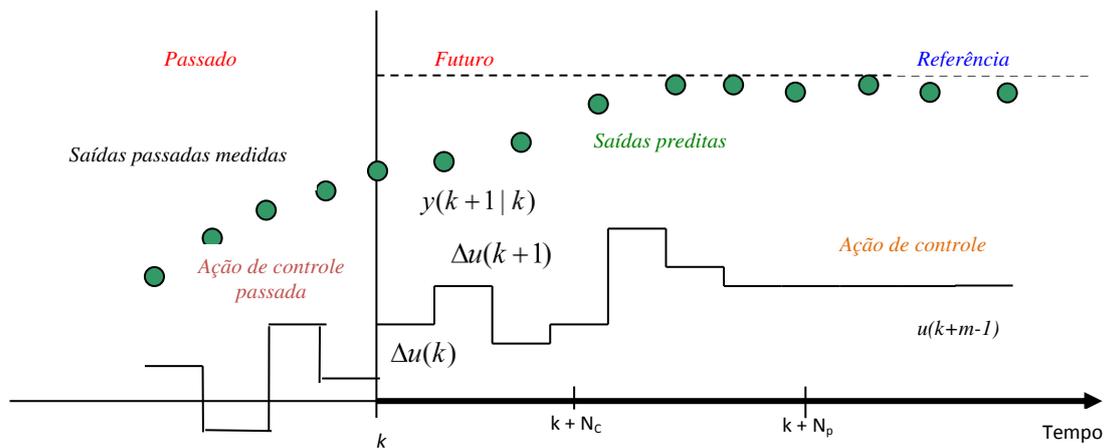


Figura 4.5- Esquemática do horizonte móvel no controle preditivo.

Para o instante, k , o controlador MPC, prevê a saída da planta para o instante $k + N_p$. Vemos a partir da Figura 4.5 que a ação de controle não se altera após o término do horizonte de controle.

A primeira entrada da sequência ótima é então enviada para a planta e um conjunto de cálculos é repetido em intervalos de controle subsequentes. A cada interação do horizonte de predição há um avanço de tempo e novamente o controlador prediz a saída da planta. Conforme pode ser observado na Figura 4.6.

Um horizonte de predição pequeno reduz o período de tempo durante o qual o controlador MPC prevê as saídas da planta. Quando o horizonte de predição é pequeno o controlador MPC funciona mais como um controlador de realimentação tradicional.

Um horizonte de predição grande aumenta a habilidade preditiva do controlador MPC, mas este apresentará uma redução de desempenho devido a cálculos adicionais.

Um horizonte de controle pequeno significa uma maior atenção às mudanças na ação de controle (ação de controle mais lenta). Um horizonte de controle grande significa mudanças mais agressivas na ação de controle (ação de controle mais rápida).

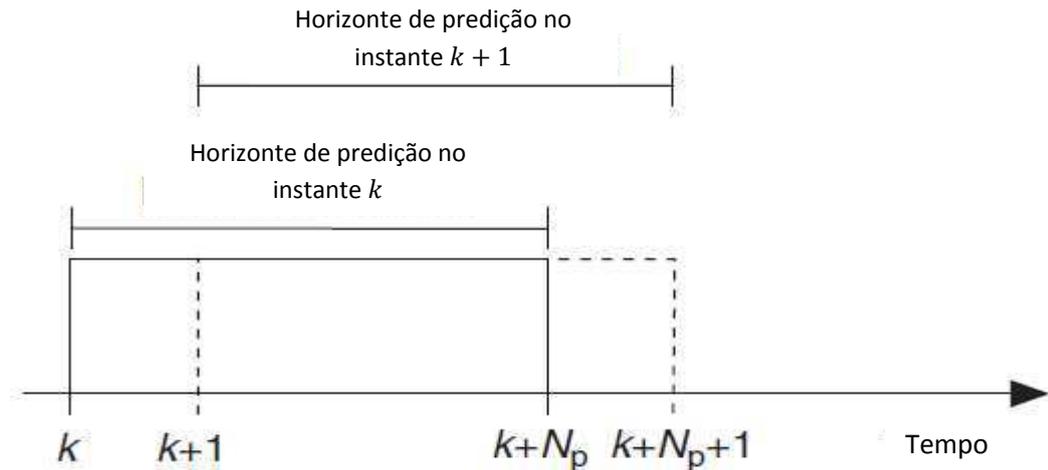


Figura 4.6- Esquema da sequência de previsão ótima.

O modelo

Uma desvantagem do controle preditivo (MPC) é a necessidade de um modelo que descreva o comportamento entrada e saída do processo, modelo este que provém de leis de conservação. Normalmente, na prática é usado um modelo baseado nos dados do processo.

Em MPC presume-se que o modelo seja uma representação em espaços de estados discreto da forma,

$$\begin{aligned} x_{k+1} &= \mathbf{A}x_k + \mathbf{B}u_k \\ y_k &= \mathbf{C}x_k + \mathbf{D}u_k \end{aligned} \quad (4.16)$$

Função custo operacional

A lei de controle preditivo de realimentação é computada minimizando uma função custo desempenho, no caso calculando uma sequência de ação de controle futura de tal forma que a função custo seja minimizada.

A função custo frequentemente usada em MPC (no caso custo quadrático, uma função linear quadrática) é definida como,

$$J = \sum_{k=0}^{N_p} (y^* - r)^T Q (y^* - r) + \sum_{k=0}^{N_p} \Delta u^T R \Delta u \quad (4.17)$$

onde N_p é o horizonte de previsão, r é o *set-point*, y^* é a saída do processo predita, Δu é a mudança no valor do sinal de controle predito, $\Delta u_k = u_k - u_{k-1}$, Q , é matriz de ponderação de erros das saídas, R é a matriz de ponderação de controle.

A função descrita pela equação (4.17) é utilizada para sistemas MIMO (*Multiple Input Multiple Output*), de modo que estamos lidando com matrizes e vetores.

Para sistemas SISO (*Single Input Single Output*) a função custo é definida como,

$$J = \sum_{k=0}^{N_p} q(y^* - r)^2 + \sum_{k=0}^{N_p} r \Delta u^2. \quad (4.18)$$

O problema básico é a minimização do valor de J , definido pela equação (4.18).

As restrições

Todos os sistemas físicos apresentam restrições. Temos limitações físicas, como limites de atuadores e sensores, variáveis que podem ser medidas e ainda temos as limitações de segurança, tais como temperatura e os limites de pressão. Finalmente temos as restrições de desempenho como *overshoot*.

Em MPC normalmente definimos as restrições como,

Restrições de saídas: $y_{min} \leq y \leq y_{max}$

Restrições de entradas: $\Delta u_{min} \leq \Delta u \leq \Delta u_{max}$, $u_{min} \leq u \leq u_{max}$,

vale ressaltar que $\Delta u_u = u_k - u_{k-1}$.

O controlador MPC leva em consideração todas estas restrições ao calcular a ação de controle futura.

4.4.1 Controle preditivo aplicado à coluna fracionadora de óleo pesado

O controlador preditivo foi utilizado para controlar as saídas y_1 , y_2 e y_7 , manipulando as entradas u_1 , u_2 e u_3 . Para o presente estudo de caso o modelo nominal do sistema, desprezando as incertezas, é dado pela expressão (4.19).

$$\begin{bmatrix} y_1(s) \\ y_2(s) \\ y_7(s) \end{bmatrix} = \begin{bmatrix} \frac{4.05e^{-27s}}{50s+1} & \frac{1.77e^{-28s}}{60s+1} & \frac{5.88e^{-27s}}{50s+1} \\ \frac{5.39e^{-18s}}{50s+1} & \frac{5.72e^{-14s}}{60s+1} & \frac{6.9e^{-15s}}{40s+1} \\ \frac{4.38e^{-20s}}{33s+1} & \frac{4.42e^{-27s}}{44s+1} & \frac{7.2}{19s+1} \end{bmatrix} \begin{bmatrix} u_1(s) \\ u_2(s) \\ u_3(s) \end{bmatrix} + \begin{bmatrix} \frac{1.2e^{-27s}}{45s+1} & \frac{1.44e^{-27s}}{40s+1} \\ \frac{1.52e^{-15s}}{25s+1} & \frac{1.83e^{-15s}}{50s+1} \\ \frac{1.14}{27s+1} & \frac{1.26}{32s+1} \end{bmatrix} \begin{bmatrix} d_1(s) \\ d_2(s) \end{bmatrix} \quad (4.19)$$

As saídas y_3 , y_4 , y_5 , y_6 , não estão sob a ação de controle, mas podem ser monitoradas a partir do sistema. Os parâmetros de sintonia do controlador estão dispostos na Tabela 4.5.

Neste projeto utilizou-se o *Toolbox Model Predictive Control* como ferramenta computacional para implementação do controlador MPC. Este *Toolbox*, disponível no pacote MatLab, oferece diversas funcionalidades para simulação de cenários e ajuste dos parâmetros do controlador que atenderam as necessidades do presente trabalho.

Os valores nominais das entradas manipuladas e das saídas controladas são: $u_0 = [0,5 \ 0,1812 \ -0,4612]^T$ e $y_0 = [0 \ 0 \ 0]^T$. O simulador do processo junto com o controlador em ambiente Simulink- MATLAB, pode ser visualizado na Figura 4.7.

Do diagrama de blocos da Figura 4.7 o bloco denominado por *Planta* foi implementado neste subsistema todas as funções de transferências das Tabelas 4.2 e 4.3 que representam a coluna *Shell*, tendo como entradas as variáveis manipuladas pelo controlador preditivo (as saídas preditas) e os distúrbios, modelados por uma função degrau, no intuito de termos uma perturbação abrupta no sistema. Todas as saídas da planta bem como as variáveis manipuladas alimentam o modelo *PCA* do qual retiramos a cartas de controle preditivo para a detecção de falhas. O controlador preditivo recebe os sinais provenientes do analisador de ponto de saída do topo (y_1), do analisador de

ponto de saída lateral (y_2) e do sensor de temperatura de refluxo de fundo (y_7) como as saídas mensuráveis. Recebe também as referências e os distúrbios mensuráveis, combina estes sinais com as restrições do processo e fornece as ações de controle para coluna fracionadora (variáveis manipuladas). Por se tratar de um processo descrito por funções de transferências normalizadas, as referências introduzidas são valores nulos.

Tabela 4.5: Parâmetros de sintonia do controlador preditivo para coluna fracionadora da *Shell*.

Parâmetro	Descrição	Valor
T_a	Tempo de amostragem	4 s
N	Horizonte do modelo	300
N_p	Horizonte de predição	30
N_c	Horizonte de controle	3
Δu_{max}	Limite Máx. De incremento nas entradas.	$[\pm 0,003; \pm 0,003; \pm 0,003]$
u_{max}	Limite máximo das entradas	$[0,5; 0,5; 0,5]$
u_{min}	Limite mínimo das entradas	$[-0,5; -0,5; -0,5]$
Q	Matriz de ponderação de predição das saídas.	$diag([2 \ 2 \ 2])$
R	Matriz de fatores de supressão de incremento nas entradas.	$diag([0 \ 0 \ 0])$

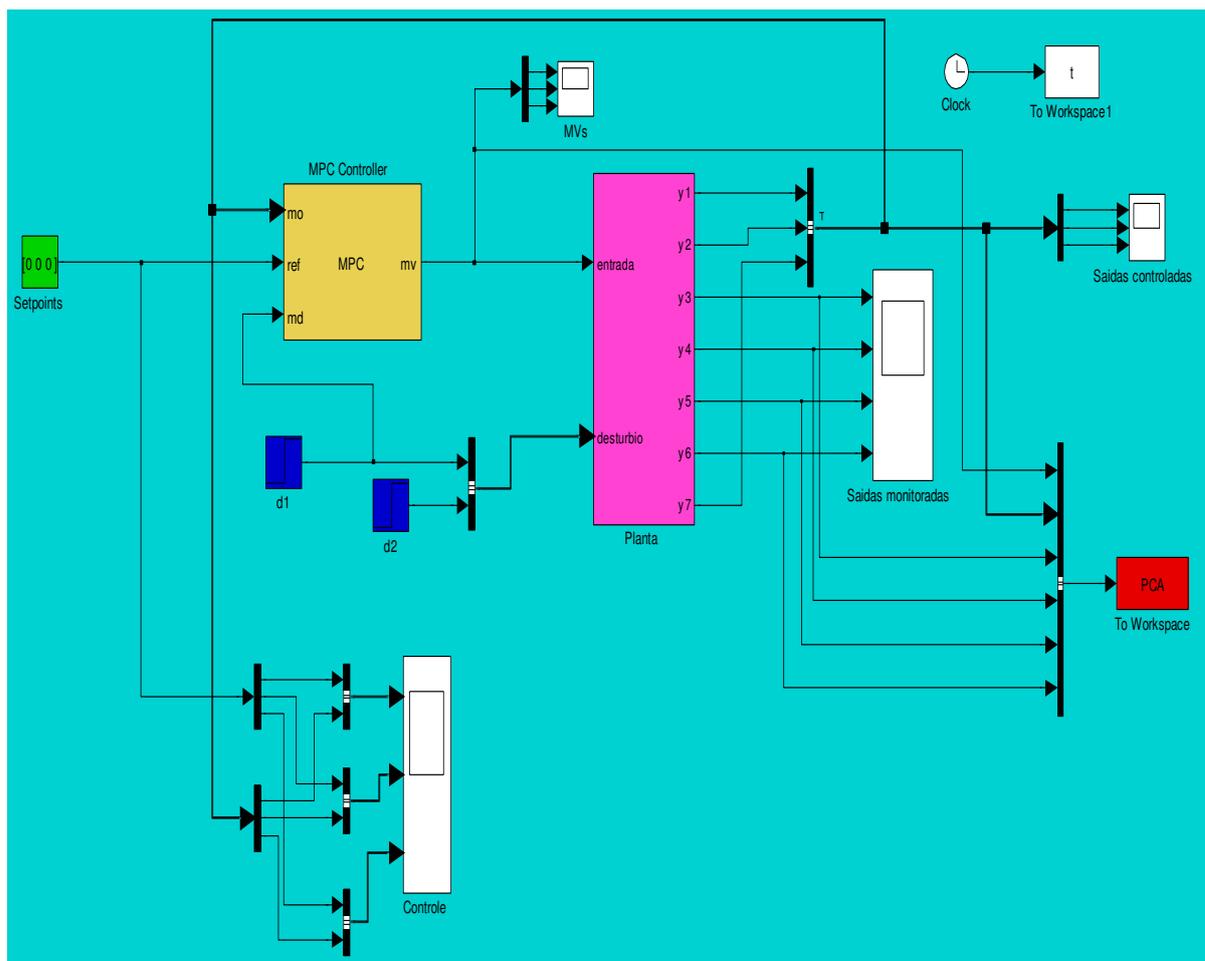


Figura 4.7 - Simulador da coluna fracionadora e o respectivo sistema de controle.

Na Figura 4.8 apresenta-se o controle das saídas y_1 , y_2 e y_7 (ponto de saída do topo, ponto de saída lateral e temperatura de refluxo do fundo, respectivamente) na presença de distúrbios (d_1 e d_2) aplicados nos instantes 500 e 2000 segundos, respectivamente.

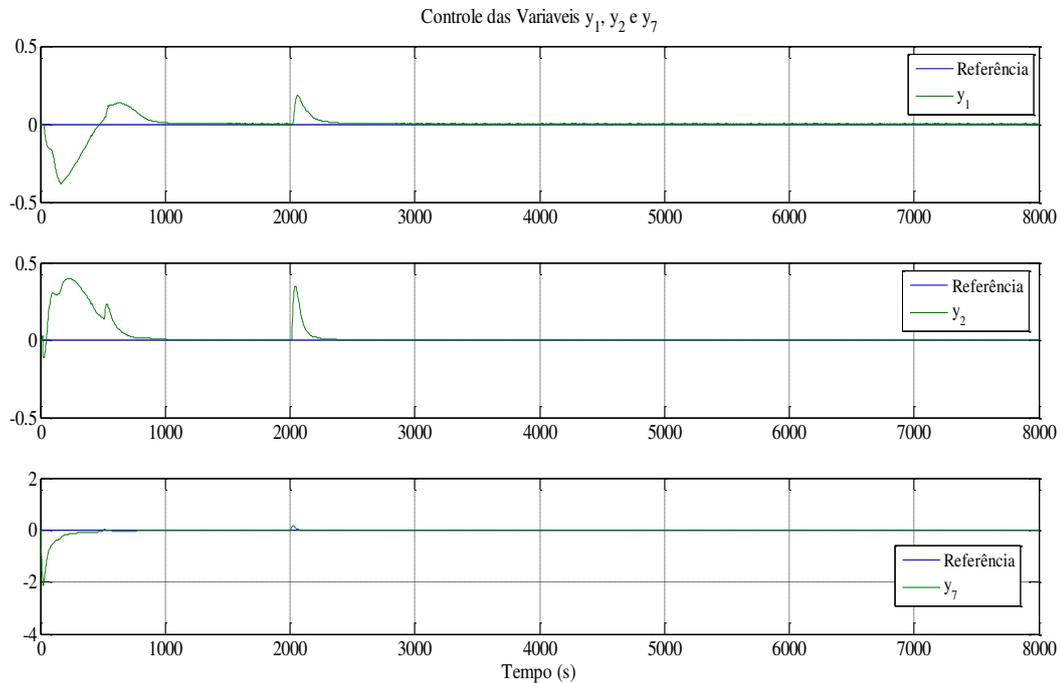


Figura 4.8 - Controle da coluna fracionadora de óleo pesado.

A análise PCA foi feita em linhas de código (o bloco *PCA* envia os dados de entrada- saída para o *Workspace*). Configuração para análise PCA implementada é a descrita pelo diagrama da Figura 4.1.

Na Figura 4.8 observa-se o comportamento a ação de controle na coluna, a qual pode ser entendida como uma ação de controle rápida visto que os tempos de assentamentos de cada malha foram pequenos se comparada a dinâmica do processo. Também pode avaliar a atuação do controlador na presença de distúrbios, o distúrbio mensurável (d_1), foi inserido no instante de 500 segundos, como o processo ainda esta em regime transitório não tão notável a ação do controlador, já o distúrbio não mensurável por ser inserido no instante de 2000 segundos, a planta já opera em regime permanente, percebe-se que o controlador atua de forma rápida aniquilando-o e levando a saída a novamente referência.

4.5 Projeto do PCA inicial para a fracionadora *Shell*

A finalidade deste estudo é garantir o desenvolvimento de um modelo PCA robusto e eficiente, que leve conseqüentemente a um bom diagnóstico de eventos anormais no processo. Ao longo do texto serão respondidas as seguintes perguntas: Qual sinal será aplicado ao processo para termos maior grau de descorrelação entre as variáveis do processo? Qual a frequência deste sinal? Qual a amplitude do sinal? Quantas amostras são necessárias para um bom PCA? Com relação às mudanças no ponto de operação,

qual o comportamento do modelo PCA em frente a estas mudanças? Qual janela de tempo (tempo de realização de novo PCA) deve-se aplicar a metodologia de monitoramento de falhas baseada em PCA em se tratando de um diagnosticador *on-line*?

Todas estas indagações serão respondidas através de testes na planta, ao final será apresentado um roteiro especificando as características de interesse, sendo estas as respostas das devidas perguntas levantadas. O roteiro desenvolvido pode ser aplicado a qualquer processo que se deseje ter um modelo PCA rico de informações.

O objetivo de projeto é gerar o modelo PCA inicial (padrão) rico de informações, e confiável, pois dele será obtido os limites de controle das cartas estatísticas utilizados no diagnóstico de falhas.

4.5.1 Projeto experimental da construção do modelo PCA

O projeto consiste em obter os seguintes parâmetros: O sinal de perturbação para geração do modelo PCA, Amplitude do sinal, Frequência do sinal, Tempo de duração do diagnóstico via PCA, Número de amostras, Índice de qualidade do modelo em frente a mudanças no ponto de operação do processo.

4.5.1.1 Sinal de perturbação

Pode se usar como excitação nos *set-points* do sistema de instrumentação e controle da fracionadora os seguintes sinais: senoidal, onda quadrada, dente de serra e onda triangular. Visto que estes respeitam a dinâmica do sistema em malha fechada e as saídas conseguem seguir a referência.

Para definirmos qual sinal deve ser usado, deve-se aplicar cada um dos sinais na mesma condição de operação do processo e medir o nível de correlação existente entre as variáveis do processo (variáveis de entrada e saída) em cada situação o candidato que atingir o maior nível de descorrelação é o candidato vencedor.

Nesta linha de pensamento foram realizados experimentos na planta, para os sinais supracitados. Como estamos interessados em obter o maior grau de descorrelação cruzada entre as variáveis, deve-se perturbar todos os *set-points*. A frequência e a amplitude usadas para cada sinal foram de 0,005 Hz e 0,1 respectivamente, os gráficos de dispersão e correlação cruzada para cada tipo de sinal podem ser visualizados nas Figuras 4.9 a 4.14. O gráfico de dispersão permite avaliar a simetria dos dados e sua dispersão, identificando o comportamento dos dados do processo, quais amostras estão mais dispersas, mais distantes dos valores nominais.

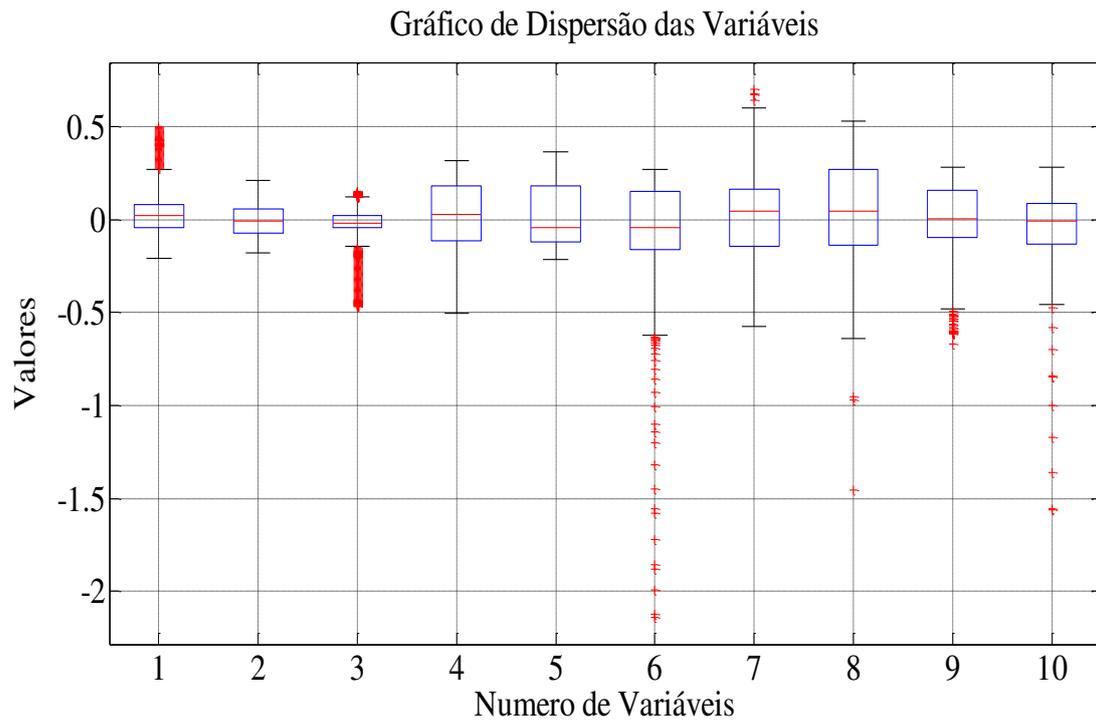


Figura 4.9 - Gráfico de dispersão das variáveis do sistema. Sinal perturbador onda quadrada.

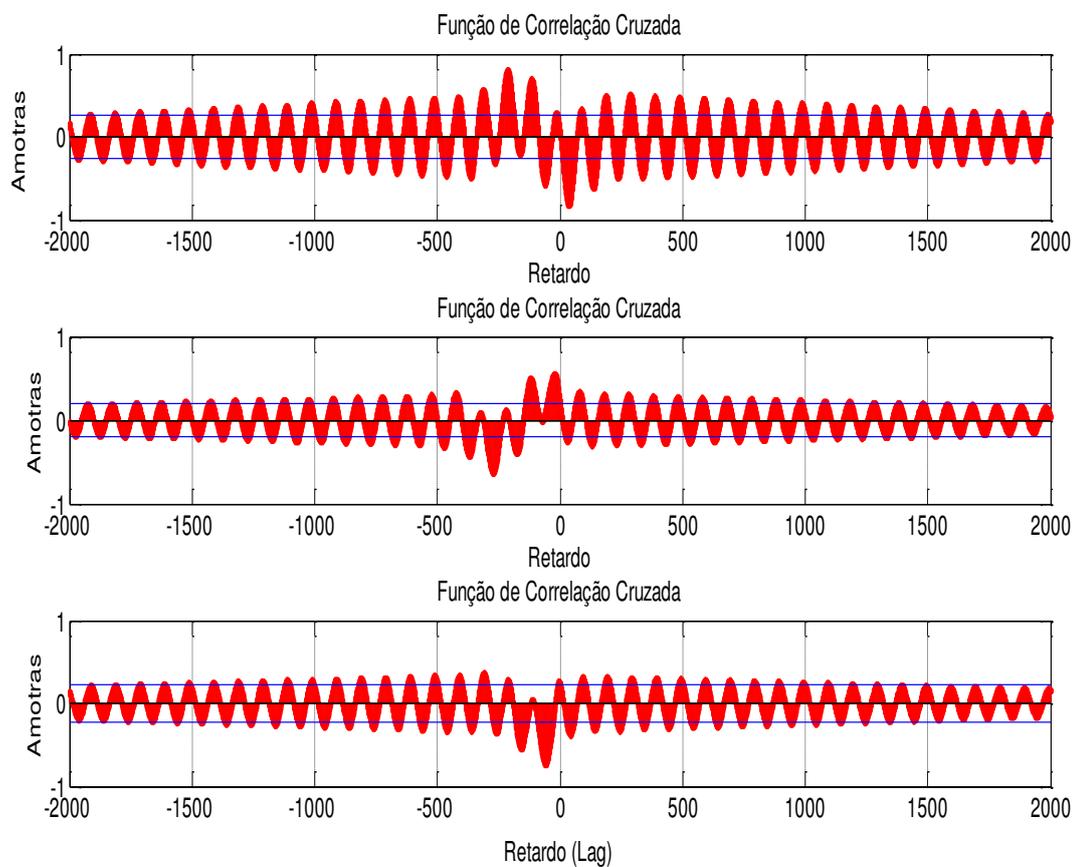


Figura 4.10 - Função de correlação cruzada: Entrada u_1 versus entrada u_2 ; entrada u_1 versus entrada u_3 ; entrada u_2 versus entrada u_3 . Sinal perturbador onda quadrada.

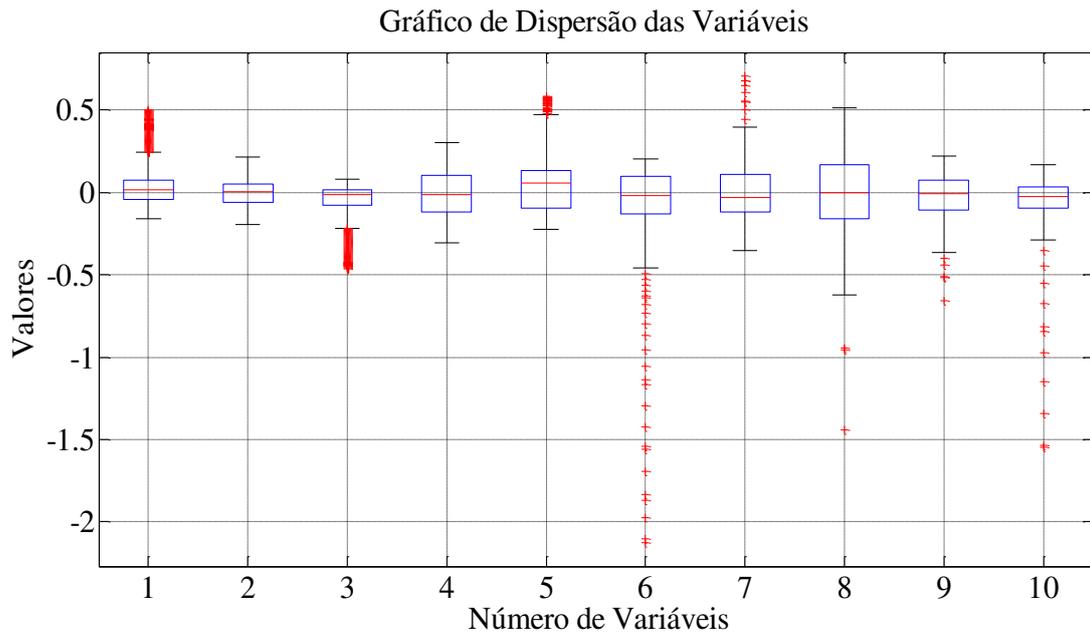


Figura 4.11 - Gráfico de dispersão das variáveis do sistema. Sinal perturbador senoidal.

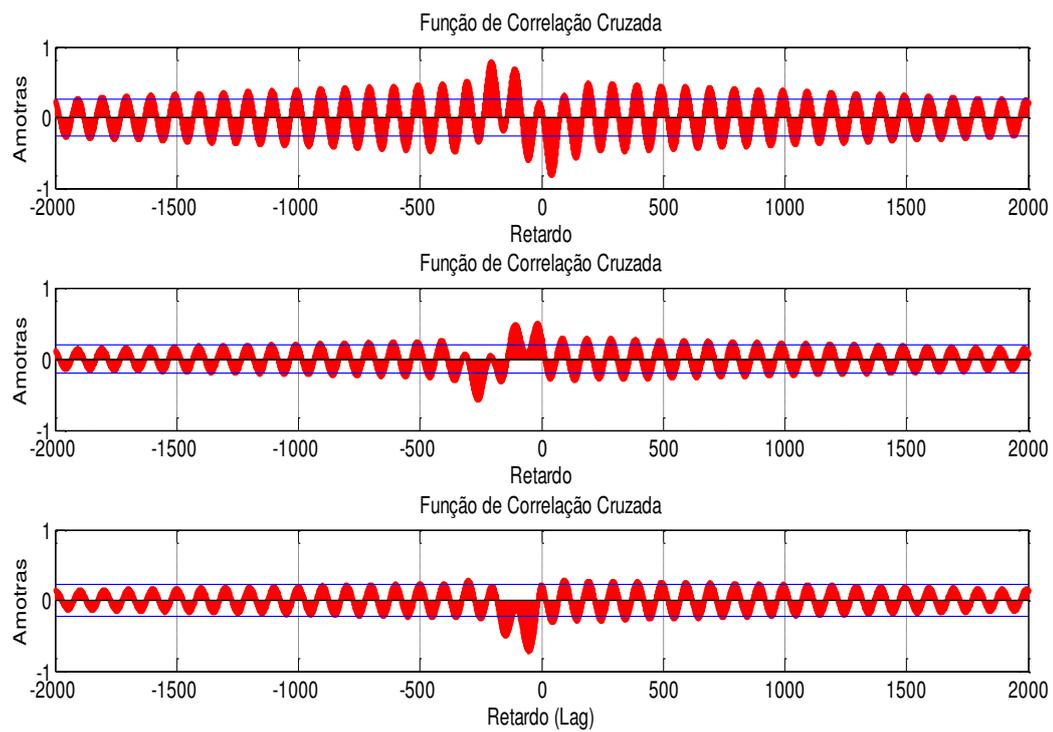


Figura 4.12 - Função de correlação cruzada: Entrada u_1 versus entrada u_2 ; entrada u_1 versus entrada u_3 ; entrada u_2 versus entrada u_3 . Sinal perturbador senoidal.

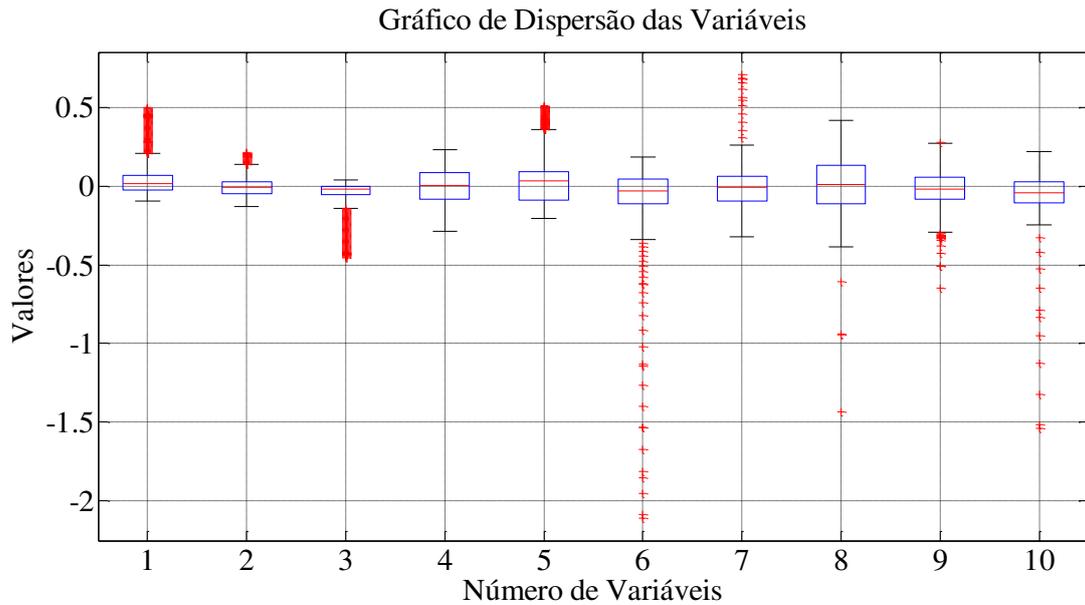


Figura 4.13 - Gráfico de dispersão das variáveis do sistema. Sinal perturbador dente de serra.

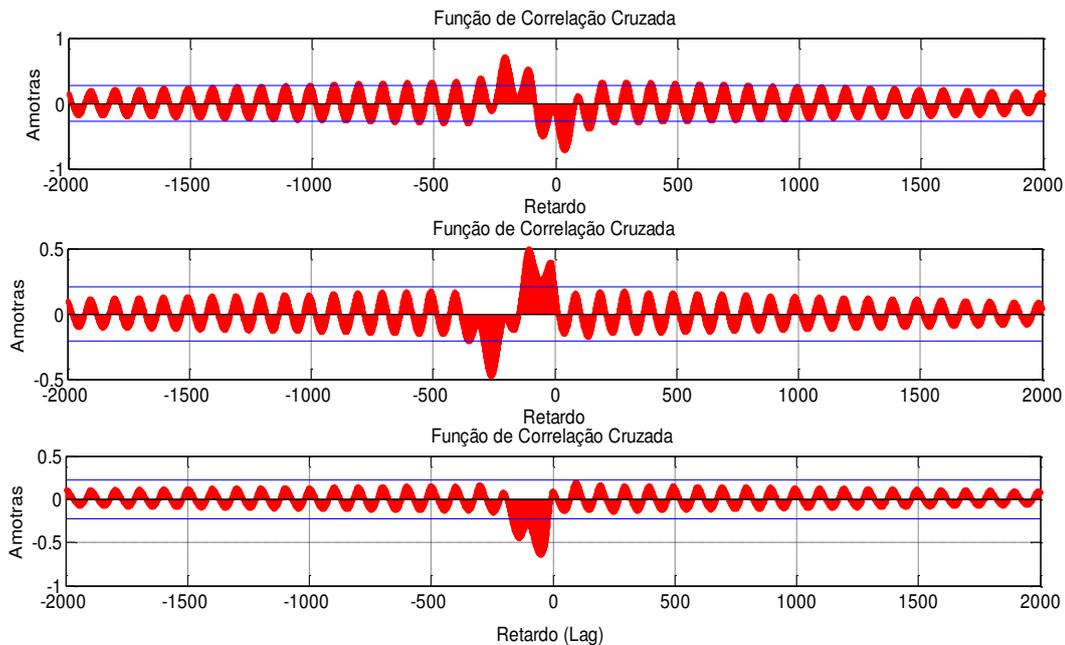


Figura 4.14 - Função de correlação cruzada: Entrada u_1 versus entrada u_2 ; entrada u_1 versus entrada u_3 ; entrada u_2 versus entrada u_3 . Sinal perturbador dente de serra.

Analisado os gráficos de valores das variáveis, percebe-se que o gráfico de dispersão para o sinal de onda quadrada apresenta um grau moderado de dispersão dos valores, já o que o gráfico de dispersão para o sinal senoidal, os valores já apresentam uma dispersão maior e finalmente o gráfico de dispersão referente ao sinal triangular, o nível de dispersão dos valores é semelhante ao gráfico de dispersão do sinal senoidal; ao analisar o gráfico de correlação cruzada da Figura 4.12 tendo como ponto de interesse (de estudo) a amostra zero percebe-se que uma alteração em u_1 altera diretamente u_3 , mas não altera muito u_2 , a correlação entre u_2 e u_3 é tida como moderada, já na Figura 4.13 uma alteração em u_1 há mudanças fortes em u_3 e moderada em u_2 , a correlação

entre u_2 e u_3 é tida como fraca, já no gráfico da Figura 4.14 u_1 é moderadamente correlacionada com u_2 e fortemente com u_3 e a correlação entre u_2 e u_3 é tida como fraca. Pode-se concluir que o sinal para y_1 pode ser uma onda quadrada como uma também senoidal, para y_2 o sinal vencedor é um sinal senoidal, e para a variável y_7 , pode-se perturbar com qualquer um dos sinais de teste.

4.5.1.2 Amplitude do sinal perturbador

Esta escolha deve ser feita de maneira arbitrária, mas não excedendo 25% do valor do *set-point* da malha fechada, sempre respeitando as restrições e especificações da planta.

4.5.1.3 Frequência do sinal perturbador

A frequência do sinal perturbador está diretamente associada ao tempo de estabelecimento (assentamento) da saída em frente ao sinal de referência da malha (ponto de operação), logo a frequência a ser escolhida deve estar próxima da frequência correspondente a $f_s = \frac{1}{T_s}$, onde T_s é o tempo de assentamento. Para o estudo de caso temos os resultados dispostos na Tabela 4.6.

Tabela 4.6: Parâmetros para escolha da frequência do sinal perturbador, ponto de operação sendo zero.

Malha de controle	Tempo de assentamento (s)	Frequência do sinal (Hz)
1	1400	0,000714
2	1250	0,0008
3	900	0,00011

4.5.1.4 Mudanças operacionais

O ponto de operação de um processo pode ser determinado pelas restrições impostas ao processo, quer seja restrição nas entradas quer seja restrições nas saídas. No caso da fracionadora de óleo pesado as restrições são nas variáveis manipuladas pelo controlador (entrada da planta) $u_n = 0,5 \pm 0,05, n = 1, 2 \text{ e } 3$. O experimento consiste em determinar a faixa de operação do processo, em outras palavras, determinar o valor de *set-point* por malha que leve a violação do valor superior da entrada desta malha, e conseqüentemente a saída em malha fechada deixa de seguir a referência, e o valor de *set-point* por malha que leve a violação do limite inferior de entrada daquela malha em estudo, por se tratar de um modelo descrito por funções de transferências para coluna fracionadora os *set-points* mínimos serão zero e por questão física, pois a vazão torna-se negativa. Os valores encontrados em simulação estão dispostos na Tabela 4.7. Quando a planta está operando fora da janela de operação a saída não consegue seguir a referência. Na Tabela 4.8 são apresentados os autovalores do modelo PCA para seis pontos de operação distintos.

Percebe-se pela análise da Tabela 4.8 que a primeira metade da janela de operação oferece muita informação, já a segunda metade não oferece informação relevante visto que os valores numéricos dos componentes principais estão próximos de zero, não contribuindo muito para o modelo PCA.

Tabela 4.7: Faixa de operação da planta.

Malha	Referência mínima	Referência máxima
1	0	4,4
2	0	4,4
3	0	4,4

Tabela 4.8: Autovalores do modelo PCA para diferentes pontos de operação da planta.

Autovalor	P.O.* [000]	P.O. 2 (1/1/1)	P.O. 3 (2/2/2)	P.O. 4 (3/3/3)	P.O. 5 (4/4/4)	P.O. 6 (4.4/4.4/4.4)
Autovalor 1	6,2687	7,7564	8,2250	8,4011	8,2191	7,8445
Autovalor 2	2,1551	1,9146	1,6685	1,4910	1,5319	1,1425
Autovalor 3	1,0955	0,1994	0,0589	0,0654	0,2239	0,9921
Autovalor 4	0,3365	0,0870	0,0237	0,0304	0,0191	0,0148
Autovalor 5	0,0752	0,0316	0,0166	0,0085	0,0042	0,0038
Autovalor 6	0,0436	0,0056	0,0045	0,0022	0,0010	0,0010
Autovalor 7	0,0158	0,0026	0,0017	0,0008	0,0005	0,0005
Autovalor 8	0,0142	0,0019	0,0006	0,0003	0,0002	0,0001
Autovalor 9	0,0041	0,0006	0,0005	0,0002	0,0001	0,0001
Autovalor 10	0,0002	0,0002	0,0002	0,0001	0,0	0,0

*P.O. Ponto de operação da planta (referência/*set-point*).

4.5.1.5 Janela de atualização do modelo PCA

Neste tópico discute-se a questão que ΔT será usado para computar o modelo PCA inicial, que será rico em informações sobre o comportamento da planta, bem como de base de cálculo dos limites de controles das cartas estatísticas, que serão testados pelas estatísticas τ^2 e SPE provenientes no diagnosticador *on-line*. Bem como o número de amostras necessárias para um PCA confiável.

A ideia é que fosse usada uma janela de tempo infinita, como não é possível, deve-se saber em que instantes os autovalores praticamente não sofrem modificações, portanto o experimento consiste em iniciar o modelo PCA com uma janela de tempo grande e vir diminuindo esta janela até encontrar variações consideráveis nos valores dos autovalores do sistema, logo a janela de tempo anterior é escolhida como a janela de tempo em que deve ser rodado o PCA inicial, bem como atualizar o PCA quando utilizado no diagnóstico de falhas *on-line*.

Com este intuito foram realizadas várias simulações na planta de estudo, os resultados obtidos podem ser visualizados na Tabela 4.9.

Analisando a Tabela 4.9, pode ser percebido que da janela de 16000 s para a janela de 32000 s a mudança nos PCs é mínima, não sendo de tão relevância, logo a janela ideal para atualização do modelo PCA será a janela de 0 a 16000 segundos.

4.5.1.6 Taxa de amostragem

A taxa de amostragem determina o número de amostra coletas para o modelo PCA é definida levando em consideração as limitações computacionais (memória para guardar

os dados, esforço computacional) tendo em vista que quanto mais amostras melhor o modelo PCA, mas por outro lado o esforço computacional e de memória para o acúmulo e processamento dos dados; cabe ressaltar também as limitações por parte da instrumentação da planta. Para o projeto do modelo PCA cabe verificar quais alterações sofridas no modelo para várias taxas de amostragens diferentes, analisando as variações nos componentes principais.

Tabela 4.9: Componentes principais para diferentes janelas de atualização do modelo PCA.

PCs*	Janela 0- 2e ³ s	Janela 0- 4e ³ s	Janela 0- 8e ³ s	Janela 0-16e ³ s	Janela 0-32e ³ s	Janela 0- 4e ⁴ s	Janela 0- 5e ⁴ s	Janela 0- 6e ⁴ s
PC 1	6,1800	6,2400	6,2687	6,2839	6,2903	6,2910	6,2912	6,2910
Var (%)	-	0,9709	0,4599	0,2425	0,1018	0,0111	0,0032	-0,0032
PC 2	2,3247	2,2058	2,1551	2,1316	2,1200	2,1177	2,1157	2,1143
Var (%)	-	-5,1146	-2,2985	-1,0904	-0,5442	-0,1085	-0,0944	-0,0662
PC 3	0,9762	1,0645	1,0955	1,1083	1,1141	1,1152	1,1160	1,1166
Var (%)	-	9,0453	2,9122	1,1684	0,5233	0,0987	0,0717	0,0538
PC 4	0,3621	0,3442	0,3365	0,3331	0,3318	0,3318	0,3318	0,3320
Var (%)	-	-4,9434	-2,2371	-1,0104	-0,3903	0,0000	0,0000	0,0603
PC 5	0,0786	0,0764	0,0752	0,0748	0,0748	0,0749	0,0750	0,0752
Var (%)	-	-2,7990	-1,5707	-0,5319	0,0000	0,1337	0,1335	0,2667
PC 6	0,0381	0,0356	0,0346	0,0342	0,0342	0,0343	0,0344	0,0346
Var (%)	-	-6,5617	-2,8090	-1,1561	0,0000	0,2924	0,2915	0,5814
PC 7	0,0173	0,0162	0,0158	0,0156	0,0156	0,0156	0,0156	0,0157
Var (%)	-	-6,3584	-2,4691	-1,2658	0,0000	0,0000	0,0000	0,6410
PC 8	0,0162	0,0149	0,0142	0,0138	0,0137	0,0137	0,0137	0,0137
Var (%)	-	-8,0247	-4,6980	-2,8169	-0,7246	0,0000	0,0000	0,0000
PC 9	0,0043	0,0041	0,0041	0,0045	0,0052	0,0056	0,0060	0,0065
Var (%)	-	-4,6512	0,0000	9,7561	15,5556	7,6923	7,1429	8,3333
PC 10	0,0002	0,0002	0,0002	0,0003	0,0003	0,0004	0,0004	0,0004
Var (%)	-	0,0000	0,0000	50,0000	0,0000	33,3333	0,0000	0,0000

*PCs, do inglês *Principal Components*, Componentes Principais.

Para a fracionadora de óleo cru, com o controlador preditivo ativo, a taxa de amostragem é determinada pelo controlador, devendo seu valor ser igual ao intervalo de controle do controlador preditivo (a taxa de amostragem do controlador constitui o limitante inferior). Foram feitos testes para diferentes taxas de amostragem, de modo a contemplar toda janela de operação desde o transitório de cada malha até uma longa faixa do regime estacionário. Os resultados obtidos encontram-se dispostos na Tabela 4.10. Para cada teste foi observado o comportamento das saídas controladas visto que alterar a taxa de amostragem do sistema é alterar o intervalo do controlador preditivo, em outras palavras, para cada teste é necessário uma re-sintonia do controlador.

Analisando a Tabela 4.10 percebe-se que os seis primeiros PCs descrevem com fidelidade o sistema. Depois de realizado o projeto do PCA inicial (padrão tido como

condição normal de operação), computa-se as cartas de controle das estatísticas τ^2 e SPE, que servirão de modelo padrão de comparação com as cartas estatísticas τ^2 e SPE geradas pelo diagnosticador *on-line* implantado na planta/processo a cada instante de tempo, ao fim de cada atualização do PCA é gerado um relatório do diagnosticador de falhas.

Tabela 4.10: Autovalores do modelo PCA para diferentes taxas de amostragem.

Autovalor	Taxa (1 s)	Taxa (2 s)	Taxa (4 s)	Taxa (5 s)
Autovalor 1	3,4874	5,8875	6,2602	6,5696
Autovalor 2	2,7060	2,1848	2,1573	1,9087
Autovalor 3	1,4102	1,0076	1,1050	1,1399
Autovalor 4	1,1197	0,5192	0,3343	0,2613
Autovalor 5	0,7911	0,2115	0,0750	0,0594
Autovalor 6	0,2978	0,1371	0,0343	0,0296
Autovalor 7	0,1420	0,0334	0,0156	0,0203
Autovalor 8	0,0334	0,0118	0,0139	0,0078
Autovalor 9	0,0082	0,0065	0,0040	0,0032
Autovalor 10	0,0041	0,0006	0,0004	0,0002

4.6 Análise PCA aplicada à coluna da *Shell*

Para o desenvolvimento do modelo PCA, dados de operação normal do sistema com o controlador ativo foram coletados com uma taxa de amostragem de 4 segundos. Visando reduzir a correlação cruzada entre as entradas (fator que influencia a qualidade dos dados para o modelo PCA), o sistema foi perturbado aplicando um sinal onda quadrada de amplitude $-0,25$ a $0,25$, aos *set-points* com frequências $0,00075$, $0,001$ e $0,002$ Hz, respectivamente. A resposta do sistema a tal perturbação é apresentadas nas Figuras 4.15, 4.16 e 4.17.

As amostras foram organizadas em uma matriz na qual cada coluna correspondia a uma variável do processo (manipulada, dependente ou controlada e independente ou monitorada) e cada linha correspondia ao valor dessa variável em determinado instante de tempo. Os autovalores e autovetores da matriz de covariância estão dispostos nas Tabelas 4.11 e 4.12.

Para o conjunto de dados não correlacionados, os componentes principais são ilustrados na Figura 4.18, bem como a variância percentual dos componentes, já na Figura 4.19 é apresentado a variância percentual acumulada, tais gráficos sugerem que o processo pode ser descrito somente pelos primeiros seis componentes principais, uma vez que os demais componentes têm autovalores praticamente nulos.

Tabela 4.11: Autovalores da matriz de correlação de dados do processo.

λ_1	λ_2	λ_3	λ_4	λ_5	λ_6	λ_7	λ_8	λ_9	λ_{10}
5,2792	2,2671	1,6513	0,5268	0,1666	0,0720	0,0193	0,0122	0,0038	0,0017

Tabela 4.12: Autovetores da matriz de correlação de dados do processo.

e_1	e_2	e_3	e_4	e_5	e_6	e_7	e_8	e_9	e_{10}
-0,1811	-0,4173	0,4908	-0,2285	0,1593	-0,0526	0,2682	-0,0129	0,3159	0,54
-0,3270	0,3028	0,0932	0,6124	0,1442	-0,349	0,4062	0,1290	-0,2549	0,1697
0,3417	0,2342	-0,3916	0,0171	-0,108	0,1104	-0,0644	0,4160	0,0876	0,6825
0,3816	0,2035	0,1034	0,2855	-0,570	-0,5508	-0,0528	-0,1564	0,2531	-0,0130
-0,1067	0,3049	0,6417	0,1356	-0,404	0,3662	-0,3024	0,2766	-0,0161	-0,0050
0,2742	0,4575	0,1380	-0,3872	-0,242	0,0680	0,5710	-0,3580	-0,1650	0,0383
0,3469	-0,2811	0,0324	0,5446	0,1027	0,5747	0,1425	-0,3564	-0,0802	0,0921
0,3772	-0,2077	0,2774	-0,1420	0,1914	-0,2388	-0,2149	0,1203	-0,7415	0,1158
0,4208	-0,0454	0,1607	0,0229	0,2458	0,0208	0,3829	0,5857	0,2574	-0,4216
0,2676	0,4599	0,2274	0,0735	0,5351	-0,1826	-0,3543	-0,3106	0,3376	0,0641

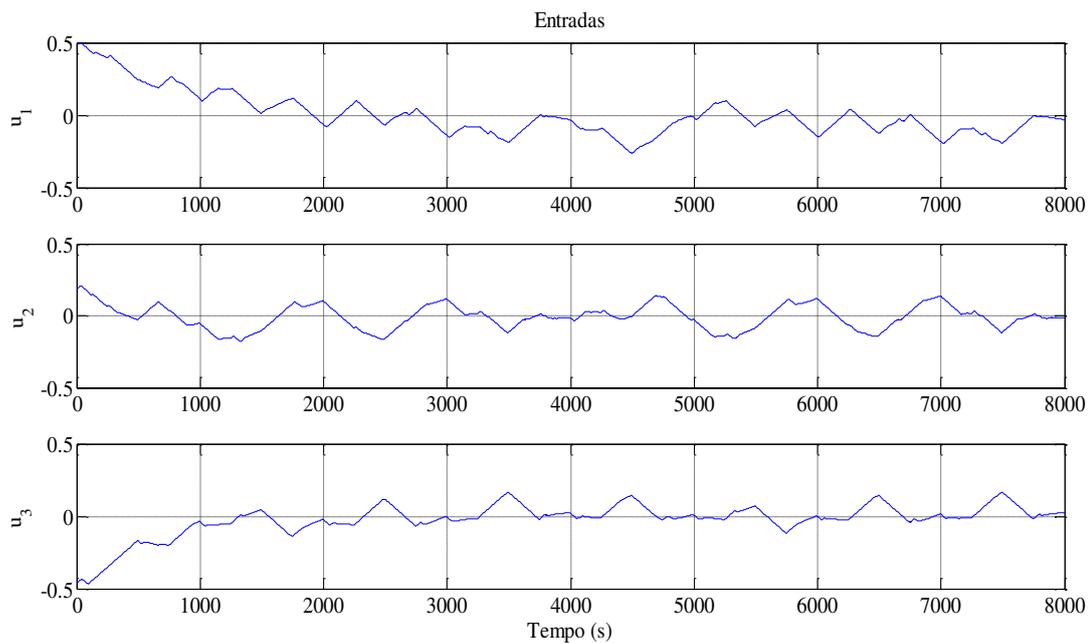


Figura 4.15 - Entradas da coluna perturbadas para geração do modelo PCA

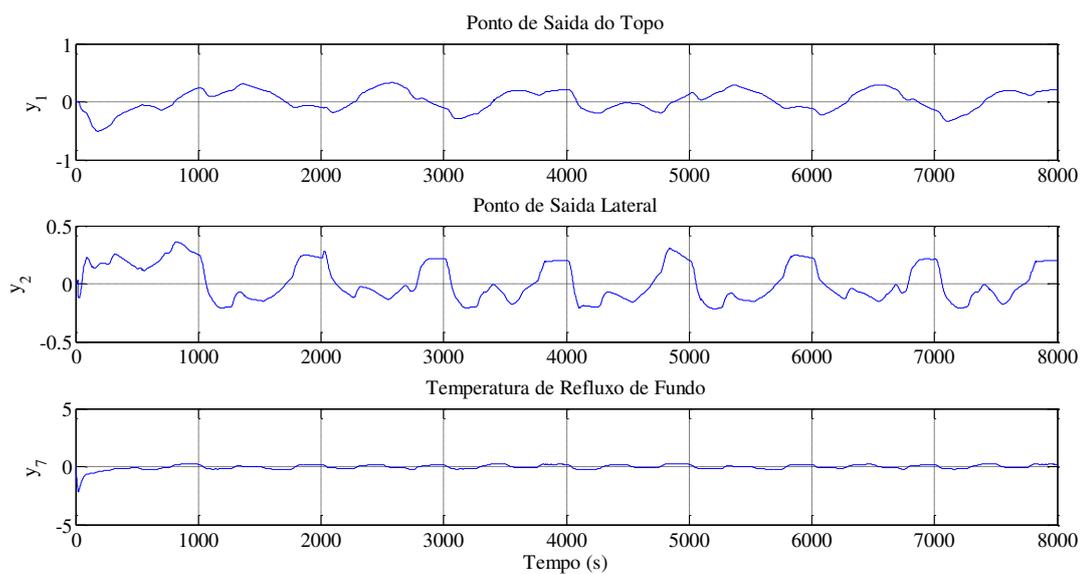


Figura 4.16 - Saídas controladas da fracionadora na presença da perturbação para gera o modelo PCA.

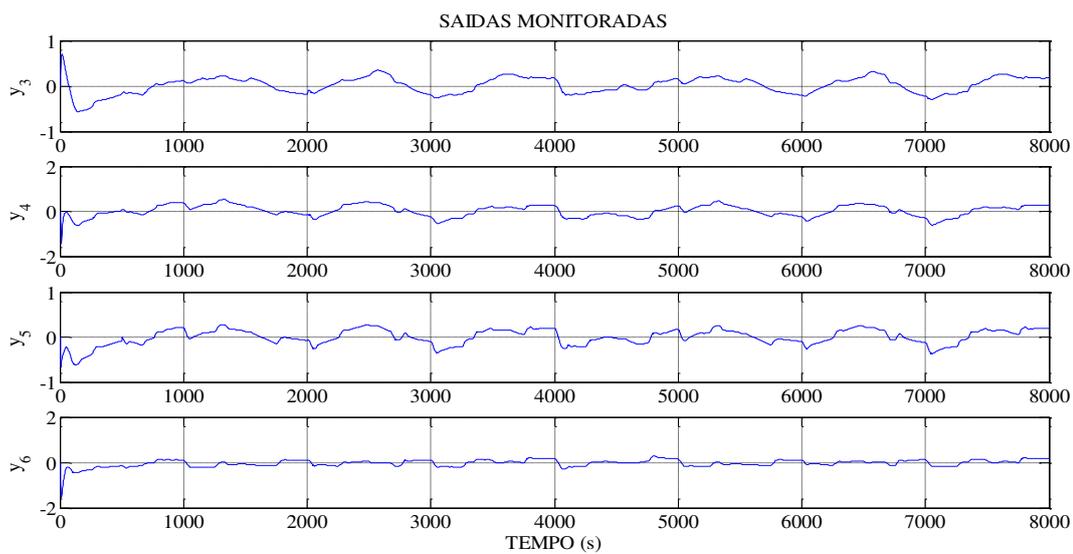
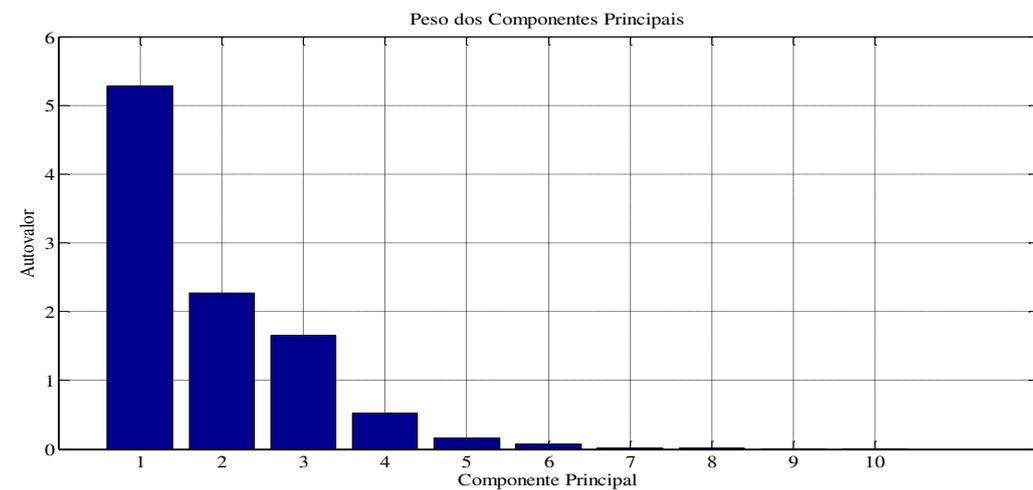
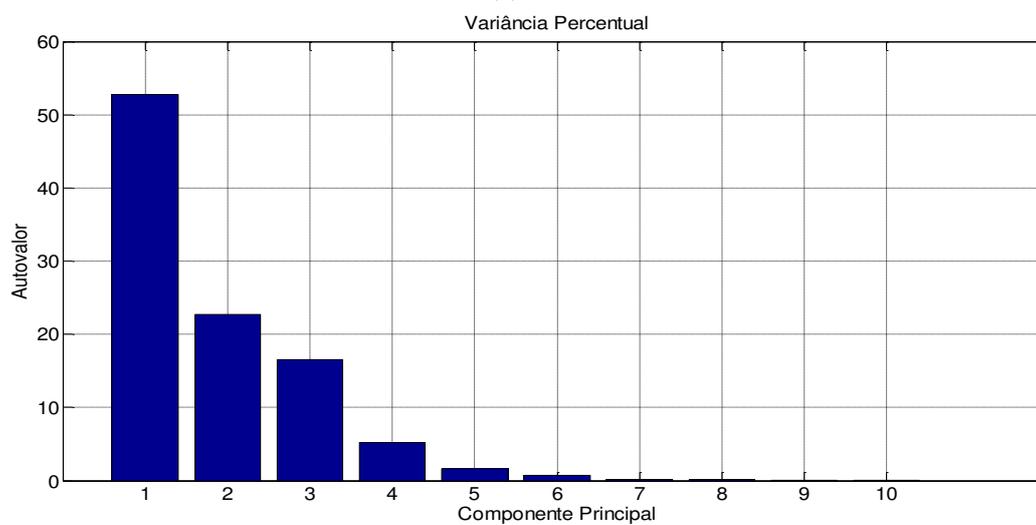


Figura 4.17 - Saídas monitoradas da fracionadora na presença da perturbação para gera o modelo PCA.



(a)



(b)

Figura 4.18: (a) - Autovalor característico para cada componente principal; (b) - Variância percentual dos componentes principais.

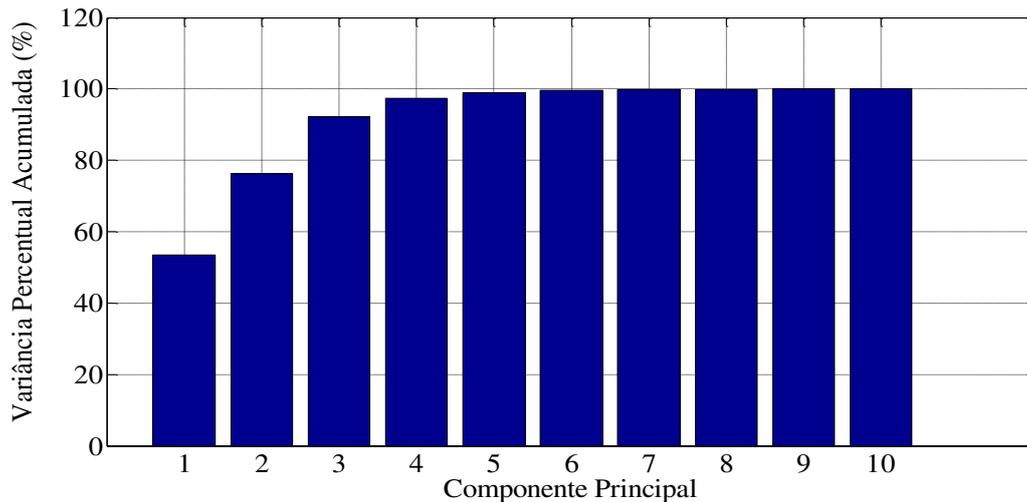


Figura 4.19 - Variância percentual acumulada.

Conforme o gráfico de variância percentual acumulada pode-se selecionar os seis primeiros componentes percentuais para representar o sistema, visto que estes representam 99,6425 % da variabilidade total, que corresponde às variáveis ligadas diretamente ao controle. Tal escolha nos permite concluir que o diagnóstico de falhas baseado em PCA da coluna *Shell* dispensa a utilização de quatro sensores (y_3 , y_4 , y_5 , y_6). As variáveis associadas a estes sensores, destarte não contribuirão para o diagnóstico de falhas, proporcionam informações importantes sobre a energia envolvida nas trocas térmicas do processo.

4.7 Monitoramento de falhas na coluna fracionadora de óleo cru

Nesta seção serão apresentados os resultados da metodologia descrita na seção 4.3, para falhas simples e falhas múltiplas, nos sensores e atuadores. As falhas consideradas no presente texto são as abruptas aditivas, uma vez que, segundo Simani (2002), são mais perigosas e usuais, causando mais danos ao processo que as falhas incipientes. Além disso, as falhas abruptas, devido a sua forma, são mais fáceis de detectar que as falhas incipientes, que produzem um pequeno efeito nos resíduos.

O cenário de falhas é descrito pelas Tabelas 4.13 e 4.14 onde foram simuladas falhas simples e falhas múltiplas, nos instrumentos do processo.

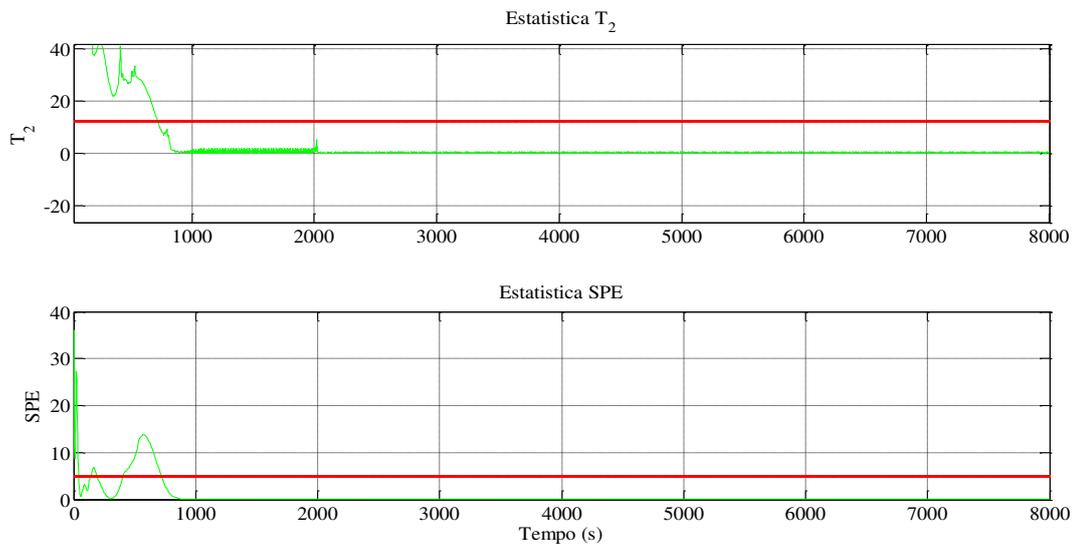
Tabela 4.13: Cenário de falhas 1- Falhas simples.

Situação	Componente	Tipo de falha	Amplitude da falha	Tempo (s)
1	Atuador 1 (u_1)	Abrupta Permanente, (degrau)	+60% no valor de operação (v. op.)	3000 – 8000
2	Sensor 1 (y_1)	Abrupta, permanente (degrau)	+60% no valor de operação (v. op.)	3000 – 8000
3	Sensor 6 (y_6)	Abrupta, permanente (degrau)	+60% no valor de operação (v. op.)	3000 – 8000

Tabela 4.14: Cenário de falhas na fracionadora 2- Falhas múltiplas.

Situação	Componente	Tipo de falha	Tempo (s)	Amplitude da falha
1	Sensor 1 (y_1);	Abrupta: degrau.	3000 – 8000	+60% no v.op. (y_1);
	Sensor 7 (y_7).	Abrupta: degrau.	3000 – 8000	+70% no v.op. (y_7);
2	Atuador 1 (u_1);	Abrupta: degrau.	3000 – 8000	+60% no v.op. (u_1);
	Sensor 2 (y_2);	Abrupta: degrau.	5000 – 8000	+70% no v.op. (y_2);
	Sensor 7 (y_7).	Abrupta: degrau.	6500 – 8000	+80% no v.op. (y_7)

As cartas de controle (estatística T^2 ou τ^2 e SPE) para a coluna fracionadora de óleo pesado em condições normais são apresentadas na Figura 4.20, os limites de controle foram obtidos conforme descrição na seção 4.3.2, e são: $T_{lim}^2 = 12,6504$ e $SPE_{lim} = 4,9587$ onde ambos foram calculados para um nível de confiança de controle de 95%.

Figura 4.20 - Estatística SPE e τ^2 para a o processo operando em condições normais.

Na Figura 4.21 pode ser observada a variação dos parâmetros da planta, no qual é traçado a variância das seis principais variáveis do processo (os seis componentes principais o qual representa 99,6425 % do processo).

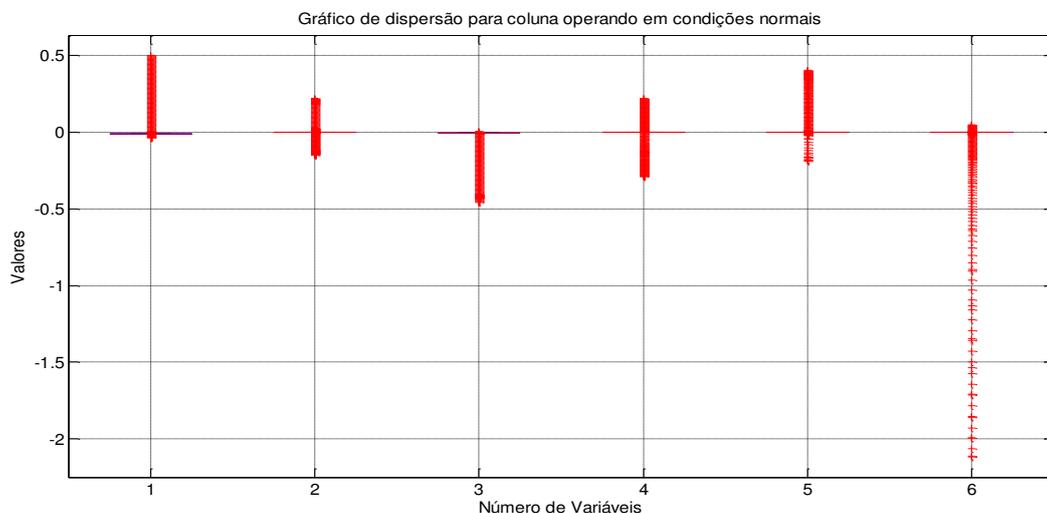


Figura 4.21 - Boxplot para a coluna fracionadora de óleo cru operando em condições normais.

A falha nos atuadores de uma planta modifica o efeito do controlador sobre o processo, e também pode causar o desvio do processo para além dos limites aceitáveis, muitas vezes pode ser mascarada pelo controlador, pesando nisto foi simulado uma falha na entrada u_1 do processo conforme descrição da situação 1 do cenário 1 (Tabela 4.13). Na Figura 4.22 ilustra-se a detecção da respectiva falha pela estatística de *Hotelling* e pela estatística *Q*.

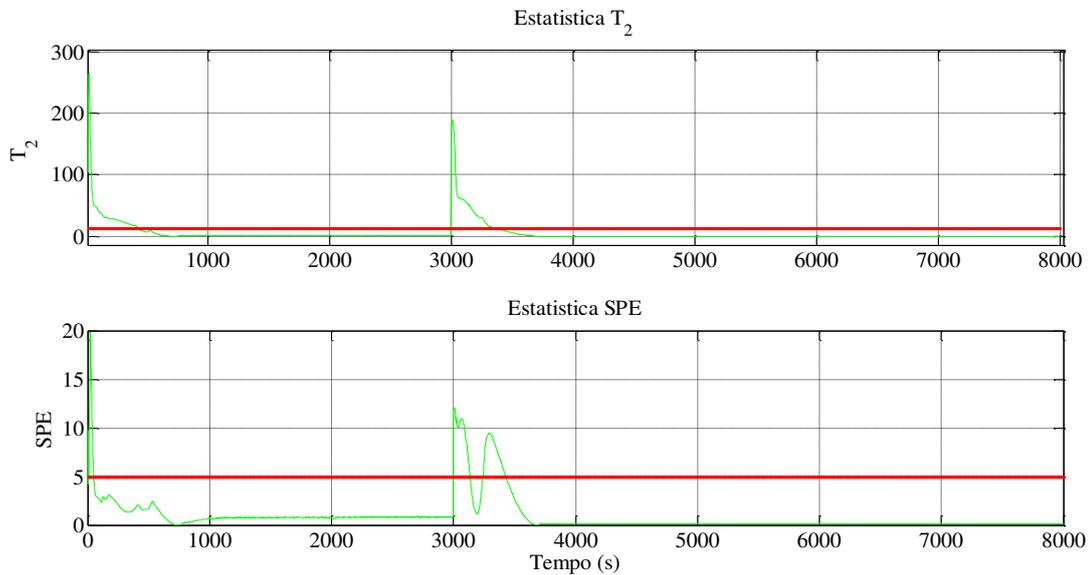


Figura 4.22 - Estatística SPE e τ^2 para a o processo operando em condições de falhas (falha no atuador 1, u_1).

Na Figura 4.23 ilustra-se a falha no atuador e o comportamento das variáveis controladas do sistema, onde se pode ver que o controlador preditivo agiu sobre a falha e conseguiu controlar o sistema, pois ele é o tipo controle por *set-point* e não por bandas, este tipo de controlador tem mais influência no modelo PCA do que o por bandas.

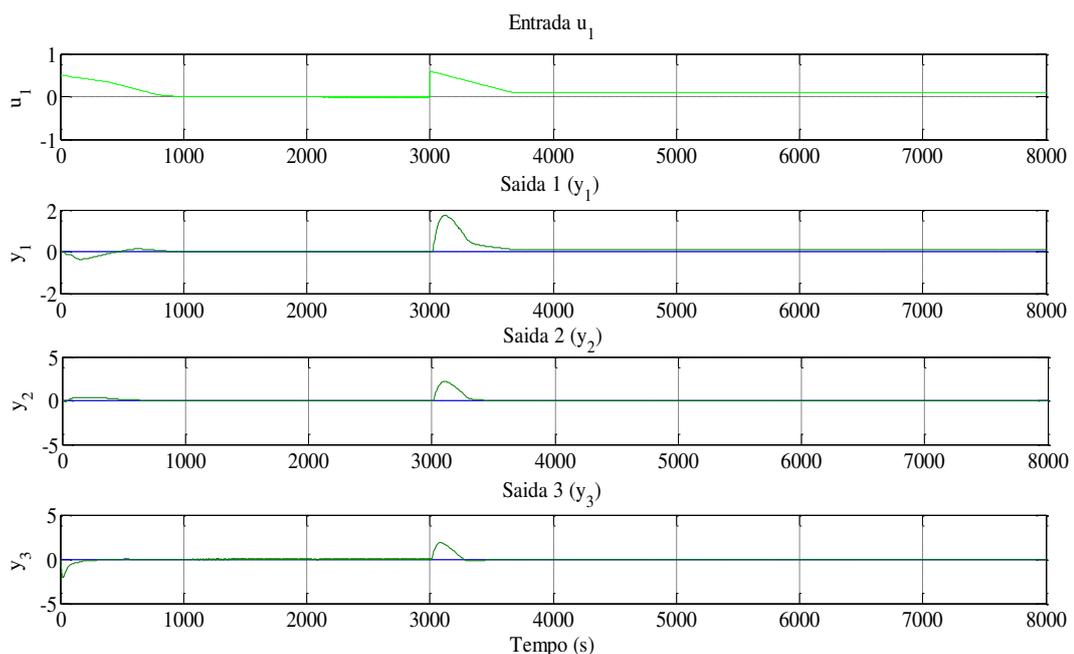


Figura 4.23 - Entrada com falha e saídas controladas (falha em u_1).

Sensores são os elementos utilizados para medição das variáveis do processo. Uma falha nesse elemento leva a uma medição errada da variável medida, podendo levar a uma ação de controle equivocada. Falhas comuns que podem ocorrer em elementos sensores ou instrumentos são a perda do sinal desse equipamento e o aparecimento gradual ou instantâneo de um *off-set* na medição. Ambas as falhas provocam ações de controle equivocadas. A perda do sinal apresenta uma variação brusca que pode ser observada pelo operador, mas em um processo grande, muitas vezes não será vislumbrada com tanta facilidade. Já o aparecimento de um *off-set* no instrumento, principalmente quando gradual, dificulta a percepção por conta do operador.

Com o intuito de verificar o comportamento do processo na presença uma falha em um dos sensores cuja medição é utilizada no controle, foi simulado a situação 2 descrita na Tabela 4.13. A detecção da respectiva falha pelas cartas de controle pode ser visualizada na Figura 4.24.

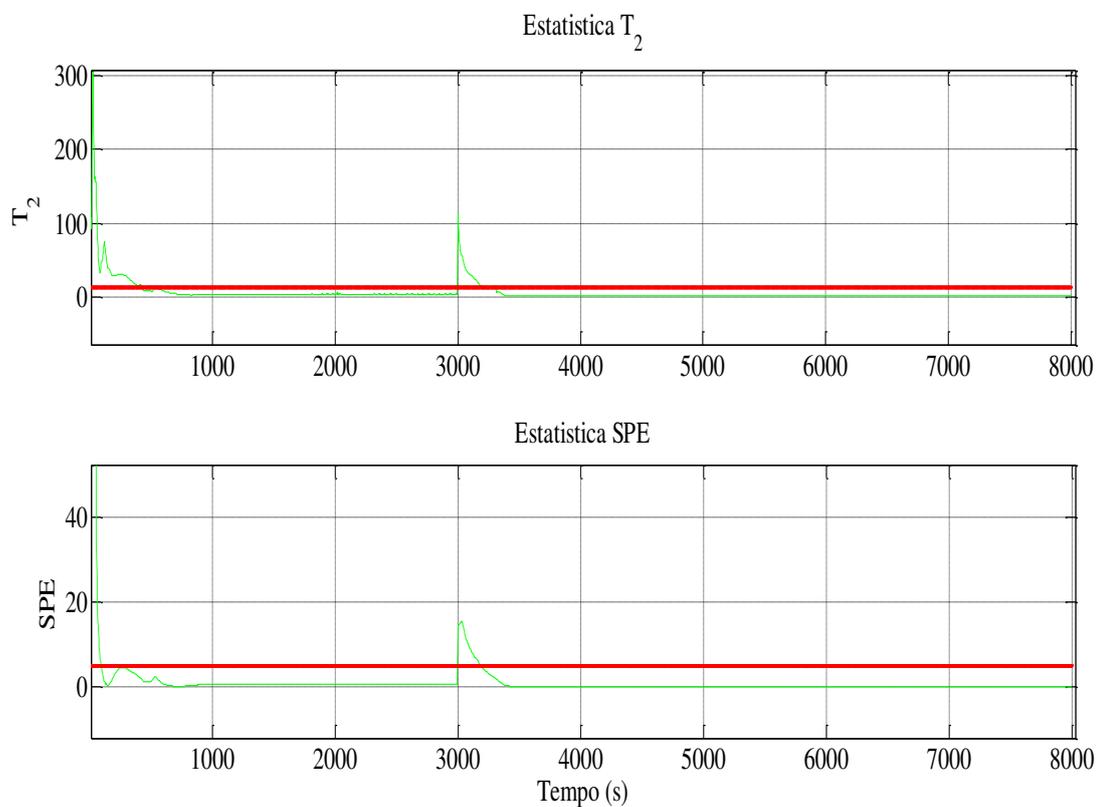
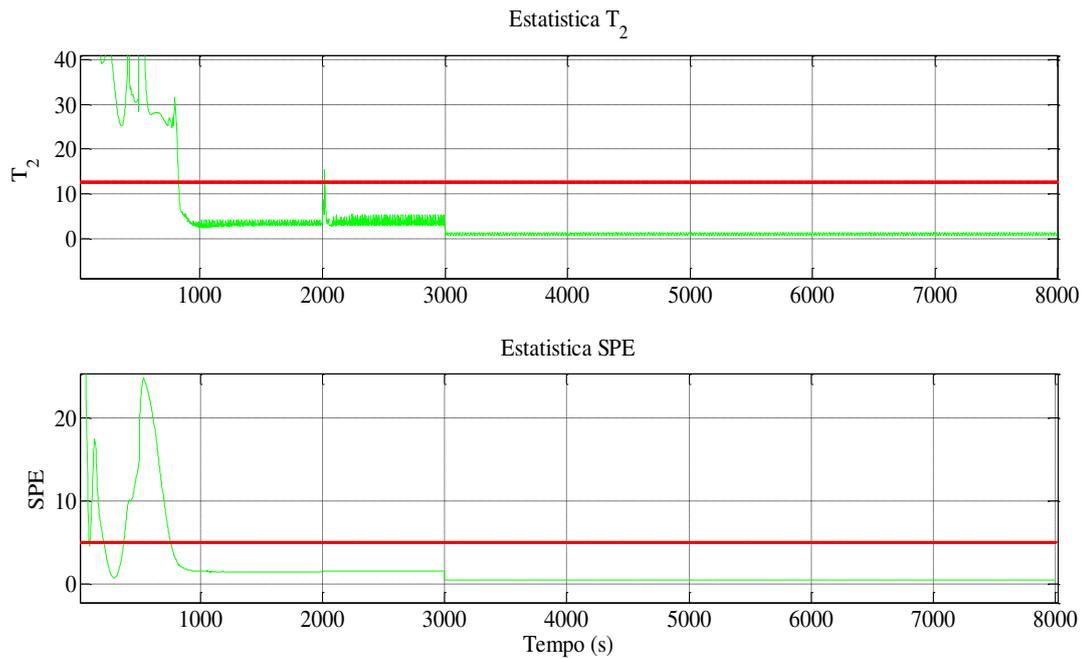
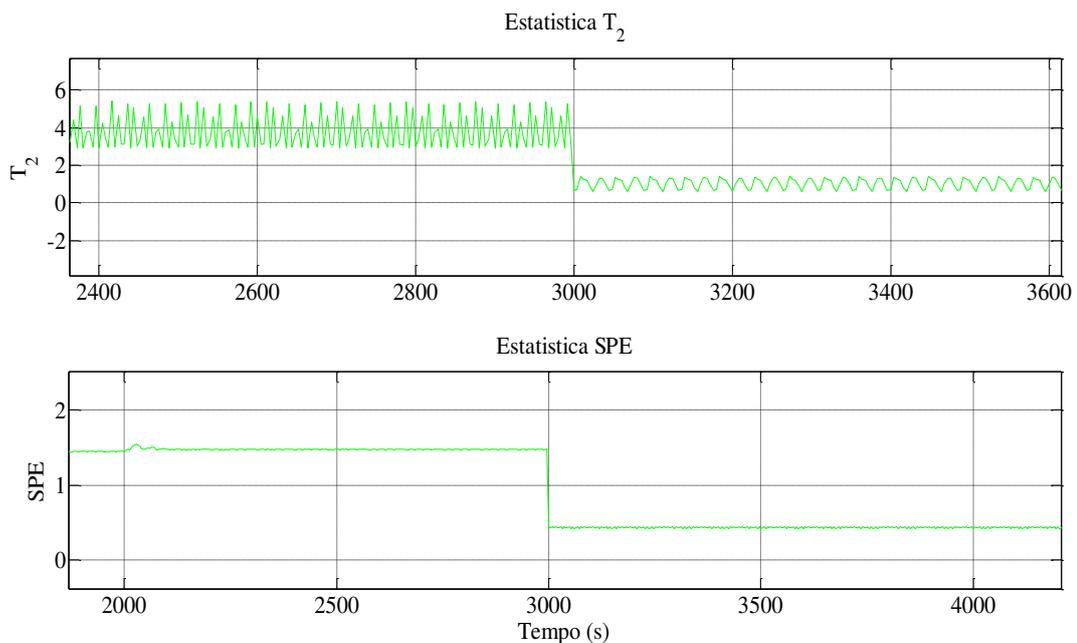


Figura 4.24 - Estatística SPE e τ^2 para o processo operando em condições de falhas (falha no sensor 1, (y_1)).

Da mesma forma que foi observado o comportamento do sistema na presença de uma falha em uma variável controlada, foi emulado no *software* matemático, uma falha em uma entrada monitorada, representando a Situação 3 descrita na Tabela 4.13. As estatísticas T^2 e Q para esta situação são apresentadas na Figura 4.25.



(a)



(b)

Figura 4.25: (a) - Estatística SPE e τ^2 para a o processo operando em condições de falhas (falha no sensor 6, (y_6)); (b) - Estatística SPE e τ^2 para a o processo operando em condições de falhas (falha no sensor 6 (y_6)), zoom no gráfico da Figura 4.25 (a).

A detecção de falhas simples pelas estatísticas é imediata, mesmo com a ação do controlador influenciando no modelo PCA. Pensando em verificar a eficiência das técnicas na detecção de falhas múltiplas nos instrumentos da coluna fracionadora, foram simuladas as duas situações descritas na Tabela 4.14, à detecção pelas cartas de controle podem ser observadas nas Figuras 4.26 e 4.27 para as respectivas situações.

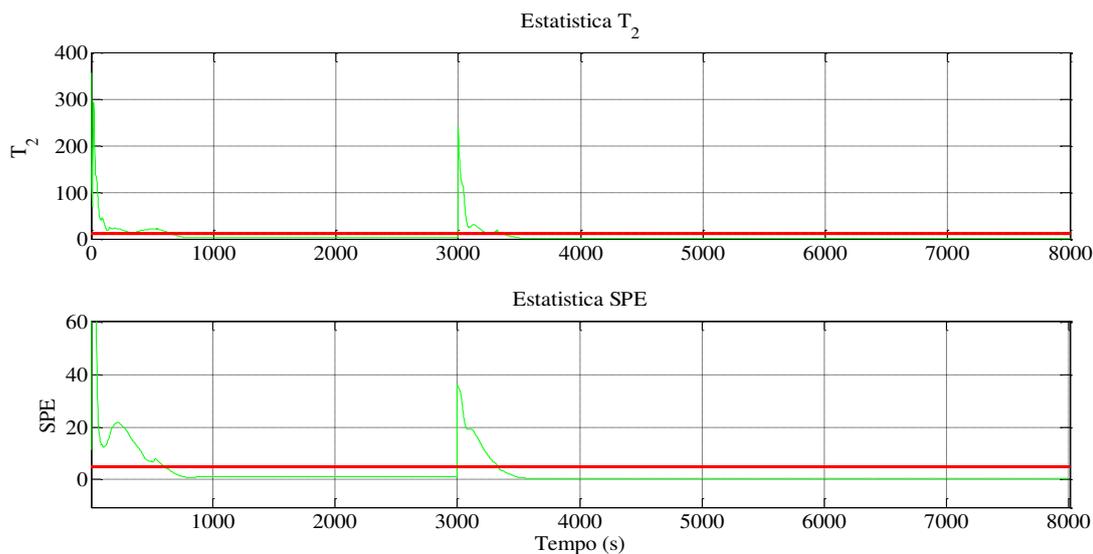


Figura 4.26 - Estatística SPE e τ^2 para o processo operando em condições de falhas múltiplas (Situação 1).

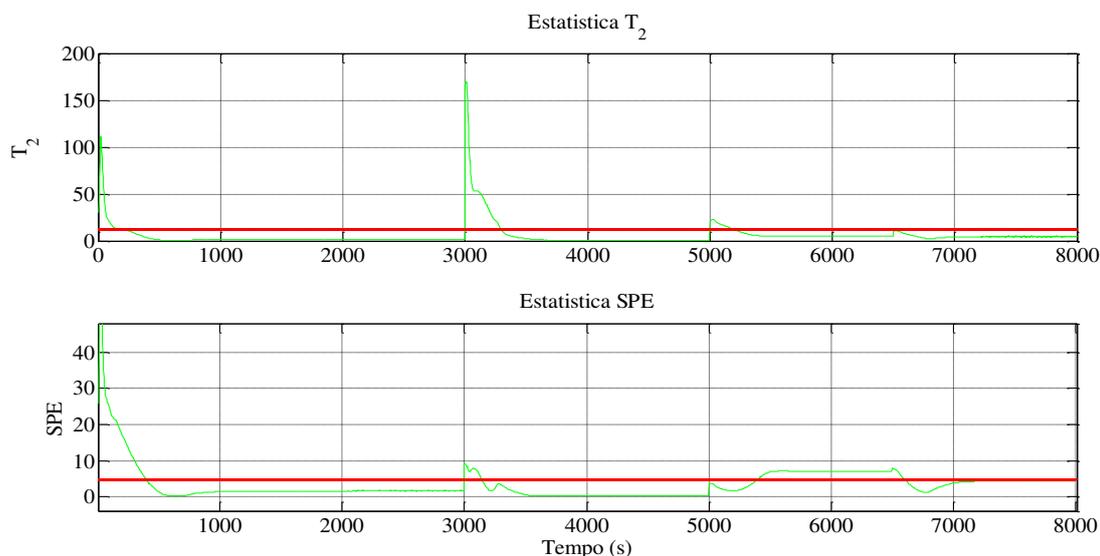


Figura 4.27 - Estatística SPE e τ^2 para o processo operando em condições de falhas múltiplas (Situação 2).

Falhas internas/ estruturais na planta não foram simuladas, pois tais falhas são mais difíceis de fazer um diagnóstico preciso e eficiente.

A identificação de falhas foi realizada para o cenário 2 descrito na Tabela 4.14, na situação 1 temos um caso de falha múltipla simultânea, na Figura 4.28 é apresentado a contribuição dos sensores/atuadores onde as variáveis com maior contribuição, indica os instrumentos defeituosos. Conforme gráfico pode ser identificado que houve falha nos sensores 2 e 7 (y_2 e y_7) e que a contribuição de cada variável corresponde a respectiva amplitude da falha.

Na Figura 4.29 pode ser visualizada a contribuição dos instrumentos defeituosos no caso da ocorrência de uma falha múltipla (Situação 2, Cenário 2, Tabela 4.14) mas não

simultânea, na qual foi interpretada como várias falhas simples, e novamente a contribuição de cada variável corresponde a amplitude da falha aplicada. Como se pode ver pelos gráficos das Figuras 4.28 e 4.29 que a teoria descrita na Seção 4.3.3 é verdadeira.

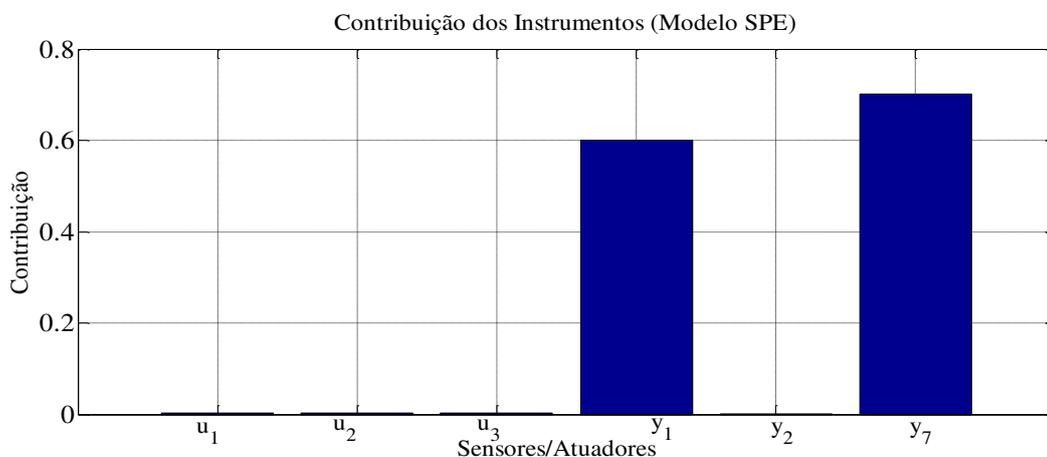


Figura 4.28 - Identificação de falhas na coluna *Shell*, falhas múltiplas simultâneas.

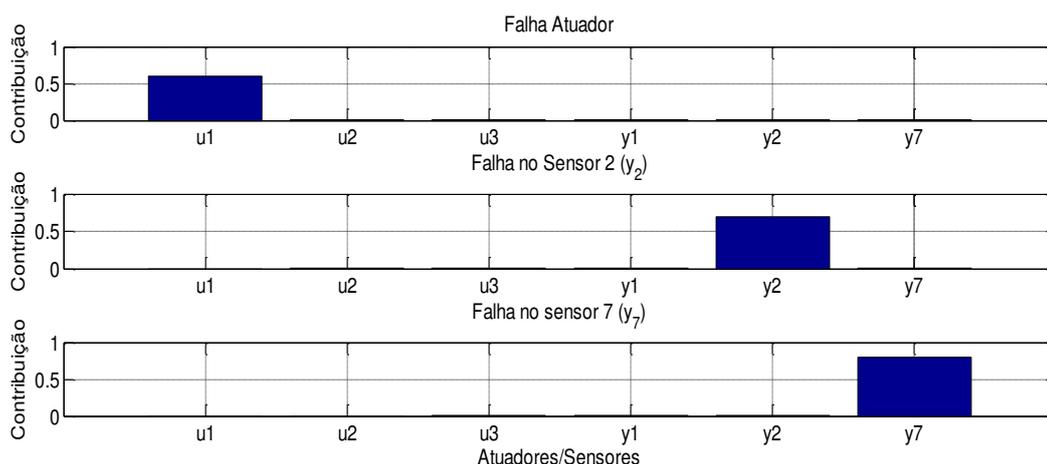


Figura 4.29 - Identificação de falhas na coluna *Shell*, falhas múltiplas não simultâneas.

A eliminação de falhas nos sensores/atuadores é feita com a reconstrução dos sinais, procedimento baseado na amplitude da falha e no vetor de direção da falha conforme descrito na Seção 4.3.4. Quando o sensor que mede o ponto de saída lateral (y_2) e o sensor de temperatura de refluxo do fundo (y_7) estiverem defeituosos a direção da falha é dada pelo vetor $\xi = [0 \ 0 \ 0 \ 1 \ 0 \ 1]$ e a amplitude da falha pode ser obtida fazendo $(x_i(k) - x_i(k - 1))$, onde $x_i(k)$ é a amostra no instante em que houve a falha obtido pelos teste de detecção e $x_i(k - 1)$ é a amostra anterior a falha (amostra normal, sem anomalia), o que corresponde a usar o valor da contribuição da variável para o modelo PCA (Figura 4.28). Os sensores/atuadores após a reconstrução são novamente testados pelas estatísticas multivariadas, com o intuito de verificar se realmente foi sanada a falha, os resultados destes testes para a situação 1 do cenário 2 são apresentadas na Figura 4.30 indicando a retificação de falhas nos sensores devido à reconstrução. A

informação reconstruída alimenta o (s) controlador (es) para manter em operação o processo especificado.

A abordagem de diagnóstico de falhas em sensores/atuadores apresentada, emprega o procedimento em que apenas os equipamentos defeituosos são diagnosticados antes da reconstrução. Deste modo, com esta estratégia, apenas os sensores/atuadores defeituosos são reconstruídos em vez de todos os sensores/atuadores. O diagnóstico dos instrumentos defeituosos antes da reconstrução tem a vantagem de que a reconstrução pode ser realizada somente se existir falha no respectivo sensor/atuador suspeito.

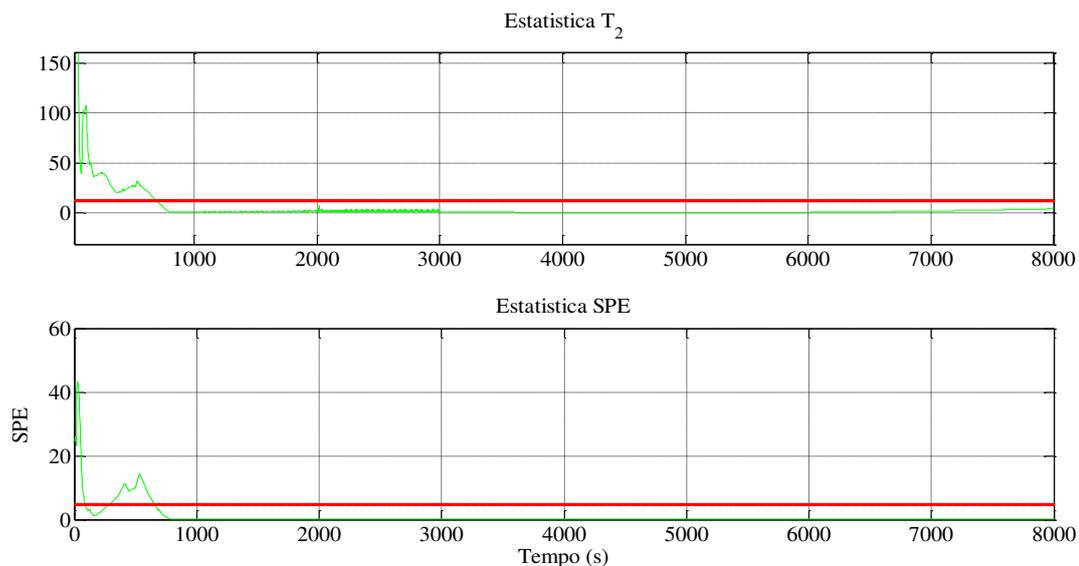


Figura 4.30 - Testes de detecção de falhas após reconstrução dos sinais, falhas simultâneas.

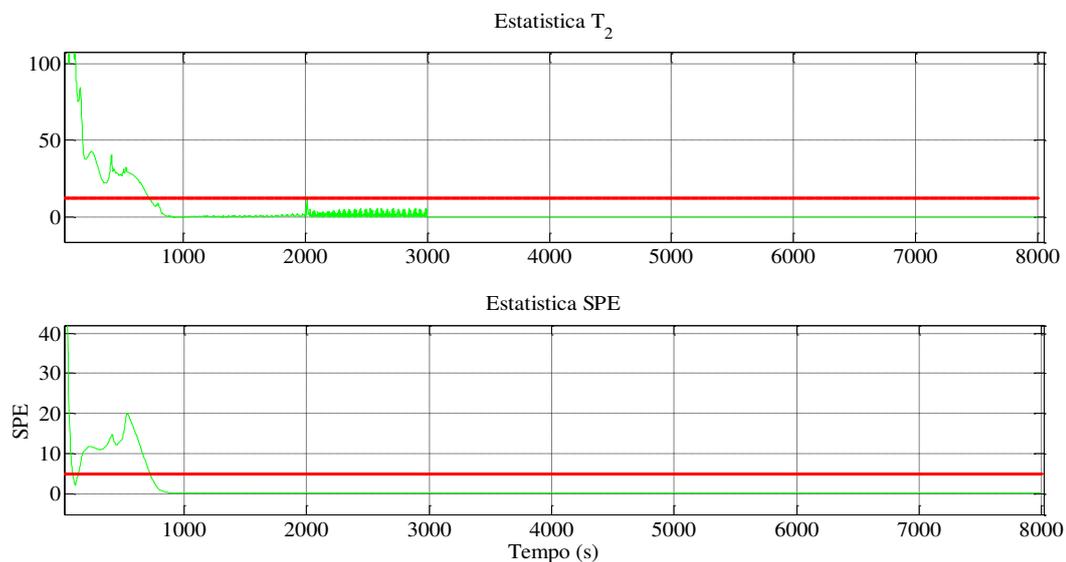


Figura 4.31 - Testes de detecção de falhas após reconstrução dos sinais, falhas não simultâneas.

Na Figura 4.31 podem ser visualizados os testes de detecção de falhas para situação 2 do cenário 2 após reconstrução dos sinais, percebe-se que em momento algum os limites de controles das cartas de controle são violados, mostrando que a abordagem do diagnóstico de falhas apresentada pode ser utilizada para localizar, identificar e reconstruir falhas ocorridas tanto em sensores como em atuadores.

Capítulo 5

Mapeamento energético de plantas industriais e prognóstico de falhas numa perspectiva energética

5.1 Introdução

Uma questão de destaque em todos os setores industriais é o tocante ao consumo energético, ao uso racional e eficiente da energia, que a cada dia que passa ganha proporções globais. O aumento dos custos de energia, o aumento da competitividade global, restrições ambientais, larga utilização de energia devido ao crescimento econômico, industrial e populacional, esgotamento a médio e longo prazo das fontes primárias convencionais e o forte apelo por um desenvolvimento sustentável são razões para a busca por uma maior eficiência energética nas atividades industriais do setor de petróleo e gás. Neste cenário o balanço energético do processo serve para indicar os valores das variáveis do processo, indicar estados indesejáveis, proximidade a estados não permitidos bem como para tomar as ações apropriadas com a finalidade de manter uma operação aceitável e evitar danos ou acidentes, o que representa uma tarefa desafiadora, mas viável do ponto de vista econômico (Alexandre & Lima, 2013).

O mapeamento consiste em levantar gráficos dinâmicos que descrevam as trocas térmicas ao longo de toda a unidade. Tomando como base este mapa energético da unidade, pode-se construir um algoritmo de monitoramento para avaliar os sinais energéticos da unidade na ocorrência da falha, computando a ocorrência do defeito e sua localização.

A eficiência energética da unidade processual pode ser entendida com estratégias/ações empregadas visando reduzir perdas e eliminar desperdícios no sistema energético. A redução de perdas é obtida com o emprego de tecnologia de ponta e a eliminação de desperdícios é alcançada através de conscientização, por meio de campanhas e treinamento profissional de recursos humanos para a área. O presente documento propõe realizar/apresentar a assinatura energética, ou seja, definir os aportes energéticos de entrada, os aportes energéticos de saída, as perdas energéticas bem como o rendimento, utilizando para isto, das leis termodinâmicas, de leis de escoamento multifásico entre outras leis físicas, para a coluna fracionadora de óleo pesado conhecida na literatura com *Process Shell*, apontar algumas ações no sentido de se obter uma melhoria na eficiência energética do processo e desenvolver e avaliar um algoritmo para detecção e identificação de falhas na unidade no sentido da energia envolvida no processo.

5.2 Descrição do funcionamento da seção de fracionamento

Nesta seção será considerado um modelo de coluna fracionadora de óleo cru, conhecido na literatura como Processo da *Shell*, inicialmente introduzido por Prett & Morari (1987), a qual foi considerada aqui, ser uma fracionadora de óleo pesado tipo

atmosférica com pré- fracionamento, para podermos realizamos a simulação dinâmica da coluna de acordo com Moreira (2007). A Figura 5.1 ilustra um esquema simplificado da coluna fracionadora.

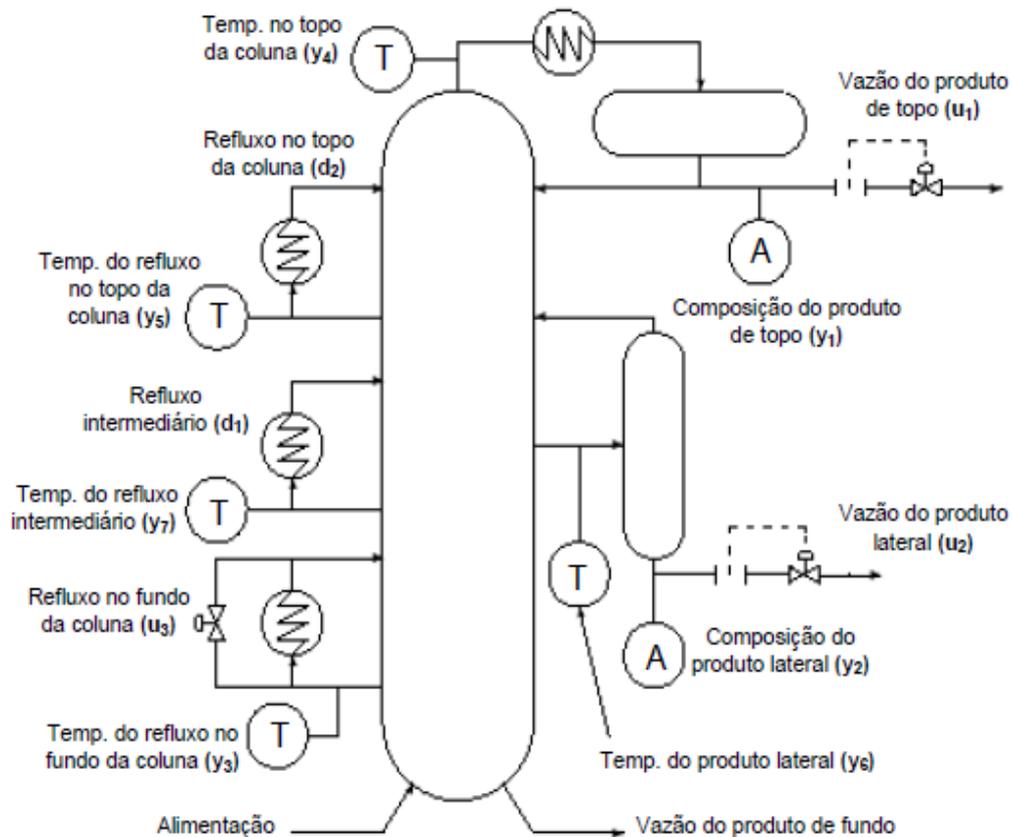


Figura 5.1 - Modelo de uma torre de fracionamento atmosférica.

Fonte: adaptado de Pretti & Morari, 1987.

Neste modelo, as variáveis controladas são a composição do produto no topo, composição do produto na lateral e a temperatura da base, sendo representadas como y_1 , y_2 e y_7 respectivamente. As variáveis que podem ser manipuladas são a vazão de saída no topo (u_1), vazão de saída lateral (u_2), e o refluxo da base da coluna (u_3).

A fracionadora de óleo pesado pode ser encarada como uma coluna de destilação contínua mais especificadamente uma coluna com pratos. A mistura líquida a ser processada é conhecida como a entrada de alimentação, que geralmente é realizada na parte intermediária da coluna. O prato de alimentação (prato é um equipamento colocado ao longo da coluna para facilitar as trocas de calor e massa e a geração de calor o mais próximo possível do equilíbrio) divide a coluna em duas seções: a seção de topo e a seção de fundo. Caracterizando os escoadouros dos produtos da torre de fracionamento, mas podem existir escoadouros intermediários para produtos que sejam de interesse econômico.

Para conseguir uma separação mais completa dos produtos é comum o uso do refluxo ou refeedor, onde o produto de partes inferiores da coluna de destilação é enviado por meio de dutos para pratos mais altos.

Dentre as principais características presentes na operação de uma coluna fracionadora, destaca-se: elevados gradientes de temperatura, tempo morto, alto grau de acoplamento entre as variáveis manipuladas e controladas, consumo elevado de energia, devido ao grande consumo de vapor de aquecimento e uma baixa eficiência termodinâmica do processo. Tais características são as razões para a intensa pesquisa e investimento privado na busca de soluções para minimizar custos e otimizar os processos.

O objetivo da seção de fracionamento é remover calor e recuperar produtos líquidos dos gases craqueados oriundos do reator. A fracionadora assemelha-se a uma torre de destilação, porém, diferente do que ocorre na torre de destilação, na fracionadora os gases devem ser desaquecidos antes de acontecer qualquer fracionamento. Tendo vários produtos ao longo de toda a coluna, sendo o produto mais pesado no fundo, chamado de óleo clarificado, junto com mais duas correntes circulantes: a borra de refluxo e a borra circulante; óleo pesado de reciclo (HCO), óleo leve de reciclo (LCO) e nafta como produtos laterais e os hidrocarbonetos mais leves como gás combustível, GLP e gasolina como produtos de topo. Todos esses produtos transportam energia, como também demandaram energia para a obtenção de tais, portanto é de suma importância levantar a assinatura energética da torre de fracionamento, mapeando toda energia envolvida nas trocas térmicas, os aportes energéticos de entrada, os aportes gastos no processo bem como o valor energético entregue na forma de produto pela fracionadora.

A partir da assinatura energética pode-se fazer uma análise da eficiência energética do processo, bem como definir estratégias de otimização da energia gasta no processo, bem como melhorias na qualidade da energia entregue na forma de produtos.

5.3 Assinatura de Energia da Fracionadora de Óleo cru

Nesta seção será apresentada a metodologia utilizada para formulação matemática da assinatura energética da coluna *Shell*, bem como a sua simulação em ambiente numérico MATLAB. O problema será dividido nas seguintes etapas:

1. Computar as entradas de energia do processo;
2. Computar a energia consumida dentro do sistema;
3. Computar as saídas de energia da planta;
4. Simulação do mapa energética do processo.

5.3.1 Formulação matemática do problema

A análise de energia na coluna será iniciada pelos inputs de energia, onde as fontes de energia são: a alimentação (vazão) gasosa da coluna bem como o calor inicial do processo (w_{alim}), a vazão do produto de topo (u_1), a vazão do produto lateral (u_2) e a vazão de refluxo no fundo da coluna (u_3). Da termodinâmica, a energia de um fluido em função da vazão é dada como (Hangos, 2001): $E = wc_pT$, onde w é vazão, c_p é calor específico do fluido e T é a temperatura do fluido, sendo assim,

$$\text{Energia de alimentação: } E_{alim} = w_{alim} c_{p_alim} y_7 \quad (5.1)$$

$$\text{Energia de entrada pela válvula de topo: } E_1 = u_1 c_{p_1} (T_{refer_1} - y_4) \quad (5.2)$$

$$\text{Energia de entrada pela válvula lateral: } E_2 = u_2 c_{p_2} (T_{refer_2} - y_6) \quad (5.3)$$

$$\text{Energia transportada pelo refluxo de fundo: } E_3 = u_3 c_{p_3} y_7, \quad (5.4)$$

sendo, T_{cond} é a temperatura no condensador de topo, T_{refe} é a temperatura no refeedor lateral.

Calor injetado pelas torres retificadoras na forma de vapor d'água:

$$Q_{reti} = Q_{atm} + Q_{quer} + Q_{leve} + Q_{pesado} = \left[\left(\frac{4,19kJ}{kg^{\circ}C} \right) ^{\circ}C \right] = \left[\frac{GJ}{h} \right]. \quad (5.5)$$

Para os dados de (Moreira, 2007) e adaptado ao problema, tem-se,

Calor injetado na torre atmosférica:

$$Q_{atm} = \frac{454kg}{h} \left(\frac{4,19kJ}{kg^{\circ}C} \right) (350^{\circ}C) = 665,791 \frac{GJ}{h} \quad (5.6)$$

Calor injetado pela retificadora de querosene:

$$Q_{quer} = \frac{37,4kg}{h} \left(\frac{4,19kJ}{kg^{\circ}C} \right) (350^{\circ}C) = 54,8471 \frac{GJ}{h} \quad (5.7)$$

Calor injetado pela retificadora de diesel leve:

$$Q_{leve} = \frac{14,5kg}{h} \left(\frac{4,19kJ}{kg^{\circ}C} \right) (350^{\circ}C) = 21,264 \frac{GJ}{h} \quad (5.8)$$

Calor injetado pela retificadora de diesel leve:

$$Q_{pesado} = \frac{7,89kg}{h} \left(\frac{4,19kJ}{kg^{\circ}C} \right) (350^{\circ}C) = 11,57 \frac{GJ}{h} \quad (5.9)$$

logo, o calor fornecido ao processo em forma de vapor d'água é dado por: $Q_{reti} = 753,472 \frac{GJ}{h}$.

A alimentação total de energia do processo será a contribuição de todos os *inputs* de energia, portanto,

$$\sum E_{input} = E_{alim} + E_1 + E_2 + E_3 + Q_{reti}. \quad (5.10)$$

O consumo energético no interior do processo dar-se nas malhas de circulação, mas especificamente nos aquecedores/trocadores de calor e nos refeedores (*reboilers*, do inglês), como também no transporte de massa e/ou deslocamento de fluido ao longo da coluna. Levando em consideração tais informações pode-se escrever:

Carga térmica no aquecedor do fundo da coluna (Hangos, 2001):

$$Q_{fundo} = m_{fluido} c_{p_fluido} (y_6 - y_7); \quad Q_{fundo} = \rho c_p u_3 (y_6 - y_7); \quad Q_{fundo} = \rho c_p V (y_6 - y_7); \\ Q_{fundo} = \rho A C a (y_6 - y_7); \quad Q_{fundo} = v \rho C a A (y_6 - y_7) \quad \text{ou} \quad Q_{fundo} = h_l A (y_6 - y_7),$$

qualquer uma dessas expressões pode ser utilizado para encontrar a carga térmica do aquecedor de fundo.

Carga térmica do aquecedor intermediário:

$$Q_{inter} = m_{fluido} c_{pfluido} (y_4 - y_6) \quad (5.11)$$

Carga térmica na entrada do vaso flash do produto lateral:

$$Q_{entr.lat} = m_{fluido} c_{pfluido} y_5 \quad (5.12)$$

Carga térmica do aquecedor superior:

$$Q_{sup} = m_{fluido} c_{pfluido} (y_3 - y_4) \quad (5.13)$$

Carga térmica de entrada do vaso flash do produto de topo:

$$Q_{entr.topo} = m_{fluido} c_{pfluido} y_3, \quad (5.14)$$

sendo m_{fluido} é massa do fluido, $c_{pfluido}$ é calor específico do fluido, ρ é densidade de massa, V o volume do recipiente, A a área do recipiente, Ca capacidade térmica do material que é constituído o recipiente, v a velocidade de escoamento, h_l é o coeficiente de troca térmica.

A energia envolvida no transporte de massa pode ser descrito pelas seguintes equações:

$$\text{Energia envolvida no refluxo intermediário: } E_{ref.inter} = d_1 c_p y_6 \quad (5.15)$$

$$\text{Energia envolvida no refluxo superior: } E_{ref.sup} = d_2 c_p y_4 \quad (5.16)$$

Deve-se também levar em conta a energia potencial da mistura na fracionadora, dada por: $E_p = mgh$, onde h é a altura da coluna em metros.

O valor energético total no interior da fracionadora de óleo pesado pode ser computado como a soma de todos os aportes energéticos no seu interior, sendo expresso por,

$$\sum E_{consu} = Q_{fundo} + Q_{inter.} + Q_{entr.lat} + Q_{sup.} + Q_{entr. topo} + E_p + E_{refe.inter} + E_{refe.sup} \quad (5.17)$$

Por fim a energia entregue pelo processo (gases para a recuperação de gases, óleos leves e resíduos), na forma de vazão de produtos, é expressa como:

$$\text{Energia transportada no produto de topo: } E_{prod.topo} = y_1 c_p y_3 \quad (5.18)$$

$$\text{Energia transportada no produto lateral: } E_{prod.lateral} = y_2 c_p y_6 \quad (5.19)$$

$$\text{Energia transportada no produto de fundo: } E_{prod.fundo} = w_{fundo} c_p y_7 \quad (5.20)$$

O valor energético total entregue pelo processo é obtido fazendo a soma dos aportes energéticos de saída, conforme (5.21),

$$\sum E_{saída} = E_{prod.topo} + E_{prod.lateral} + E_{prod.fundo}. \quad (5.21)$$

A formulação matemática apresentada serve para construir um mapa energético ao longo da coluna, utilizando este mapa é possível localizar os principais pontos de

desperdícios de energia bem como identificar pontos onde ocorram falhas no processo, podendo ser utilizado na construção de um diagnosticar de falhas de dispositivos de instrumentação baseado na assinatura de energia da coluna fracionadora de óleo pesado.

5.3.2 Mapeamento Energético da Fracionadora de Óleo Cru

O mapeamento de energia consiste em obter gráficos e/ou tabelas que descrevem o comportamento energético em vários níveis ao longo da fracionadora. O levantamento aqui feito dar-se do fundo da coluna até o topo, levando em consideração as diversas trocas térmicas envolvidas neste caminho bem como as várias etapas da separação da mistura.

As especificações de entrada e saída (em forma de produtos) da fracionadora de óleo pesado tipo atmosférica com pré- fracionamento são apresentadas nas Tabelas 5.1 e 5.2.

Tabela 5.1: Alimentação da fracionadora atmosférica.

Entrada		
Vapor d' água	Óleo cru pré-fracionado	
	Óleo cru leve	Óleo cru pesado

Tabela 5.2: Produtos de saída da fracionadora.

Saída						
Produto de topo			Produto lateral			Produto de fundo
Gás combustível	Nafta pesada	Água ácida	Querosene	Diesel leve	Diesel pesado	Resíduo atmosférico

Considerando os dados de Moreira (2007), a coluna tem 40 estágios e é alimentada com óleo cru pré-fracionado proveniente da torre de pré-fracionamento. Parte dos dados de entrada do algoritmo de mapeamento energético encontra-se em Moreira e os restantes foram obtidos na pesquisa, portanto não sendo dados reais, visto a dificuldade para serem disponibilizados pelas empresas. Tais dados estão dispostos na Tabela 5.3.

O simulador da coluna fracionadora de óleo cru junto com o controlador preditivo foi implementado em Simulink- MATLAB e a assinatura do processo em linhas de código no MATLAB. O valor energético total de alimentação da fracionadora é ilustrado pelo gráfico da Figura 5.3, a Figura 5.4 apresenta a energia consumida ao longo da fracionadora devido às trocas térmicas bem nas etapas da separação da mistura. Por fim a energia entregue pela coluna na forma de produtos e de resíduos é apresentada na Figura 5.5.

Foi simulado o cenário de falhas múltiplas para a fracionadora de óleo cru (Tabela 4.14, situação 1), com o diagnosticador estatístico não está em operação, com o intuito de observar o comportamento das variáveis energéticas no momento da falha. Desenvolveu-se um módulo diagnosticador energético, tendo como funções de monitoramento do sistema, a entrada de energia da planta, a energia entregue e a energia consumida pelo processo. Os gráficos das Figuras 5.3, 5.4 e 5.5 ilustram o comportamento do sistema no ponto de vista energético na ocorrência da falha múltipla

e simultânea nos analisadores da composição de topo e da temperatura de refluxo da base.

A metodologia utilizada para a simulação da assinatura energética da coluna dar-se conforme o fluxograma da Figura 5.2.

Tabela 5.3: Dados relevantes à simulação da assinatura energética da fracionadora de óleo cru.

Descrição	Variável	Unidade	Valor
Massa molar do fluido de alimentação	m	kg/mol	-
Vazão de alimentação	w_{alim}	m^3/d	870,3
Calor fornecido pelas torres retificadoras	Q_{reti}	GJ/h	753.472
Calor específico (petróleo cru)	c_p	$kJ/kg^{\circ}C$	1,947
Calor específico da nafta pesada	c_{p1}	$kJ/kg^{\circ}C$	2,273
Calor específico do produto lateral	c_{p2}	$kJ/kg^{\circ}C$	
Calor específico do produto de fundo	c_{p3}	$kJ/kg^{\circ}C$	-
Temperatura do condensador de topo	T_{cond}	$^{\circ}C$	34,5
Temperatura do refeedor lateral	T_{refer2}	$^{\circ}C$	150,4
Aceleração da gravidade	g	m/s^2	9.8
Altura da fracionadora	h	m	60
Vazão do produto de fundo	w_{fundo}	t/h	0,454

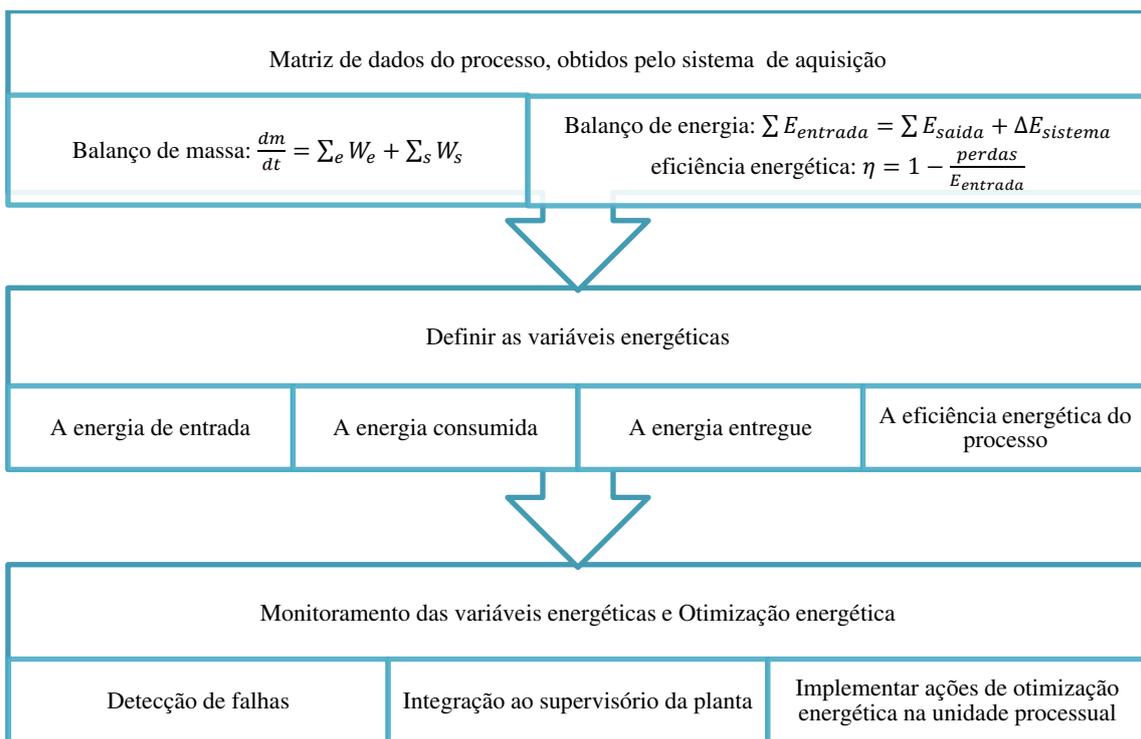


Figura 5.2 - Fluxograma descritivo da geração da assinatura energética da torre de fracionamento atmosférica.

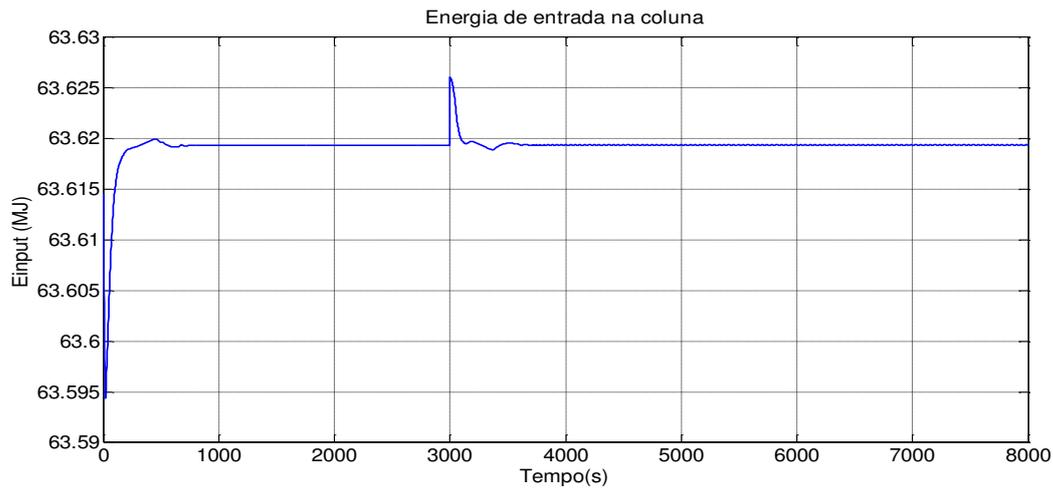


Figura 5.3 - Energia de entrada na fracionadora de óleo cru, na ocorrência da falha simultânea nos analisadores de composição de topo e de temperatura de refluxo de base.

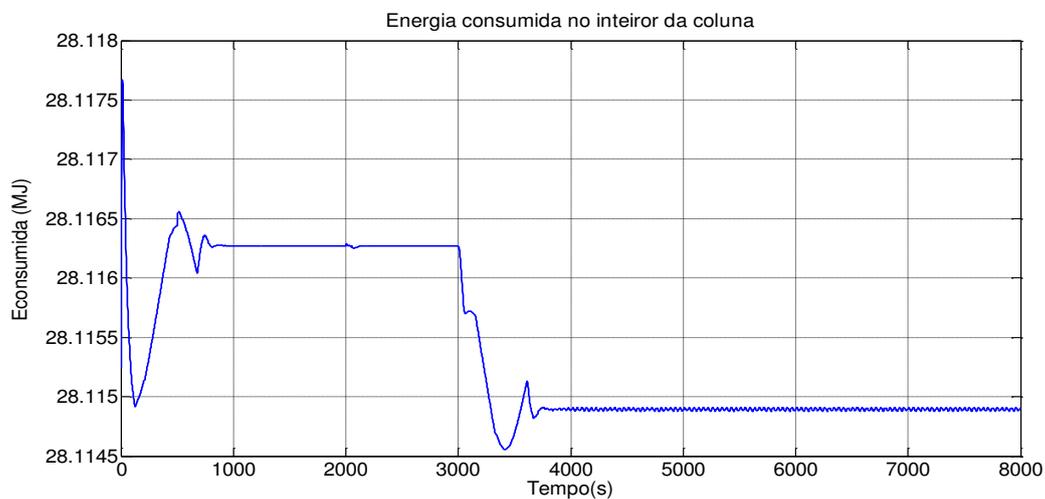


Figura 5.4 - Energia consumida ao longo da fracionadora de óleo cru.

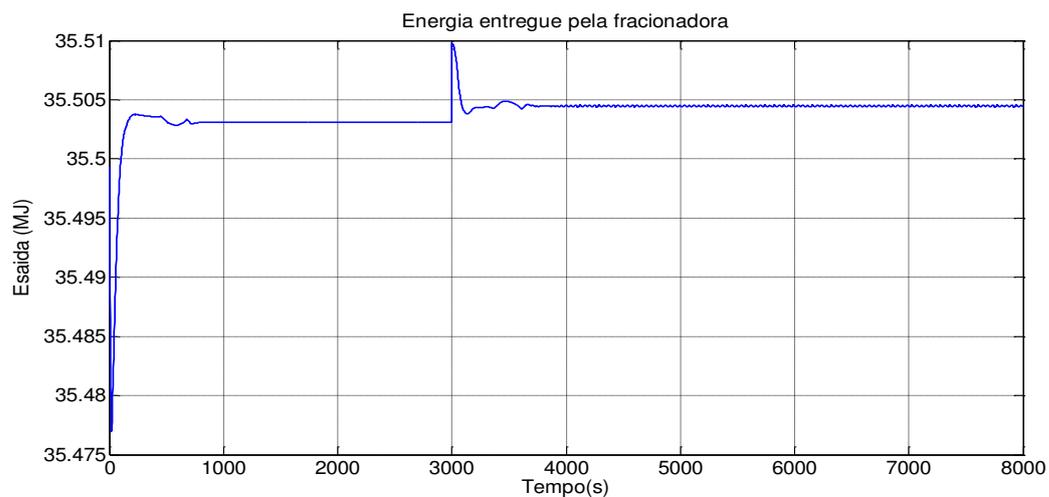


Figura 5.5 – Comportamento da energia entregue pela torre atmosférica, na ocorrência de falhas simultâneas. Percebe-se um aumento na energia devido informações errôneas capturadas pelos analisadores e repassada ao controlador e transmitida à planta.

Como a plataforma encontra-se em regime permanente, podemos utilizar, $rendimento = 1 - \frac{perdas}{Entrada}$, sem nenhuma perda de informação e computar a eficiência energética da fracionadora, conforme ilustrada na Figura 5.6.

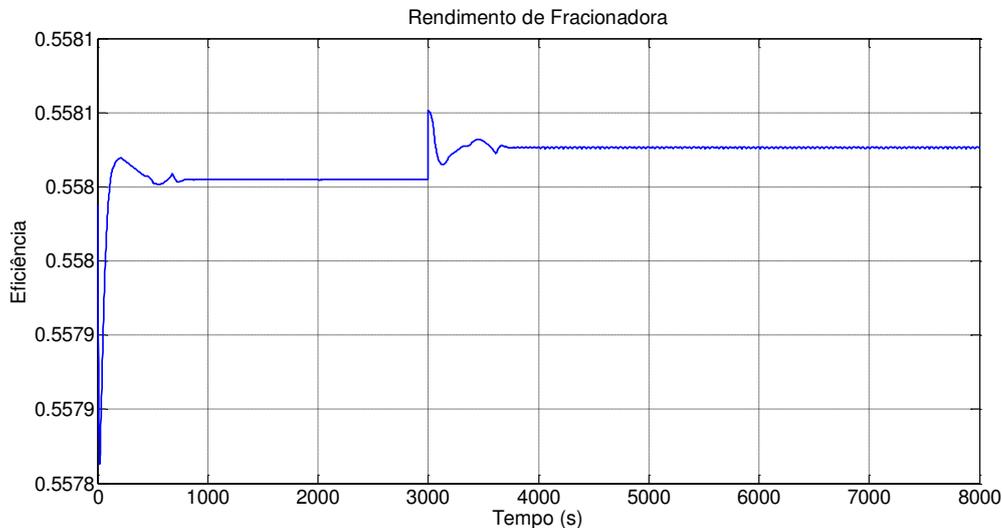


Figura 5.6 - Eficiência energética da torre de fracionamento atmosférica operando em condições anormais. Percebe-se um aumento na eficiência após a ocorrência da falha, devido ao mascaramento da falha por parte do controlador.

Analisando os gráficos anteriores percebe-se a propagação do defeito levando a tomada de decisão errada do controlador. Daí vê a importância da mitigação da falha ou o controle tolerante, que atuaria minimizando os efeitos da propagação do defeito até a intervenção final do operador após alarme disparado pelo sistema de supervisão e diagnóstico de falhas.

Embora os resultados não sejam com dados totalmente reais, mas ilustra bem o desempenho da metodologia proposta para a assinatura energética e para o diagnosticador do ponto de vista energético da unidade.

5.4 Medidas de otimização energética

A literatura na área de otimização energética de unidades processuais pode ser dividida em três categorias:

1. Modelos para otimização do projeto da planta;
2. Modelos de gestão da planta, reprogramação e manutenção;
3. Modelos para adequar a unidade a uma nova capacidade de produção (*revamp*), objetivando maximizar a integração energética com o mínimo possível de mudanças estruturais.

Neste sentido as ações a serem conduzidas objetivam reduzir o consumo energético e consequentemente aumentar a eficiência da unidade, sendo assim vale destacar,

1. Uso de técnicas de integração e intensificação energética, tal como a metodologia *pinch* - Metodologia baseada em princípios termodinâmicos, que

tem como objetivo economizar custos para a indústria, otimizando a maneira como os recursos necessários para os processos (particularmente energia e água) são aplicados para uma larga gama de propósitos; ou outras ferramentas de otimização energética de processos;

2. Seleção das correntes potenciais de integração energética;
3. Determinação do mínimo consumo de utilidades;
4. Identificação das trocas térmicas e análise de potenciais impactos operacionais;
5. Integração ao módulo diagnosticador PCA;
6. Eficiência energética no uso final da energia;
7. Recuperação de energia;
8. Implantação de medidas no sentido de cogeração de energia;
9. Determinação do ponto ótimo de temperatura para cada rede de trocadores de calor por ferramentas de simulação termodinâmica de processos;
10. Reduzir consumo de utilidades: isolamento térmico, reduzir desperdícios, eliminar vazamentos e operar o processo de forma estável;
11. Uso da metodologia descrita pelo fluxograma da Figura 5.2 para realização do balanço de energia;
12. Analisar o consumo energético do processo para diferentes formas de controle;
13. Analisar estratégias descritas na literatura que tratam o problema de otimização do número de equipamentos térmicos para a unidade industrial, como um problema de programação inteira da programação matemática e depois convertido num problema de transporte da programação linear e de programação multi-objetiva;
14. Implantação de um sistema de gestão energética na unidade.

Todas estas medidas de efficientização energética se aplicam a unidade fracionadora estudada.

Capítulo 6

Especificações técnicas de *software* e gestão de alarmes

6.1. Introdução

A segurança na automação e o diagnóstico de falha são áreas estratégicas na indústria de processo. O desenvolvimento de ferramentas de apoio à operação e a manutenção da planta contribuem para minimizar custos operacionais da corporação, neste contexto vale ressaltar alguns conceitos. A literatura sobre diagnose de falhas (detecção, isolamento, mitigação e sinalização) utilizam as palavras defeito, falha e erro com significados específicos: defeito é a degradação no desempenho de um componente ou do sistema; falha é a degradação total, a paralisação de um componente ou do sistema. Assim, dependendo do caso, um defeito ou uma falha em um componente pode acarretar um defeito ou uma falha no sistema. O erro é um conceito mais abrangente, pois designa o mau desempenho do sistema, qualquer que seja sua origem: defeitos, falhas ou comandos externos não previstos.

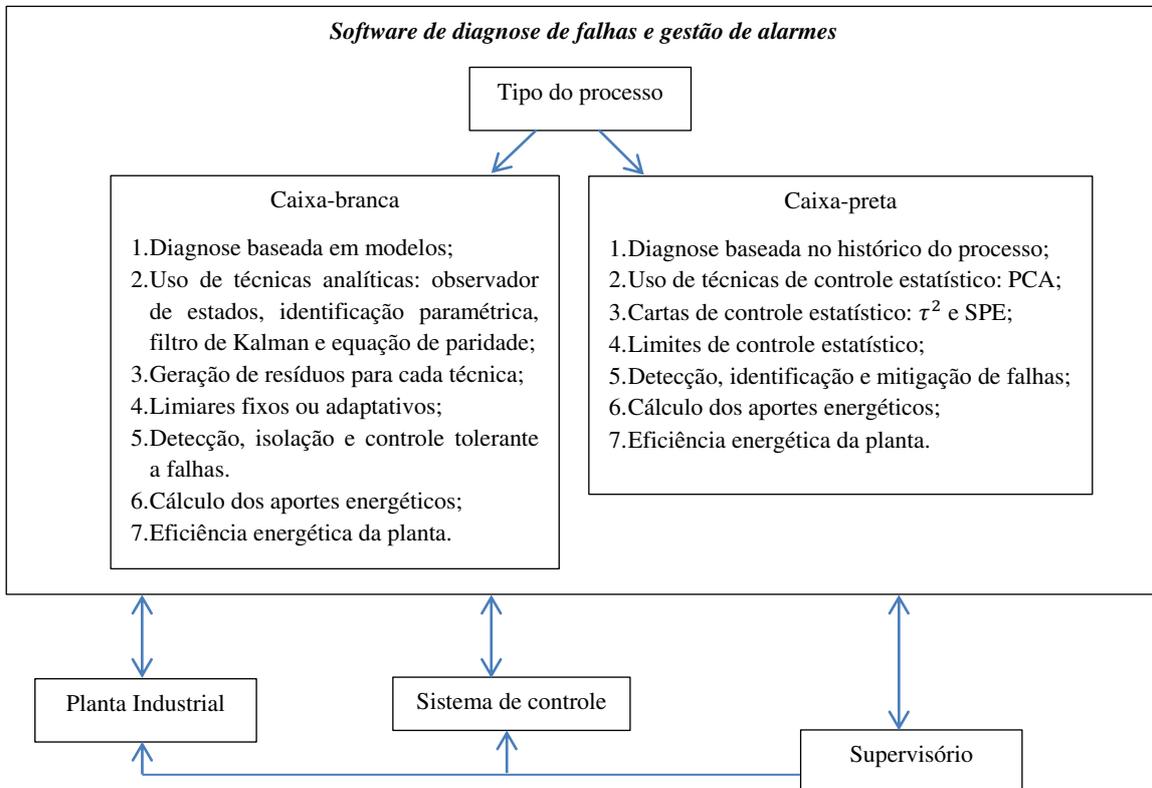
Falhas são eventos que ocorrem de maneira aleatória e suas consequências são do “tipo pior caso” podendo ser analisadas deterministicamente, mas em geral requerem tratamento ou simulação de caráter estatístico. Aumentar a confiabilidade de um sistema, isto é, reduzir a sua probabilidade de ocorrência de falhas, pode ser feito por dois caminhos: empregando componentes de melhor qualidade, que são geralmente mais caros ou pode-se introduzir componentes redundantes.

A redundância significa duplicar ou triplicar os sensores ou atuadores e reunir os seus sinais de saída em um único sinal, por meio de operadores lógicos AND, OR ou XOR (exclusive OR). Para garantir a robustez do sistema de monitoramento pode-se usar tais operadores de maneira combinada em lógica específica.

O diagnóstico de falhas é o processo que deve entrar em ação a fim de identificar o componente falho, aumentando a rapidez e a segurança da detecção da falha, tarefa difícil devido à complexidade dos processos atuais. Maior complexidade implica em maior probabilidade de falhas, mais informações técnicas para intervenções de manutenção, maior custo de parada, exigindo uma resposta mais rápida para equipe de manutenção na então chamada automação da manutenção. Neste contexto o diagnóstico passivo, aquele realizado a partir dos sinais de operação e o diagnóstico ativo, aquele feito com a cooperação dos técnicos da manutenção.

Neste Capítulo será apresentada a especificações técnicas do *software* para diagnose de falhas em medidores e atuadores de processos industriais a ser desenvolvido em linguagem e plataforma específica e compatível com todos os sistemas operacionais, o sistema (a definir) será desenvolvido de forma a prover seus serviços na *web* ou funcionando em uma única máquina cliente. Uma proposta de sistema de gestão de alarmes em unidades processuais é apresentada e discutida cada atividade desenvolvida por tal sistema.

Um esquemático geral do *software* de diagnose de falhas e gestão de alarmes pode ser visualizado na Figura 6.1, observa-se que a arquitetura envolve todas as estratégias desenvolvidas para processos como modelo conhecido, para processos tipo caixa-preta multivariável e a diagnose do ponto de vista energético em um único produto, o *software*.



restrições de operação e de desenvolvimento do sistema. A engenharia de requisitos é um estágio crítico do processo de *software*, pois erros nesta etapa conduzem inevitavelmente a problemas posteriores no projeto e na implementação do sistema.

O processo da engenharia de requisitos é ilustrado na Figura 6.2. Tal processo leva a produção de um documento, que é a especificação do sistema.

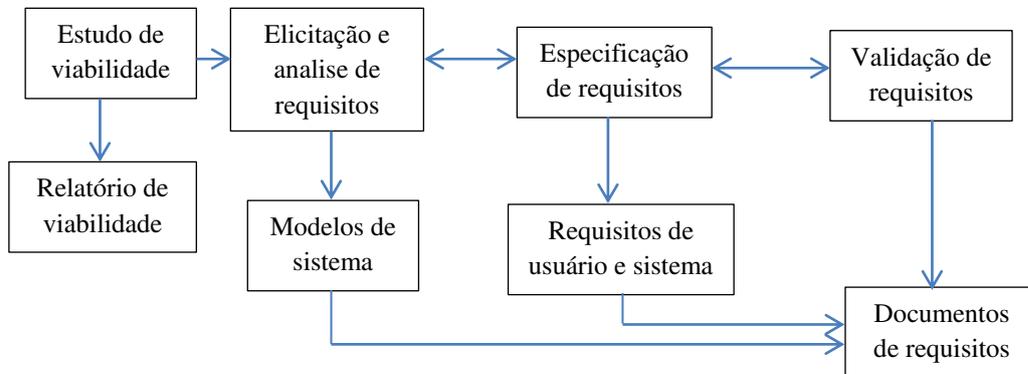


Figura 6.2. Processo de engenharia de *software*.

Fonte: Sommerville, 2011.

As atividades descritas no fluxograma da Figura 6.2, podem ser descritas, de maneira resumida, conforme Council (2001) e Sommerville (2011):

1. *Estudo de viabilidade*. É feita uma avaliação para verificar se as necessidades dos usuários identificadas podem ser satisfeitas por meio das tecnologias atuais de *software* e *hardware*. O estudo considera se o sistema proposto terá custo adequado do ponto de vista comercial e se pode ser desenvolvido dentro das restrições de orçamento existente. O resultado do estudo deve fornecer informações para tomada de decisão quanto a prosseguir para uma análise mais detalhada.
2. *Elicitação e análise de requisitos*. É o processo de derivação de requisitos de sistema através da observação de sistemas existentes, discussões com usuários potenciais, análise de tarefas, entre outros. Isso pode envolver o desenvolvimento de um ou mais modelos de sistema e protótipos.
3. *Especificação de requisitos*. Atividade de traduzir as informações coletadas durante a atividade de análise em um documento eu define um conjunto de requisitos. Devem ser incluídos dois tipos de requisitos nesse documento. Requisitos de usuário são declarações abstratas dos requisitos de sistema para o cliente e os seus usuários finais; requisitos de sistema constituem uma descrição detalhada da funcionalidade a ser fornecida.
4. *Validação de requisitos*. Essa atividade verifica os requisitos em relação ao realismo, consistência e abrangência. Durante este processo, erros no documento de requisitos são descobertos, sendo feitas as devidas modificações para corrigir esses problemas.

As atividades de processo de *software* não são realizadas na sequência estrita descrita anteriormente, podem ocorrer de maneira simultânea, mas uma característica importante a ser levada em consideração é o *feedback* das informações.

Na engenharia de requisitos é importante conhecer e explicitar os requisitos. Requisitos de um sistema são descrições dos serviços fornecidos pelo sistema e as suas restrições operacionais, são classificados em requisitos funcionais, requisitos não funcionais ou requisitos de domínio, conforme Sommerville (2011):

1. *Requisitos funcionais*. São as declarações de serviços que deve ser fornecer, como o sistema deve reagir a entradas específicas e como o sistema deve se comportar em determinadas situações.
2. *Requisitos não funcionais*. São restrições sobre os serviços ou as funções oferecidas pelo sistema. Eles incluem restrições sobre o processo de desenvolvimento e padrões.
3. *Requisitos de domínio*. São requisitos provenientes do domínio da aplicação do sistema e que refletem as características e as restrições desse domínio. Podem ser requisitos funcionais ou não funcionais.

Nos parágrafos anteriores discutiu-se as principais etapas para especificação de um *software*, mas resta uma pergunta, como apresentar a abstração do sistema a ser projetado? A técnica amplamente usada é documentar a especificação do sistema como um conjunto de modelos. Esses modelos são representações gráficas que descrevem processos negócios, o problema a ser resolvido e o sistema a ser desenvolvido.

Um modelo de sistema é uma abstração em estudo, e não uma representação alternativa do sistema. Uma representação do sistema deve manter todas as informações sobre a entidade que está sendo representada. Uma abstração simplifica a descrição e ressalta as características mais salientes (Sommerville, 2011). Os principais tipos de modelos existentes no mercado de *software* que são criados o processo de análise são:

1. *Modelo de fluxo de dados*. Modelos de fluxo de dados mostram como os dados são processados em diferentes estágios do sistema.
2. *Modelo de composição*. Um modelo de composição ou agregação mostra como as entidades no sistema são compostas por outras entidades.
3. *Modelo de arquitetura*. Modelos de arquitetura mostram os principais subsistemas que constituem um sistema.
4. *Modelo de classificação*. Diagramas de classe de objeto/herança mostram como as entidades têm características comuns.
5. *Modelos de estímulo-resposta*. Um modelo de estímulo-resposta, ou diagrama de transição de estados, mostra como o sistema reage aos eventos internos e externos.

Para especificação técnica do *software* de diagnose falhas em plantas industriais, usaremos do modelo de fluxo de dados e do modelo estímulo-resposta para apresentação da abstração do sistema a ser desenvolvido, visto que estes modelos são os mais usados nas literaturas estudadas e no mercado brasileiro de desenvolvimento de *software* (2013); pela maneira estruturada e organizada de apresentar as informações, o que auxilia o programador na fase de projeto e implementação do produto *software*. As especificações técnicas do *software* de diagnose (detecção, identificação, isolamento e

mitigação) de falhas em sistemas de instrumentação e controle industrial são apresentadas nas Tabelas 6.1, 6.2 e 6.3.

Tabela 6.1. Descrição técnicas do sistema de diagnose de falhas em processos industriais.

Nome	DiaFault
Versão	1.0
Descrição do <i>software</i>	Este <i>software</i> é usado com na diagnose (detecção, isolamento e mitigação) de falhas em sensores e atuadores em processos industriais, usando de técnicas avançadas de controle, padrões industriais de comunicações, técnicas de gerenciamento de energia e tráfego de dados. Apresenta <i>interface</i> fácil e interativa ao operador da planta, sendo integrado facilmente ao supervisório da planta industrial. Compatível com qualquer sistema operacional e protocolo de comunicação.
Finalidade	Auxiliar na operação e na manutenção rotineira da unidade processual, dando suporte ao operador e ao mesmo tempo minimizando paradas não programadas da planta industrial.
Variáveis de entrada (<i>inputs variables</i>)	<ul style="list-style-type: none"> • Sinais analógicos e/ou digitais dos diversos sensores espalhados no campo. • Sinais analógicos e/ou digitais dos atuadores (mensuráveis) instalados no campo. • Todos os sinais de entrada do diagnosticador de falhas virão do sistema de aquisição de dados, que coleta as medições e estados dos sensores e atuadores instalados em campo. • Os sinais oriundos do sistema de aquisição deverão ser organizados em uma matriz de dados ($n \times m$), na qual as n linhas representam as amostras e as m colunas representam as variáveis mensuráveis da planta. • Uso do padrão OPC para comunicação industrial. • Todas variáveis devem ser coletadas em tempo real.
Variáveis de saída (<i>outputs variables</i>)	<ul style="list-style-type: none"> • Todos os sinais lógicos de ocorrência (alarmes) de falhas na planta, nos sensores e nos atuadores; • Todos os sinais temporais dos resíduos de cada variável na forma de carta de controle de qualidade (resíduos operando dentro da faixa de limiares projetados para condições operacionais de estabilidade da planta); • Todas as variáveis controladas e monitoradas; • Carta de controle estatístico de Hotelling (τ^2); • Carta de controle estatístico Q (<i>SPE - Square Predictor Error</i>); • Estimativa da magnitude da falha ocorrida; • Gráfico (barra) da contribuição das variáveis mensuráveis da planta no instante da ocorrência da falha. • Aporte energético de entrada da planta industrial (gráfico gerado pelo diagnosticador que analisa a falha do ponto de vista energético);

	<ul style="list-style-type: none"> • Energia consumida na unidade processual; • Energia entregue pela unidade processual; • Eficiência energética da planta industrial; • Todas as variáveis de saída do módulo de diagnose de falhas devem ser apresentadas em interface própria; • Todas as variáveis de saída do módulo de diagnose de falhas devem ser enviadas para o nível hierárquico superior, o supervisório da planta para que seja apresentada na IHM do supervisório da planta industrial. • Todas as variáveis de saída devem ser apresentadas em tempo real.
Certificação	Standard Information/ IEEE/IEC
Compatibilidade	O sistema a ser desenvolvido deve ser compatível com processador de 32-bits e processadores superiores. Devendo trabalhar com pontos flutuantes.
Linguagem de programação	C, C++, C# ou C++ Builder.
Interação do usuário	<i>Interface</i> gráfica interativa por meio de: manipulação direta, seleção de <i>menu</i> e/ou preenchimento de formulários.
Banco de dados próprio	Armazenar o histórico das principais falhas ocorridas no processo.
Módulos de trabalho	<ul style="list-style-type: none"> • Módulo para processos do tipo caixa-branca. • Módulo para processos do tipo caixa-preta.
Apresentação das informações	Todas as informações deverão ser apresentadas ao operador na tela da IHM na forma de gráficos em tempo real.
Interação do <i>software</i> com o supervisório da planta	Via padrão de Comunicação industrial OPC ou Profibus International communications.
Interação do <i>software</i> com o sistema de aquisição de dados	Via padrão de Comunicação industrial OPC ou Profibus International communications.
Instalação do <i>software</i>	O <i>software</i> deverá ser instado em servidor ou em computador próprio com IHM próprio, interligado diretamente com o supervisório.
Biblioteca de blocos	Criação de biblioteca de blocos e <i>toolbox</i> específicos.
Interação como o módulo de gestão de alarmes	Via padrão de Comunicação industrial OPC ou Profibus International communications.

Todos os sistemas interativos têm de fornecer algum modo de apresentação de informações aos usuários. A apresentação de informações pode ser simplesmente uma apresentação direta das informações de entrada processadas (por exemplo, texto em um processador de texto (tabelas .txt)) ou pode apresentar as informações graficamente. No projeto a ser desenvolvido a apresentação deverá ser no formato de gráficos dinâmicos e *on-line* (tempo real), pois as informações instantâneas são necessárias para tomada de decisão por parte do operador.

O diagnosticador de falhas deverá ser auxiliado por um segundo diagnosticador no qual avalia a falha ocorrida do ponto de vista da energia processada pelo processo. As Tabelas 6.2 e 6.3 apresentam as especificações técnicas do *software* a ser desenvolvido. Para as definições das características de projeto, é levada em consideração que a planta já se encontra bem instrumentada e como um sistema de controle em funcionamento.

Tabela 6.2. Especificações técnicas: módulo – processos do tipo caixa-branca.

Atividades	Especificação
1. Modelagem do processo	<ul style="list-style-type: none"> • Modelar o processo utilizando as leis físicas que regem os fenômenos de transformação envolvidos no processo. <ul style="list-style-type: none"> ✓ Implementar a equação de balanço de massa, definida no fluxograma da Figura 5.2. ✓ Programar a equação de balanço de energia definida no fluxograma da Figura 5.2. ✓ Unir as a equação de energia e de massa em um modelo de espaço de estados.
2. Modelagem dos sensores e atuadores	<ul style="list-style-type: none"> • Desenvolver aproximações para os sinais medidos. <ul style="list-style-type: none"> ✓ Implementar as equações e curvas que descrevem a dinâmica de cada sensor e atuador instalado. Tais informações estão disponíveis nos catálogos do fabricante.
3. Geração de resíduos	<ul style="list-style-type: none"> • Uso de técnicas analíticas para geração de resíduos <ul style="list-style-type: none"> ✓ <i>Equações de paridade ou relação de consistência.</i> Configurar o sistema modelado para que fique idêntico ao definido pela equação (2.11); Implementar as equações (2.15), (2.16) e (2.17). O resíduo é aquele definido pela equação (2.17). ✓ Observadores de estado. Configurar o sistema para que fique conforme equação (2.5); Calcular matriz L; Implementar a equação que define o resíduo (equação 2.9). ✓ Identificação paramétrica. Implementar o algoritmo definido na página 19 deste documento, onde a equação de erro de estimação é o resíduo da variável. ✓ Filtro de Kalman. Implementar as equação 2.20, o erro de estimação é o resíduo da técnica. • Uso da técnica mais eficiente para entrada e saída, conforme definido neste documento. • Criação de um banco de resíduos, organizados num matriz onde as linhas são os resíduos das variáveis mensuráveis e as colunas a técnica de geração (no caso, quatro).
4. Geração de limiares adaptativos	<ul style="list-style-type: none"> • Usar o roteiro definido na Seção 3.3.4. Lembrar que a variável de saída deste algoritmo é o limite superior e inferior de operação no tempo. • Aplicar o roteiro para cada resíduo gerado por cada uma das técnicas analíticas de geração de resíduos.
5. Sinalização de alarmes	<ul style="list-style-type: none"> • Lógica de decisão: classificação do banco de resíduos, por lógica combinacional para falhas nos sensores, nos

	<p>atuadores e na planta, para que seja feito um banco de alarmes;</p> <ul style="list-style-type: none"> • Computar os sinais de alarmes. Sinais binários onde “0” representa que não houve falha e “1”, sinalizando a ocorrência de falha, toda vez que o resíduo exceder repetidas vezes os limiares de controle. • Computar a magnitude da severidade da falha (usar equação 3.2) e enviar para o submódulo de controle tolerante.
6. Controle tolerante	<ul style="list-style-type: none"> • Receber o sinal de estimativa da magnitude da falha; • Reconfigurar a lei de controle conforme fluxograma da Figura 3.9. • Enviar os sinais de controle aos atuadores instalados (observar diagrama de blocos da Figura 3.1).
7. Diagnosticador energético	<ul style="list-style-type: none"> • Computar os aportes energéticos envolvidos no processo (energia de alimentação (equação 5.10), energia consumida (equação 5.17), energia entregue (5.21) e a eficiência energética do processo (ver fluxograma da Figura 5.2)).
8. Apresentação de informações	<ul style="list-style-type: none"> • Apresentar como saída do sistema em IHM específica: <ul style="list-style-type: none"> ✓ Todos os sinais lógicos de ocorrência (alarmes) de falhas na planta, nos sensores e nos atuadores. ✓ Todos os sinais temporais dos resíduos de cada variável na forma de carta de controle de qualidade. ✓ Todas as variáveis controladas e monitoradas. ✓ Estimativa da magnitude da falha ocorrida. ✓ Aporte energético de entrada do processo. ✓ Energia consumida na unidade processual. ✓ Energia entregue pela unidade processual (<i>energy output</i>). ✓ Eficiência energética da planta industrial. • Envio de todas as variáveis apresentadas na IHM própria do sistema ao supervisor da planta para apresentação na IHM da planta.
9. Banco de dados	<ul style="list-style-type: none"> • Armazenar em uma matriz de dados o histórico das faltas mais deletérias e ocorrentes no processo (servidor de dados), onde as linhas representam o tempo e as colunas representam as falhas (falha no atuador, falha no sensor e falha no processo).

Tabela 6.3. Especificações técnicas: módulo – processos do tipo caixa-preta.

Atividades	Especificação
1. Aquisição de dados	<ul style="list-style-type: none"> • Receber como entrada do diagnosticador estatístico a matriz de dados processada e organizada pelo sistema de aquisição de dados, as linhas são as amostras no tempo e as colunas são as variáveis medidas. • Receber do sistema de aquisição o número de sensores e de atuadores instalados (variáveis mensuráveis). • Identificar e separar as variáveis de entrada (sinais dos

	<p>atuadores) da planta e as variáveis de saída da planta (sensores). As primeiras colunas estarão agrupadas as variáveis de entrada da planta e as últimas as variáveis de saída, identificar a partir da informação do número de atuadores a coluna de transição e sinalizar.</p>
<p>2. Análise de correlação de sinal</p>	<ul style="list-style-type: none"> • Etapa <i>off-line</i>: aplicar sinais perturbadores na planta, definidos conforme roteiro da Seção 4.5 e coletar os dados de entrada e saída da planta por meio da camada de instrumentação; implementar as equações (4.1),(4.2) e (4.4) para base de dados coletados; calcular os limites e controles para as cartas Q e τ^2, conforme equações (4.8) e (4.11), verificar fluxograma da Figura 4.1. • Etapa <i>on-line</i>: Calcular as estatísticas Q e τ^2, usando as equações (4.5) e (4.7); plotar em mesmo gráfico a estatística Q e os seus respectivos limites de controle de qualidade; plotar em mesmo gráfico a estatística τ^2 e os seus respectivos limites de controle de qualidade. • Comparar as estatísticas multivariadas com os limiares de controle, se $Q_i > LSC_{i_{SPE}}$ ou $Q_i < 0$ e $T_i^2 > LSC_{i_{T2}}$ ou $T_i^2 < 0$, sinalizar a detecção da falha (plotar um gráfico de sinal lógico, “0” ou “1”, no tempo). • Registrar <i>on-line</i> o instante de tempo da ocorrência da falha. • Como solução alternativa para definição dos limiares optar pelo roteiro detalhado na Seção 3.3.4. • Verificar o fluxograma descritivo da Figura 4.1.
<p>3. Identificação da falha</p>	<ul style="list-style-type: none"> • Sincronizar a contribuição das variáveis com a detecção da anormalidade. • Computar os gráficos de contribuição das variáveis na ocorrência da falha, para cada estatística multivariada, usar as equações (4.12) (4.13), respectivamente. • Estimar a severidade da falha, usar equação (4.13) e enviar para o sub-módulo de mitigação de falhas; • Apresentar na IHM própria o gráfico de contribuição das variáveis no instante de ocorrência da falha para estatística Q; • Apresentar na IHM própria o gráfico de contribuição das variáveis no instante de ocorrência da falha para estatística τ^2; • Se $con^{\tau^2}(x_i) > 2\%$ e $con^{SPE}(x_i(k)) > 2\%$, sinalizar (gráfico binário) defeito no instrumento $x_i(k)$.
<p>4. Mitigação da falha</p>	<ul style="list-style-type: none"> • Identificar o vetor direção de falhas, usar para isso os gráficos de contribuição das variáveis, construir um vetor linha onde as colunas representam as variáveis mensuráveis da planta industrial, o instrumento defeituoso sinalizado vale “1” e o componente sadio vale “0”, a dimensão de tal vetor será $(1 \times m)$, onde m corresponde as m variáveis mensuráveis.

	<ul style="list-style-type: none"> • Sincronizar a reconstrução da falha como o tempo de detecção e identificação da falha, visando mitigar o mais rápido possível, minimizando os prejuízos causados. • Reconstruir os sinais perdidos com a ocorrência da falha, usando o vetor direção de falha e estimativa da magnitude de falha, usar para isto a equação (4.15), computar esta equação para reconstruir o vetor de medições. • Executar a etapa definida na atividade 2 da Tabela 6.3, iniciando da etapa <i>on-line</i>, para comprovar a mitigação ou eliminação da falha.
5. Diagnosticador energético	<ul style="list-style-type: none"> • Computar os aportes energéticos envolvidos no processo (energia de alimentação (equação 5.10), energia consumida (equação 5.17), energia entregue (5.21) e eficiência energética do processo, ver fluxograma da Figura 5.2).
6. Apresentação de informações	<ul style="list-style-type: none"> • Apresentar como saída do sistema em IHM específica: <ul style="list-style-type: none"> ✓ Carta de controle estatístico de Hotelling (τ^2). ✓ Carta de controle estatístico Q (SPE). ✓ Todas as variáveis controladas e monitoradas. ✓ Alarme de sinalização de detecção de falha. ✓ Alarme de sinalização dos componentes defeituosos. ✓ Aporte energético de entrada do processo. ✓ Energia consumida na unidade processual. ✓ Energia entregue pela unidade processual (<i>energy output</i>). ✓ Eficiência energética da planta industrial. • Envio de todas as variáveis apresentadas na IHM própria do sistema ao supervisor da planta para apresentação na IHM da planta. • Relatório estatístico de ocorrência e sinalização de falhas.
7. Banco de dados	<ul style="list-style-type: none"> • Armazenar em uma matriz de dados o histórico das faltas mais deletérias e ocorrentes no processo, onde as linhas representam o tempo e as colunas representam as falhas (falha no atuador, falha no sensor e falha no processo).

O estágio de implementação do desenvolvimento de *software* é o processo de conversão de uma especificação de sistema em um sistema executável. Ele sempre envolve os processos de projeto e de programação de *software*, mas, for praticada uma abordagem evolucionária, pode também envolver o refinamento da especificação de *software*.

O processo de projeto pode envolver o desenvolvimento de vários modelos do sistema em diferentes níveis de abstração. Como o projeto é decomposto, os erros e as omissões em estágios anteriores são descobertos. Com as especificações técnicas apresentadas, pretende-se partir para fase de projeto e programação e que não é escopo deste Projeto de Conclusão de Curso (TCC). Um documento técnico com as especificações e mais detalhes do software DiaFault 1.0 deve ser elaborado para que seja repassado para equipe de programadores.

6.3. Gerenciamento eficiente de alarmes

A implantação da automação no ambiente industrial, bem como seu aperfeiçoamento posterior, mantendo a confiabilidade, a produtividade e a segurança, pede um consciencioso planejamento estratégico por parte da engenharia da organização, seja da fornecedora do sistema, seja da própria indústria, trata-se, portanto da gestão da automação.

Um alarme é um anúncio para o operador iniciado por uma condição de mau funcionamento de equipamento, desvio de processo ou condição anormal que requer uma ação. O anúncio pode ser feito por meio de sons audíveis, indicações visuais como piscar de luzes e textos, mudança de cor de fundo ou texto, mudanças gráficas e de figuras ou ainda por mensagens. Um alarme é uma representação por meio da qual uma das características do processo é identificada e configurada em sistema binário para caracterizar estado "em alarme" ou "limpo" - ou seja, não em alarme. A condição de alarme é passada ao operador por meios de sons e anúncios colocados em unidades de vídeo ou outros dispositivos para chamar a atenção. O operador pode controlar esses sons e anúncios por meio de comandos específicos da plataforma, ou sistema de alarme, tais como "silenciar o alarme" ou "reconhecer o alarme". Normalmente, esta plataforma de alarme é parte integrante da infraestrutura do sistema de controle do processo (Araújo, 2010).

Usando de técnicas da gestão da automação, propõe-se uma metodologia para uma política estratégica de gerenciamento de alarmes, de modo que minimize o falso alarme e aumente a probabilidade de detecção da falha. A ideia é usar de técnicas de controle de qualidade (controle estatístico) associadas a técnicas inteligentes (redes neurais e *fuzzy*) na geração de limiares robustos. Tais técnicas são combinadas de modo a ter um banco de alarmes que avaliados e testados darão uma decisão precisa do alarme geral, como um único sinal. A configuração do sistema proposto para gestão de alarmes é ilustrado na Figura 6.3.

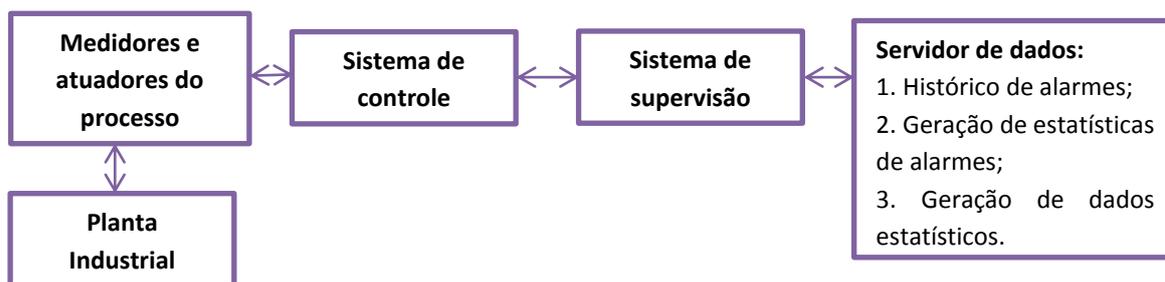


Figura 6.3. Configuração do sistema de gestão de alarmes.

Os sinais medidos no campo pela camada de instrumentação são realimentados por lei controle de realimentação específica (CLP - Controlador Lógico Programável), entregando energia a bombas, motores e diversos atuadores espalhados na planta industrial, levando as saídas controladas seguirem as devidas especificações técnicas de malha fechada, tais sinais (de controle, de atuadores e de medidores), são captados pelo sistema de aquisição de dados que os envia para o módulo diagnosticador de falhas, este

os repassa para o sistema supervisório do processo, os quais são acessíveis ao operador por meio da IHM (*Interface Human Machine*) do supervisório do processo, auxiliando o módulo de supervisão está o módulo diagnosticador de falhas e o sistema de gestão de alarmes. O sistema de gestão realiza basicamente três operações (atividades), registra por meio de servidor próprio o histórico de alarmes do processo, gerando um banco de dados próprio de alarmes ocorridos; processa as estatísticas de ocorrências de anormalidades e apresenta na IHM do processo e gera relatórios de dados estatísticos, das características dos alarmes ocorridos e da magnitude de cada alarme.

O registro de alarmes que compõe o banco de dados é gerado pelas diversas técnicas geradoras de resíduos ou pelas cartas de controle estatístico, se a análise de padrão sair da faixa de operação (limite superior de controle e limite inferior de controle) por determinado intervalo de tempo, é caracterizado o alarme, os sinais de alarme são agrupados em uma matriz de dados que compõe o banco. A importância de manter ou possuir uma base de dados do histórico dos alarmes ocorridos no processo está no fato de se poder planejar uma manutenção preventiva e corretiva mais eficiente, bem como estudar e buscar soluções para tais vistos que dados estatísticos são apresentados.

A geração de estatísticas consiste em apresentar gráficos ou tabelas que descreva as estatísticas de cada tipo de alarme, especificamente, número de alarmes por dia; duração do alarme; alarme mais frequentes; taxa de picos de alarmes; percentual de instabilidade; gravidade do risco envolvido pelo alarme (baixo, médio ou alto), também chamado de distribuição de prioridades; distribuição de alarmes por setores operacionais e percentuais de cada tipo de alarme. Tais gráficos estarão disponíveis na tela (IHM) do computador do operador, para que o mesmo esteja acompanhando de perto o que está acontecendo no chão de fábrica, ao mesmo tempo também estão sendo assistido pelo sistema de supervisão.

Ao fim do dia ou turno de operação da planta industrial é gerado um relatório dos alarmes ocorridos, informando a localização, a magnitude, a periodicidade, as estatísticas, tal documento pode ser usado sem perda alguma para compor o relatório de operação diário da unidade processual. O relatório consiste em tabelas .txt ou .xls, informado todos os dados estáticos associados ao alarmes em formato fácil e acessível ao operador ou ao coordenador de cada setor produtivo.

É importante destacar que o sistema de gestão de alarmes é totalmente automatizado. A requisição dos cálculos das análises estatísticas é feita pelo sistema de supervisão nos primeiros segundos de cada dia e os dados gerados são carregados nas telas de monitoramento assim que o operador as seleciona. Esta solução difere da grande maioria dos trabalhos publicados nesta área, já que eles utilizam *softwares* comercializados por empresas de sistemas de automação. Outra importante característica da solução de gerenciamento de alarmes proposta é sua integração com o sistema de supervisão. Uma vez que os operadores possuem muitas atribuições, uma aplicação independente poderia tornar a ferramenta subutilizada.

Capítulo 7

Conclusões e trabalhos futuros

A solução proposta para detecção, isolamento de falhas baseada em modelos mostrou-se eficiente quando avaliada para o tanque de pré-aquecimento de água operando em malha fechada, em termos da identificação de condições anormais de funcionamento, bem como a metodologia para reconfiguração da lei de controle quando da ocorrência de falhas em sensores e atuadores.

Tendo em vista, o classificador lógico está utilizando limiares fixos discutiu-se uma metodologia para consecução de limiares adaptativos, os quais devem ser definidos pelas informações estatísticas e históricas do processo, de modo a minimizar a ocorrência de falsos alarmes ou a perdas de alarmes (fato que compromete o controle tolerante). Ainda que no estudo realizado tenha sido utilizada uma lei de controle clássica para controlar a planta, o procedimento para prognóstico de falhas em sistemas industriais proposto é relativamente independente, sendo possível utilizá-lo no caso de outras estratégias de controle.

A solução proposta para detecção, isolamento e mitigação de falhas via PCA mostrou-se eficiente quando avaliada para a fracionadora de óleo cru operando em malha fechada, em termos da identificação de condições anormais de funcionamento, bem como da reconstrução de medições quando da ocorrência de falhas em sensores e atuadores. Mesmo considerando que o Processo *Shell* é amplamente utilizado como problema de referência em estudos de controle avançado, vale destacar que o estudo realizado indica que a implementação do sistema de diagnóstico demandaria somente quatro dos sete sensores usualmente utilizados.

Tendo em vista que a solução PCA proposta demanda a realização de experimentos para caracterizar a condição de operação normal da planta, preconiza-se a execução de um procedimento de teste inicial no qual os sinais de referência são perturbados por sinais de forma, amplitude e frequência específicos. A definição desses parâmetros é baseada nas especificações de desempenho de malha fechada (e.g., período de amostragem, tempo de estabelecimento, limites dos sinais de referência e das variáveis manipuladas) e na análise da correlação das variáveis manipuladas e das variáveis de saída. Ainda que no estudo realizado tenha sido utilizada uma lei de controle preditivo multivariável para controlar a planta, o procedimento de teste proposto é relativamente independente, sendo possível utilizá-lo no caso de outras estratégias de controle.

O sistema proposto para gestão de alarmes em processos industriais embora esteja sendo direcionada para uma planta industrial específica, pode ser avaliado/aplicado em outras unidades, não dispensando uma consultoria técnica e projeto específico para cada unidade pela equipe projetista. O projeto arquitetural especificado deve ser reavaliado levando em consideração informações específicas de requisitos de desempenho e processamento de dados, mas da maneira especificada já atende aos objetivos de projeto alocados. O maior problema enfrentado atualmente na engenharia de requisitos, está relacionado com a definição do que o sistema deve fazer, suas propriedades emergentes

desejáveis e essenciais e as restrições quanto a operação do sistema e quanto aos processos de desenvolvimento de software. Neste contexto se os requisitos de especificação técnica forem bem delineados, as etapas seguintes do processo de software, serão executadas com maior flexibilidade e com menor ocorrência de erros que fazem o processo atrasar ou até mesmo parar (ser reprovado pelo órgão financiador).

Como trabalhos futuros que podem ser desenvolvidos para a continuação do trabalho iniciado nesta monografia, sugere-se:

1. Modelagem de um número maior de falha para a fracionadora de óleo pesado.
2. Simulação da fracionadora em ambiente *Aspen Plus*® *Software* ou no *Aspen HYSYS*® *Software* ambos da *Aspen Technology Corporation*.
3. Implementação industrial do sistema de diagnóstico de falhas via PCA proposto (desenvolvimento de um *software*).
4. Inserção do modelo dos sensores/atuadores no sistema de monitoramento de falhas e gestão de alarmes.
5. Estudo da comunicação do diagnosticador de falhas com o supervisor do processo.
6. Desenvolvimento de lógica de decisão do diagnosticador com limiares adaptativos estatísticos.
7. Desenvolvimento de lógica de decisão do diagnosticador com limiares adaptativos inteligentes (redes neurais ou *fuzzy*).
8. Para análise de correlação da matriz de dados do processo foi utilizado três técnicas: PCA linear, SPE e estatística de Hotelling. Usar outras técnicas de estatística multivariada tais como: PCA recursiva, Kernel PCA, PCorrA (*Principal Correlation Analysis*), mínimos quadrados parciais (*PLS- Partial Least Squares*), análise do discriminante de Fisher e análise de componente independente (*ICA- Independent Component Analysis*).

Por fim, o autor espera que este trabalho possa ser uma plataforma para estudos na área de detecção e diagnóstico de falhas em sistemas de controle e instrumentação industrial.

Referências bibliográficas

Aguirre, L. A. **Introdução a Identificação de Sistemas: Técnicas Lineares e Não-Lineares Aplicadas a Sistemas Reais**. 2004. 2ª edição, Editora UFMG.

Alexandre G.B., Lima A.M.N. & Neto J.S.R. **Monitoramento de eventos anormais em processos industriais via análise de componentes principais**. In: Congresso Brasileiro da Automática (CBA), 2012, Campina Grande, pp. 1-8, (a).

Alexandre G.B. & Lima A.M.N. **Estratégia baseada em modelos para prognóstico de falhas em sistemas industriais**. In: IX Congresso de Iniciação Científica da Universidade Federal de Campina Grande, 2012, Campina Grande, pp. 1-14 (b).

Alexandre G.B., Lima A.M.N. & Neto J.S.R. **Otimização do uso de energia em sistemas de instrumentação industrial**. In: VIII Congresso de Iniciação Científica da Universidade Federal de Campina Grande, 2011, Campina Grande, pp. 1-13.

Alexandre G.B. & Lima A.M.N. **Diagnose de falhas e gestão eficiente de alarmes em sistemas de instrumentação e controle industrial**. In: VIII Congresso Norte e Nordeste de Pesquisa e Inovação (CONNEPI), 2013, Salvador, pp. 1-10.

Araújo, E. V. **Gerenciamento de Alarmes em Plantas Industriais: Conceitos, Normas e Estudo de Caso em um Forno de Reaquecimento de Blocos**. Master Thesis, Departamento de Engenharia Elétrica, Universidade Federal de Minas Gerais, Belo Horizonte - MG, 2010.

Ansari, R. M. & Tadé, M. O. **Non-Linear Model-Based Process Control Applications in Petroleum Refining**. Springer-Verlag, London, 2000.

Bhattacharjee N. & Roy B. K. **Fault Detection and Isolation of a Two Non-Interacting Tanks System Using Partial PCA**. 2010 International Conference on Industrial Electronics, Control and Robotics (IECR). IEEE. 2010, 137-41. Piscataway, NJ, USA.

Bin Shams M. A., Budman H. M., Duever T. A. **Fault Detection, Identification and Diagnosis Using CUSUM Based PCA**. Chemical Engineering Science, vol. 66, nº 20, 15 Oct. 2011, 4488-98. Publisher: Elsevier Science Ltd., UK.

Bose M. S. R. K., Kumar Sathyendra & Venkateswarlu Ch. **Detection, Isolation and Reconstruction of Faulty Sensors Using Principal Components Analysis**. Indian Journal Technology, v. 12, July 2005, pp.430-435.

Councill, W. T. & Heineman, G. T. **Component-Based Software Engineering: Putting the Pieces Together**. Addison-Wesley, USA, 2001.

Chow, E. Y.; Willsky, A. S. **Analytical Redundancy and the Design of Robust Failure Detection Systems**. 1984. *IEEE Transactions on Automatic Control*, pp. 29:603-614.

Dunia, R., Qin, J., Edgar, T., Mcavoy, T. **Identification of Faulty Sensors Using Principal Component Analysis**. *AIChE Journal*, v.42, n.10, pp.2797-2812, 1996 (a).

Dunia, R., Qin, J., Edgar, T., Mcavoy, T., **Use of Principal Component Analysis for Sensor Fault Identification**. *Computers and Chemical Engineering*, 20, pp. 713-718, 1996 (b).

Gertler, J. J. **Analytical Redundancy Methods in Fault Detection and Isolation, Survey and Synthesis**. 1991. IFAC Safe Process Conference, vol. 1. Baden-Baden, Germany, pp 9-22.

Gertler, J.J. **Survey of Model-Based Failure Detection and Isolation in Complex Plants**. 1988. *IEEE Control System Magazine*, vol. 8, n. 6, pp. 3-11.

Halligan G. R., Jagannathan S. **PCA-Based Fault Isolation and Prognosis With Application to Pump**. *International Journal of Advanced Manufacturing Technology*, vol. 55, n° 5-8, July 2011, 699-707. Publisher: Springer-Verlag London Ltd., UK.

Hangos K. M. & Cameron I. R. **Process Modeling and Model Analysis**. Academic Press, 2001.

Haykin S. **Kalman Filtering and Neural Networks**. 2001. John Wiley & Sons, Interscience.

Jackson, J. E. & Mudholkar, G. S. **Control Procedures for Residuals Associated with Principal Component Analysis**. *Technometrics*, 1979, 21(3), 341–349.

Jeng Jyh-Cheng, Li Cheng-Chih, Huang Hsiao-Ping **Fault Detection and Isolation for Dynamic Processes Using Recursive Principal Component Analysis (PCA) Based on Filtering of Signals**. *Asia-Pacific Journal of Chemical Engineering*, vol. 2, n° 6, Nov-Dec, 2007, 501-9. Publisher Jonh Wiley & Sons Ltd, UK.

Kano, M., Nagao, K., Ohno, H., Hasebe, S., Hashimoto, I. **Dissimilarity of Process Data for Statistical Process Monitoring**. *Proceedings of IFAC Symposium on Advanced Control of Chemical Processes*, v. 1, pp. 231-236, 2000.

Kinnaert M. **Fault Diagnosis Based Analytical Models for Linear and Nonlinear Systems- a Tutorial**. 2003. Session plenieré. *Acts de Safe process 2003*, Washington DC, pp. 37-50.

Ku, W., Storer, R.H., Georgakis, C. **Disturbance Detection and Isolation by Dynamic Principal Component Analysis**. *Chemometrics and Intelligent Laboratory Systems* 30, 1995, pp. 179–196.

Ljung L. **System Identification: Theory for the User**. 1999. Second edition, Prentice Hall Information and System Sciences Series.

Mathwoks- Statistics Toolbox- Princomp.

Disponível em: www.mathworks.com/help/stats/princomp.html, Acesso: 25/05/2013.

Montgomery, D. C. **Introdução ao Controle Estatístico da Qualidade**. 4ª edição. Rio de Janeiro: LTC, 2004, 532 p.

Moreira, A. M., Pellanda, A. P., Veloz, C. S. C., Butrimavicius, P. J., Porto, M. F., Ahón, V. R. R. & Costa, A. L. H. **Estudo Energético da Integração Energética de uma Unidade de Destilação Atmosférica e Vácuo**. 2007, 4º PDPetro, Campinas, São Paulo.

Neto, J. L. P. **Detecção e Isolamento de Falta em Motores de Indução Utilizando Técnicas de Inteligência Computacional**. 2006. Dissertação de mestrado Pontifícia Universidade Católica de Minas Gerais, Belo Horizonte- Brasil.

Oliva, Á. P. **Sensor Fault Detection and Analytical Redundancy Satellite Launcher Flight**. 1998. Control System, SBA Controle & Automação, vol. 9, n. 3, pp. 156-164.

Ogata K. **Engenharia de Controle Moderno**. 2001. 4ª edição, Prentice Hall.

Prett, D. M. & Morari, M. **The Shell Process Control**; Workshop, Butterworth Publisher, Boston, 1987.

Patton, R. J.; Jie C. **Robust Model-Based Fault Diagnosis for Dynamic Systems**. 1989. The International Series an Asian Studies Computer and Information Science.

Santana, B.G. **Detecção e Diagnóstico de Situações Anormais em Sistemas de Separação de Água-Óleo-Gás**. Trabalho de conclusão de curso, Departamento de Engenharia Elétrica. UFES, 2009.

Sommerville, Ian **Software Engineering**. 9th edition. Person Education International, USA, 2011.

Shen Yin, Steven X. D., Naik A., Pengcheng Deng, Haghani A. **On PCA-Based Fault Diagnosis Techniques**. 2010 Conference on Control and Fault-Tolerant Systems (SysTol). IEEE. 2010, 179-84. Piscataway, NJ, USA.

Simani, S.; Fantuzzi, C.; Patton, R. J.; 2002, **Model-Based Fault Diagnosis In Dynamic Systems Using Identification Techniques**. Springer-Verlag: Berlin.

Sotomayor, O. A. L.; Odlak, D. **Observer-Based Fault Diagnosis in Chemical Plants**. 2005. Chemical Engineering Journal, vol. 12, pp. 93-108.

Tarantino, R. & Szigeti F. **Generalized Luenberger Observer-Based Fault Detection Filter Design: an Industrial Application**. Control Engineering Practice, Vol. 8, pp. 665-671, 2000.

Teixeira, A. J. **Detecção, Identificação e Reconfiguração de Falhas Múltiplas em Sensores de Sistemas Lineares Invariantes no Tempo**. 2007. Tese de doutorado, Instituto Nacional de Pesquisas Espaciais- INPE, São José dos Campos- Brasil.

Teixeira, A. J.; Souza, M. L. O.; Oliva, Á. P. **Multiple Faults Detection and Isolation in Sensors of Dynamic Systems**. 2005. SAE BRASIL 2005 Congress, Doi: 2005-01-4136.

Welch, G.; Bishop, G. **An Introduction to the Kalman Filter**. 2006. "TR 95-041", Department of Computer Science, University of North Carolina.

Yoneyama, T. **Detecção de Falhas, Baseado em Modelo**. 2009. Notas de aulas, Disponível em: <http://www.ele.ita.br/~takashi/didatico.htm> .

Apêndices

A.1 Características dinâmicas da coluna fracionadora de óleo pesado

A fracionadora é representada por um modelo dinâmico descrito por um conjunto de funções de transferências com vários atrasos no tempo. A sua avaliação para fins de controle pode ser obtida pela resposta ao degrau unitário aplicado a coluna. A resposta ao degrau do processo é apresentada na Figura A.1 mostrando que a planta é assintoticamente estável e que os tempos de estabilização variam aproximadamente de 10 segundos até 250 segundos.

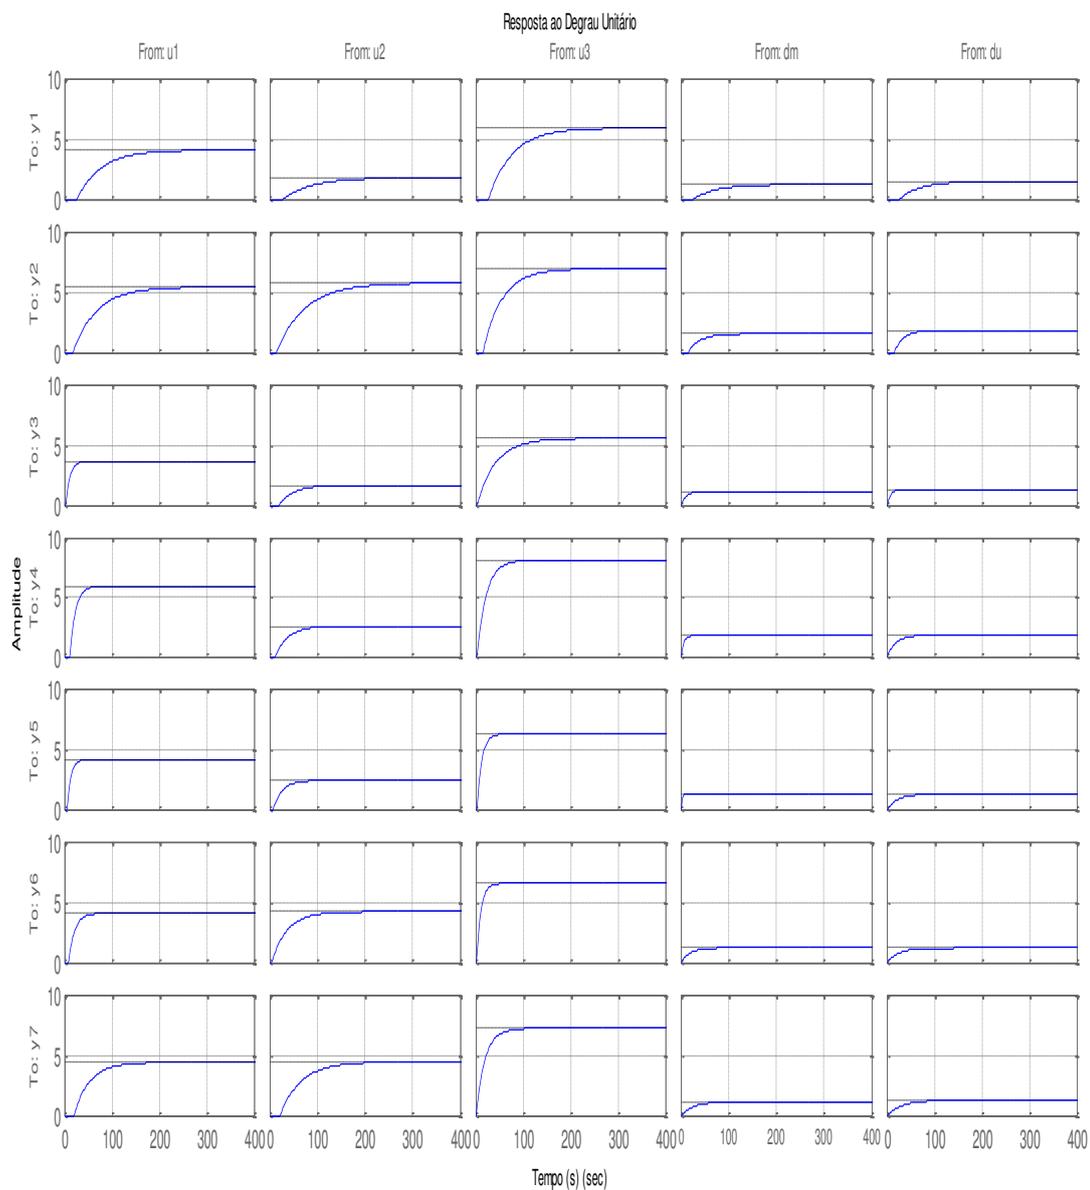


Figura A.1 – Resposta da coluna *Shell* ao degrau unitário.