



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA QUÍMICA
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA QUÍMICA



Metodologia para o Monitoramento de Sistemas de Controle na Indústria Química

Davi Leonardo de Souza

Uberlândia - MG
2011

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA QUÍMICA
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA QUÍMICA

Metodologia para o Monitoramento de
Sistemas de Controle na
Indústria Química

Davi Leonardo de Souza

Uberlândia - MG
2011

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA QUÍMICA
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA QUÍMICA

Metodologia para o Monitoramento de
Sistemas de Controle na
Indústria Química

Davi Leonardo de Souza

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Engenharia Química da Universidade Federal de Uberlândia como parte dos requisitos necessários à obtenção do título de Doutor em Engenharia Química, área de concentração Desenvolvimento de Processos Químicos.

Uberlândia - MG
2011

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da UFU, MG - Brasil

C198a Souza, Davi Leonardo de, 1981-
Metodologia para o monitoramento de sistemas de controle
na indústria química / Davi Leonardo de Souza. - 2011.
151 f. : il.

Orientador: Luís Cláudio Oliveira Lopes.

Tese (doutorado) – Universidade Federal de Uberlândia,
Programa de Pós-Graduação em Engenharia Química.
Inclui bibliografia.

1. Engenharia química - Teses. 2. Controle de processos
químicos - Teses. I. Lopes, Luís Cláudio Oliveira. II. Universida-
de Federal de Uberlândia. Programa de Pós-Graduação em
Engenharia Química. III. Título.

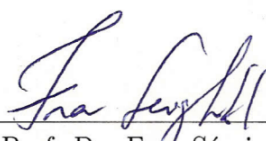
CDU: 66.0

TESE DE DOUTORADO SUBMETIDA AO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA DA UNIVERSIDADE FEDERAL DE UBERLÂNDIA COMO PARTE DOS REQUISITOS PARA OBTENÇÃO DO TÍTULO DE DOUTOR EM ENGENHARIA QUÍMICA EM 28 DE NOVEMBRO DE 2011.

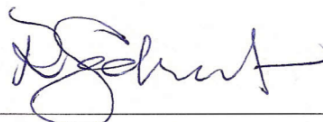
BANCA EXAMINADORA:



Prof. Dr. Luís Claudio Oliveira Lopes
(Orientador - PPGEQ/UFU)



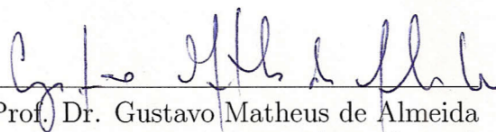
Prof. Dr. Fran Sérgio Lobato
(FEQUI/UFU)



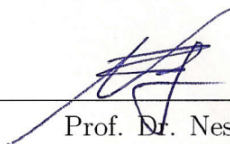
Prof. Dr. Rubens Gedraite
(FEQUI/UFU)



Prof. Dr. Luís Fernando Faina
(FACOM/UFU)



Prof. Dr. Gustavo Matheus de Almeida
(DEQUE/CAP/UFSJ)



Prof. Dr. Nestor Roqueiro
(DAS/UFSC)

Agradecimentos

Primeiramente a Deus pela sua misericórdia em me conceder a fé e a capacidade de desenvolver este trabalho.

A minha esposa Juliana, por todo carinho, incentivo, paciência e orações ao meu favor.

Aos meus pais, Landoaldo e Glória, pela dedicação em toda a minha vida para que eu conseguisse alcançar os meus objetivos, me ensinando os valores necessários desde os primeiros passos da minha vida, e a minha irmã Débora, pela força, incentivo e orações ao meu favor, para que meus objetivos fossem alcançados.

A meu sogro Lucas e minha sogra Regina, pela força, incentivo e orações ao meu favor, para que meus objetivos fossem alcançados.

Aos meus amigos e companheiros de curso: Adriene, Fran Sérgio, Marcos, Ricardo Corrêa, Ricardo Malagoni, Ricardo Pires, Sandra e Francis, pela força e incentivo ao longo do meu trabalho.

Aos meus amigos Adriano e Sabrina, pela amizade, carinho e orações ao meu favor.

Aos meus amigos Professores da UFSJ, Demian, Edson Nucci, Eduardo, Cristiane Finzi, Karina, Néstor e Patrícia, pela amizade, carinho, força e incentivo.

Ao Professor Luís Cláudio Oliveira Lopes pela orientação técnica na produção deste trabalho, e principalmente pela amizade e confiança.

Aos professores da FEQUI, e aos membros da banca.

A CAPES pela concessão de 3 anos de bolsa de estudo, e a Universidade Federal de São João Del-Rei (UFSJ).

“Adquire a sabedoria, adquiere a inteligência, e não te esqueças nem te apartes das palavras da minha boca”

Provérbios 4:5

A minha esposa e aos meus Pais

SUMÁRIO

Lista de Figuras	xv
Lista de Tabelas	xix
Lista de Abreviaturas	xxi
Lista de Símbolos	xxi
Resumo	xxv
Abstract	xxvii
1 Introdução	1
1.1 Por que monitorar e avaliar sistemas de controle?	1
1.1.1 Aspectos fundamentais	1
1.2 Monitoramento de sistemas de controle	4
1.3 Gerenciador de desempenho	8
2 Revisão bibliográfica	11
2.1 Cálculo do índice de desempenho	11
2.1.1 Cálculo do índice de desempenho utilizando controle de variância mínima (MVC)	21
2.2 Detecção de oscilações	32

2.3	Detecção do emperramento de válvulas	34
2.4	Detecção de falhas: perturbações e sensores	43
2.4.1	Análise dos componentes principais (PCA)	43
2.4.2	Técnicas para redução de ordem	47
3	Monitoramento de sistemas de controle na indústria química	51
3.1	Metodologia para o monitoramento	51
3.2	Cálculo do índice de desempenho	53
3.2.1	Fatoração de modelos para o cálculo do índice de desempenho	54
3.2.2	Matriz de interação generalizada (GIM)	57
3.3	Detecção de oscilações	63
3.3.1	Análise Karhunen-Loève e Periodograma	63
3.4	Detecção do emperramento de válvulas	66
3.5	Detecção de falhas: perturbações e sensores	70
3.5.1	O uso da estatística para o monitoramento de sistemas	70
4	Resultados e Discussões	75
4.1	Cálculo do índice de desempenho	76
4.1.1	Coluna de destilação binária	76
4.1.2	CSTR isotérmico	79
4.1.3	Tanque para o aquecimento de substâncias	84
4.2	Detecção de oscilações	93
4.2.1	Sinais sintéticos	93
4.2.2	Reatores em série	95
4.3	Detecção do emperramento de válvulas	101
4.3.1	Coluna de destilação de alta pureza	101
4.4	Detecção de falhas: perturbações e sensores	107
4.4.1	CSTR não-isotérmico	107
4.4.2	CSTR em série	116
4.5	Metodologia para o monitoramento	124

4.5.1	Cálculo do índice de desempenho	124
4.5.2	Detecção de oscilações	125
4.5.3	Detecção do emperramento de válvulas	125
4.5.4	Detecção de falhas: perturbações e sensores	126
5	Conclusões e Sugestões	129
5.1	Conclusões	129
5.1.1	Cálculo do índice de desempenho	129
5.1.2	Detecção de oscilações	131
5.1.3	Detecção do emperramento de válvulas	131
5.1.4	Detecção de falhas: perturbações e sensores	132
5.1.5	Contribuições	132
5.1.6	Publicações	132
5.2	Sugestões	133
	Referências Bibliográficas	144
	Apêndice A	145
	Apêndice B	149

LISTA DE FIGURAS

1.1	Esquema simples para a aplicação CPM/CPA	2
1.2	Esquema simples para o monitoramento e avaliação de sistemas de controle	2
1.3	Procedimento básico para a realização da CPM/CPA	4
1.4	Matriz de Desempenho	5
2.1	Linha do tempo para a aplicação do MVC	21
2.2	Interpretação da estratégia de controle GMV com <i>Preditor de Smith</i> .	27
2.3	Diagrama de blocos para um sistema de controle	31
2.4	Válvula de controle	35
2.5	Diagrama de blocos do sistema de controle <i>feedback</i>	35
2.6	Movimento da válvula	36
2.7	Relação entre OP e MV	37
2.8	Métodos para detecção do emperramento de válvulas	39
2.9	Sinais de entrada/saída da válvula	40
2.10	Estrutura Hammerstein	42
2.11	Espaço de menor dimensão	46
2.12	Modelagem da PCA	47
2.13	Procedimento <i>Scree</i> para cálculo de a	48
3.1	Gerenciador de desempenho	52

3.2	Diagrama de blocos - malha <i>feedback</i>	53
3.3	Projeto do sistema de referência	62
3.4	Características de uma válvula emperrada	66
3.5	Representação simbólica da movimentação da válvula	67
3.6	Padrões de movimento para válvula emperrada	67
3.7	Padrões adicionais ao método de Yamashita	69
4.1	Validação do modelo $G(q)$ frente a uma perturbação pulso	77
4.2	Desempenho do sistema de controle	79
4.3	Desempenho do sistema com fatoração do modelo sob variação de λ .	80
4.4	Comportamento dinâmico do sistema não linear e para a aproximação linear utilizada	82
4.5	Controle corrente PI	83
4.6	Comportamento do sistema fatorado sob ação de controladores PIs .	83
4.7	Índice de Desempenho para o CSTR isotérmico	84
4.8	Índice de Desempenho para o CSTR isotérmico utilizando o MVC como referência	85
4.9	Tanque de aquecimento	85
4.10	Excitação persistente para identificação	87
4.11	Identificação do modelo da planta	88
4.12	Histograma	89
4.13	Resíduos	89
4.14	Identificação do modelo da perturbação	90
4.15	Histograma	91
4.16	Resíduos	91
4.17	Desempenho do sistema de controle corrente	93
4.18	Dados sintéticos para análise de oscilação	94
4.19	Variância de $\lambda(n)$	94
4.20	Espectro de potência dos sinais aleatórios	95
4.21	Reatores contínuos em série	96

4.22	Dinâmica do sistema de reatores	98
4.23	Sinais de saída para o sistema de reatores	99
4.24	Variância de $\lambda(n)$ para o sistema de reatores	99
4.25	Espectro de potência para o sistema de reatores	100
4.26	Diagrama esquemático da coluna de destilação	103
4.27	Curva de operação do estado estacionário	103
4.28	Identificação em espaço de estados	104
4.29	Dinâmica sem a presença do emperramento	105
4.30	Dinâmica com a presença do emperramento	105
4.31	OP \times MV	106
4.32	CSTR não Isotérmico	107
4.33	Simulação da falha 1 - comportamento de h e q	110
4.34	Simulação da falha 1 - comportamento de T e q_C	110
4.35	Simulação da falha 2 - comportamento de h e q	111
4.36	Simulação da falha 2 - comportamento de T e q_C	111
4.37	Dados normais para h e q	112
4.38	Dados normais para T e q_C	113
4.39	Dados normais para C_A e T_C	113
4.40	Estatísticas T^2 e Q para os dados de operação normal	114
4.41	Estatísticas T^2 e Q para a falha 1 no CSTR não-isotérmico	115
4.42	Estatísticas T^2 e Q para a falha 2 no CSTR não-isotérmico	115
4.43	Simulação da falha 1 - comportamento de C_{A2} e C_{A0}	116
4.44	Simulação da falha 1 - comportamento de T_1 e T_{j10}	117
4.45	Simulação da falha 1 - comportamento de T_2 e T_{j20}	117
4.46	Simulação da falha 2 - comportamento de C_{A2} e C_{A0}	118
4.47	Simulação da falha 2 - comportamento de T_1 e T_{j10}	118
4.48	Simulação da falha 2 - comportamento de T_2 e T_{j20}	119
4.49	Dados normais para C_{A2} e C_{A0}	120
4.50	Dados normais para T_1 e T_{j10}	121

4.51	Dados normais para T_2 e $Tj20$	121
4.52	Estatísticas T^2 e Q para os dados de operação normal	122
4.53	Estatísticas T^2 e Q para a falha 1 nos CSTRs em série	123
4.54	Estatísticas T^2 e Q para a falha 2 nos CSTRs em série	123

LISTA DE TABELAS

4.1	Notação	86
4.2	Parâmetros no estado estacionário	87
4.3	Análise Karhunen-Loève para sinais sintéticos	95
4.4	Parâmetros do sistema de reatores	97
4.5	Análise Karhunen-Loève para os reatores em série	99
4.6	Propriedades da coluna de destilação	102
4.7	Símbolos e unidades do CSTR não-isotérmico	108
4.8	Valores nominais da variáveis para o CSTR	109

LISTA DE ABREVIATURAS

ARMAX - *Auto-Regressive Moving Average with eXogenous input*

ARMA - *Auto-Regressive Moving Average*

CARIMA - *Controlled Auto-Regressive Integrated Moving Average*

CARMA - *Controlled Auto-Regressive Moving Average*

CPA - *Control Process Assessment*

CPM - *Control Process Monitoring*

CPV - *Cumulative Percent Variance*

CSTR - *Continuous Stirred Tank Reactor*

DMC - *Dynamic Matrix Control*

FCOR - *Filtering and Subsequent Correlation Analysis*

GIM - *Índice de Desempenho Baseado em Matriz de Interação Generalizada*

GMVC - *Generalized Minimum Variance Control*

GMV - *Generalized Minimum Variance*

IAE - *Integral of Absolute Error*

IMC - *Internal Model Control*

LQG - *Linear Quadratic Gaussian*

LTI - *Linear Time Invariant*

MIMO - *Multiple Input Multiple Output*

MISO - *Multiple Input Single Output*

MPC - *Model Predictive Control*

MVC - *Minimum Variance Control*

NLDM - *Nonlinear Detection Methods*

NMP - *Nonminimal phase*

PCA - *Principal Components Analysis*

PID - Controlador Proporcional-Integral-Derivativo

QP - Programação Quadrática

RS-MPC - *Reference System Model Predictive Control*

RVI - *Relative Variance Index*

SISO - *Single Input Single Output*

SVD - *Singular Value Decomposition*

LISTA DE SÍMBOLOS

D - Matriz de interação unitária

D_h - Matriz de tempo morto

$E\{\}$ - Esperança matemática

G - Função de transferência do modelo

I_i - Índice de eficiência

K - Função de transferência do controlador

K_L - Base de Karhunen-Loève

N - Função de transferência da perturbação

N_0 - Número de oscilações

T_s - Tempo de amostragem

W - Padrões de movimento da válvula

Σ_C - Parte não inversível do modelo fatorado

$\Sigma_{M(p)}$ - Função de transferência do modelo fatorado com interação p

$\Sigma_{M(r)}$ - Função de transferência do modelo fatorado com interação r

η - Índice de desempenho

ϕ_0 - Sinal fictício

$\rho_{3,\alpha}$ - Índice para detecção do emperramento de válvulas

σ^2 - Variância

σ_i - Zeros finitos fora do ciclo unitário

ξ - Matriz de interação

a - Número do componente principal

$e(t)$ - Erro em função do tempo

f_d - Fricção dinâmica

f_s - Fricção de Coulomb

q - Operador de atraso

u - Entrada ou variável manipulada

w - Interação generalizada do tipo p ou r

y - Sinal de saída

Resumo

Monitorar sistemas de controle relaciona-se à capacidade de supervisionar de maneira ampla a operação de plantas industriais, avaliando o desempenho de controladores, detectando oscilações, perturbações, falhas em sensores, emperramento de válvulas de controle e diagnosticando as possíveis causas de problemas que possam degradar a capacidade produtiva, gerenciando alarmes e fornecendo possíveis estratégias de como atuar para manter, ou até mesmo, aprimorar a eficiência da operação. O monitoramento contínuo do desempenho de sistemas de controle (*Control Process Monitoring* - CPM) e a avaliação do desempenho de sistemas de controle (*Control Process Assessment* - CPA) são tecnologias essenciais para a manutenção da eficiência durante a operação de processos industriais. Neste contexto, este trabalho apresenta uma sistemática para o monitoramento de sistemas de controle na indústria química, através de um gerenciador de desempenho proposto. Desta forma foi investigado sistemas de controle utilizando o conceito de índice de desempenho para quantificar a degradação da eficiência do controlador, tratando-se de uma ferramenta para a sua avaliação durante a operação industrial. O índice de desempenho fornece a ideia do quanto o controle corrente do sistema está distante do melhor controle idealizado com mesma estrutura. Devido as características do comportamento de referência, que independe da estrutura de controle utilizada, pode-se avaliar controladores de diversos tipos e sob várias situações. Este índice foi obtido através do projeto da referência, utilizando fatoração de modelos lineares através da matriz de interação generalizada. Descobrir anormalidades constitui-se uma tarefa muito importante e complicada. Desta forma, avaliou-se processos sujeitos à presença de oscilações, utilizando uma extensão do método de Karhunen-Loève e periodogramas. Avaliou-se também, processos com emperramento de válvulas de controle através do método de Yamashita e falhas em sensores e sistemas submetidos à perturbações, utilizando a análise dos componentes principais (PCA) e as estatísticas T^2 e Q , com o objetivo de detectar, isolar e diagnosticar a possível causa da degradação dos sistemas de controle analisados.

Palavras-chave: Monitoramento, Índice de Desempenho, Oscilação, Emperramento de válvulas.

Abstract

Control systems monitoring relates to ability to supervise the industrial plants operation, evaluating the controller performance by oscillation detection, disturbances, faults in sensors, valve stiction and diagnosing possible causes of problems that may degrade the productive capacity, managing alarms and providing possible strategies to act or even improve the efficiency of operation. Control Process Monitoring (CPM) and Control Process Assessment (CPA) technologies are essential for maintaining the efficient during operation of industrial processes. This work presents a systematic method for monitoring of control systems in chemical industry, using a performance manager. This way it was investigated control systems using the performance index concept to quantify the degradation of controller's efficiency, that is a tool to evaluate the behavior in industrial operation context. Performance index supplies the idea of as the control system is distant of best control idealized with same structure. Due the characteristics of reference behavior, that does not depend on the structure of control used, it can be evaluated controllers of several types and under several situations. This index was obtained by design of reference, using the factorization with interactor matrix generalized. Discover abnormalities in control systems is very important and complicated. In addition, was evaluated procedures subject to presence of oscillations, using an extension of the Karhunen-Loève method and periodogramas. It was also evaluated, processes with valves stiction using the Yamashita method and faults in sensors and systems subjected to disturbances, using the principal components analysis (PCA) with T^2 and Q statistics, with objective of detecting, isolating and diagnosing possible cause of control systems deterioration.

Keywords: Monitoring, Performance Index, Oscillation, Valve stiction.

CAPÍTULO 1

Introdução



este capítulo serão abordadas a introdução e a motivação para a realização do monitoramento de sistemas de controle na indústria química, bem como o objetivo principal deste trabalho.

1.1 Por que monitorar e avaliar sistemas de controle?

1.1.1 Aspectos fundamentais

Através do monitoramento contínuo do desempenho de sistemas de controle (CPM) e da avaliação do desempenho de sistemas de controle (CPA), é que se tem uma ideia realística do comportamento do processo ao longo do tempo. Com a aplicação destas técnicas, é possível:

- detectar mudanças no desempenho/características dinâmicas através de dados históricos, analisando a variabilidade do sistema;
- detectar a necessidade de re-sintonização ou realização de um novo projeto de controle;

- detecção de falhas;
- identificar a necessidade de modificações no sistema para reduzir influência de perturbações, etc.

Desta forma, é possível manter a eficiência da operação de processos industriais.

A Figura (1.1) apresenta um esquema da aplicação das técnicas CPM/CPA.



Figura 1.1: Esquema simples para a aplicação CPM/CPA.

Para avaliar se um sistema de controle é eficiente e está atendendo as especificações desejadas, como pode ser observado na figura (1.2), deve-se responder as seguintes questões: O sistema está trabalhando satisfatoriamente? Se não, por que sua “eficiência” está comprometida? Como se pode organizar e melhorar o sistema de acordo com um comportamento de referência entendendo como o sistema se comporta perante perturbações? Como os dados correntes de uma indústria podem ser aproveitados para esta tarefa?

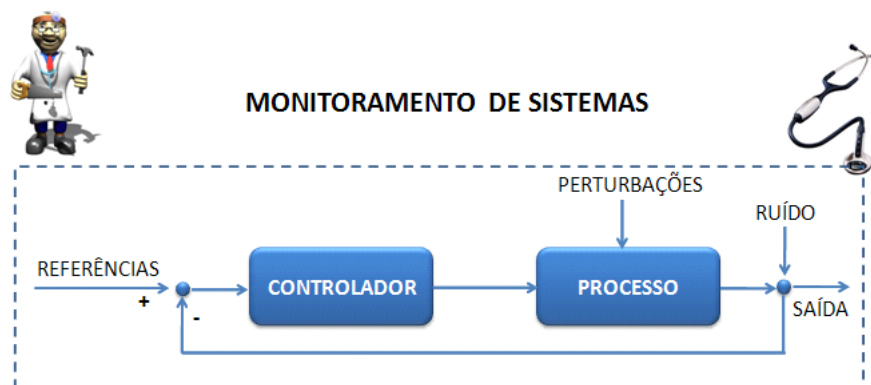


Figura 1.2: Esquema simples para o monitoramento e avaliação de sistemas de controle.

De acordo com Jelali (2006), um sistema de controle é dito como “insatisfatório” ou “ineficiente” quando:

- *controlador for inadequado e faltar manutenção*: Isto pode estar relacionado a um controlador que nunca foi sintonizado adequadamente ou que foi sintonizado baseado em um modelo que não descreve eficientemente o comportamento do sistema, ou até mesmo, ao uso de um tipo de controlador inadequado para a atribuição do sistema. Sabe-se que mais do que 90% dos controladores instalados dentro dos sistemas de automação industrial são do tipo PID (Proporcional-Integral-Derivativo), o que se dá até mesmo em casos onde outros controladores são mais apropriados que o PID.

A causa mais comum de um fraco desempenho do sistema de controle é que uma vez sintonizado, e com o passar do tempo e mudanças no processo, o controlador continua com a mesma sintonia, perdendo desempenho e prejudicando sua eficiência. Tais fatos podem ser motivados por:

1. mudanças nas características dos materiais ou produtos utilizados inicialmente;
 2. modificações nas condições operacionais;
 3. mudanças nos equipamentos (planta industrial);
 4. sintonia conservadora para os controladores, tal que, quando ocorrem mudanças nas condições operacionais, principalmente em sistemas não lineares, tende-se a ter um controlador atuando de forma lenta;
 5. capacitação de somente uma pessoa para se responsabilizar por toda a manutenção do sistema automático;
 6. falta de mão-de-obra qualificada para entender o sistema automático.
- *mau funcionamento dos equipamentos ou projeto “insatisfatório”*: Um fraco desempenho de um sistema de controle é, em geral, resultado de falhas ou mau funcionamento dos sensores ou atuadores. Contudo, o mais sério é quando o processo ou um componente do mesmo não é projetado adequadamente;
 - *compensação feedforward ineficiente*: Se não forem consideradas perturbações externas, elas podem deteriorar o desempenho de controle. Assim, quando perturbações estão sendo medidas, é recomendada a compensação destas perturbações com o emprego do controlador *feedforward* que possui ações antecipatórias;
 - *estrutura de controle inadequada*: Relações de entrada/saída do processo inadequadas, ignorando interações entre as variáveis do sistema, competição entre os controladores, graus de liberdade, presença de uma forte não linearidade, e a falta de compensação do tempo-morto são características básicas para a definição de problemas na estrutura de controle.

As características mais importantes que a CPM/CPA devem satisfazer, foram apresentadas por autores em diversos trabalhos, com o intuito de viabilizar a técnica, tais como Vaught e Tippet (2001) e Ingimundarson (2003). Essas características são: (1)- não necessidade de testes realizados na planta; (2)- habilidade para se desenvolver automaticamente; (3)- não comprometer o processo; (4)- usar dados ou modelo do processo; (5)- detectar baixo desempenho do sistema de controle; (6)- diagnosticar baixo desempenho do sistema de controle; (7)- sugerir medidas satisfatórias para remover a causa da deterioração do desempenho; (8)- apresentar de forma apropriada dos resultados para o usuário (interface homem-máquina).

Nas últimas décadas houve um interesse crescente nas indústrias de processo no que se refere ao CPM/CPA. A Figura (1.3) apresenta o procedimento básico para a realização da CPM/CPA. Métodos, aplicações, pacotes e *softwares* foram estudados na literatura. A aceitação crescente da tecnologia CPM/CPA em muitas indústrias se dá pelo fato da consciência de que se manter habitualmente a eficiência do sistema de controle trás conforto tanto para o sistema de produção quanto para o consumidor, que terá em suas mãos produtos de alta qualidade (SOUZA, 2007).




Figura 1.3: Procedimento básico para a realização da CPM/CPA.

1.2 Monitoramento de sistemas de controle

O desenvolvimento de controladores que possuem comportamento uniforme em malha fechada para grandes variações da dinâmica do processo e robustez tem acelerado a alta competição do mercado nos dias atuais.

A exploração de novas alternativas de sistemas de controle pode resultar em

um fator importante na conquista de mercado. Além disso, aspectos como aumento da demanda por processos e produtos de qualidade, responsabilidade ambiental e demandas por um mercado variável e dinâmico, motivam a busca por sistemas de controle com flexibilidade operacional, e garantia da eficiência através do gerenciamento do sistema.

Para que se possa efetuar uma avaliação da eficiência do gerenciamento de processos complexos é necessário o monitoramento contínuo e análise do desempenho sob vários pontos de vista. A perda do desempenho da malha de controle, emperramento de válvulas, presença de oscilação, que muita das vezes pode ser ocasionada pelo emperramento de válvulas, ou até mesmo perturbações com mesma natureza, são fenômenos ocorrentes em malhas de controle e que devem ser detectadas, diagnosticadas, isoladas, e por fim encontrar caminhos para a manutenção da eficiência do processo.

O índice de desempenho de um sistema representa uma medida utilizada para a análise de eficiência (SOUZA, 2007), principalmente para detectar a perda do desempenho do sistema de controle. Uma classificação inicial para os tipos de métricas para avaliação de desempenho pode ser descrita como: métricas financeiras (lucro, vendas, custo operacional, etc) e métricas não financeiras (taxa de satisfação do cliente, imagem do produto e da empresa etc). Outras categorias de classificações são aquelas quantitativas e qualitativas. As métricas quantitativas compreendem desde aspectos financeiros (vendas por dia, etc), quantidades não financeiras e até medidas técnicas (taxa de defeitos, propriedades físicas do produto etc). Assim, pode-se utilizar uma matriz de desempenho para se obter a ênfase no que é importante para a avaliação de desempenho desejada. A Figura (1.4) apresenta o esquema genérico de uma matriz de desempenho (ORDYS et al., 2007).




Figura 1.4: Matriz de Desempenho: DB= Desempenho Bom; DF: Desempenho Fraco; AI: Alta Importância; BI: Baixa Importância.

Os quadros apresentados na Figura (1.4) podem ser interpretados conforme região em análise:

1. DB/AI: resultados de análises nessa região da matriz são relevantes devido a associação entre desempenho e importância ambas favoráveis ao processo;
2. DF/AI: Resultados de análises nessa região da matriz indicam que se deve fazer um esforço para se melhorar o desempenho dessas variáveis;
3. DB/BI: resultados nessa região indicam que variáveis de baixa importância estão fornecendo bom desempenho. Isto implica que esforços podem estar sendo empregados para variáveis de baixa importância no contexto do processo;
4. DF/BI: resultados nessa região da matriz não são críticos para investigação, pois são de variáveis de baixa importância e onde baixos desempenhos são aceitáveis.

Neste trabalho, a avaliação da eficiência de um sistema de controle, está localizado na região DB/AI, tratando-se, por interesse, de uma investigação diretamente relacionada ao gerenciamento eficiente do processo (seja por lucratividade, segurança ou restrição técnica). Este aspecto motiva a investigação da análise de desempenho de sistemas de controle. Além disso, soma-se o fato de que a incorporação de um sistema de controle avançado necessita de uma atenção contínua para garantia do desempenho projetado e aperfeiçoamento ao longo do tempo da operação do novo sistema.

Uma das causas de perda na eficiência do sistemas de controle está ligado diretamente por controladores inadequados ao processo. Neste caso, tem-se que o controle em vigor já ficou obsoleto às mudanças ocorridas ao decorrer do tempo, causando um aumentando na variabilidade dos processos, pois em média somente 30% das malhas de controle na indústria reduzem a variabilidade (MITCHELL et al., 2004). Neste cenário, surge à necessidade de desenvolver técnicas de monitoramento contínuo do sistema de controle para que o mesmo possa acompanhar as mudanças ocorridas, mantendo as características de projeto do controlador, tais como eficiência e robustez.

Um desempenho fraco para o sistema de controle pode resultar em instabilidade e ações de controle não satisfatórias, indicando a necessidade de atividades adicionais tais como a realização da identificação do processo e a reestruturação do controlador (HUANG; SHAH, 1999).

As divergências entre as variáveis controladas e os valores desejados (*setpoint*) podem ser quantificadas por um único número que é conhecido como índice de desempenho (SOUZA; OLIVEIRA-LOPES, 2011). Vários índices de desempenho para sistemas de controle foram propostos na literatura, tais como em Bezergianni e Georgakis (2000), Kozub (1997), Kozub e Garcia (1993), Desborough e Harris (1992) e Devries e Wu (1978), e várias aproximações foram propostas para calcular o índice de desempenho para sistemas SISO (Simples Entrada e Simples Saída), inclusive a aproximação de índice de desempenho normalizada (DESBOROUGH; HARRIS, 1992). Não obstante, existe a necessidade do desenvolvimento de novos índices de desempenho que sejam intuitivos, facilmente determinados e baseados em comportamentos de referência que apresentem implicitamente o que pode ser conseguido por um controlador de interesse.

Em Jelali (2006) é apresentado uma visão geral sobre os métodos para o cálculo do índice de desempenho e um procedimento sistemático para o monitoramento contínuo bem como avaliações aplicadas a processos industriais.

Descobrir anormalidades em sistemas de controle é uma tarefa muito importante, e dentre elas pode-se citar as oscilações que podem estar ligadas a várias origens, tais como, a perda do desempenho da malha de controle, emperramento de válvulas, ou perturbações com mesma natureza.

Sabe-se que cerca de 60% dos controladores industriais desenvolve algum problema, seja eficiência ou robustez, perante os processos que mudam suas características ao longo do tempo, tais como manufatura de produtos sazonais (HARRIS et al., 1999).

De acordo com McMillan (2009), as válvulas de controle são usadas como elemento final em 95% ou mais dos sistemas de controle dos processos industriais. Desta forma, o emperramento de válvulas representa uma das principais causas de oscilação de sistema de controle, sendo assim, o objetivo de se manter o sistema de controle em sua eficiência nominal, é importante detectar, localizar e diagnosticar oscilações. Na literatura existem vários métodos para detectar oscilações e emperramento de válvulas, e que podem ser vistos em Jelali e Huang (2010).

Outro aspecto importante e que deve ser levado em consideração no monitoramento de sistemas de controle, são as falhas em sensores, que ao receber o sinal medido no processo, pode ocasionar tomadas de ações incorretas, causando perda na eficiência da malha.

Desta forma, é a partir de técnicas de monitoramento que se pode detectar mudanças no desempenho e características dinâmicas utilizando dados históricos ou de

modelos do processo, analisando a variabilidade do sistema, bem como a necessidade de re-sintonização ou realização de um novo projeto de controle, identificando a necessidade de modificações no sistema para reduzir a influência de perturbações etc.

Não é uma tarefa muito fácil a de estabelecer um monitoramento eficiente de um sistema de controle, devido ao fato da presença de ruídos, perturbações, tempo de resposta variante, não linearidade, dentre outros. Sendo assim, estes fatos dão ênfase a necessidade do desenvolvimento de técnicas eficientes para o monitoramento e avaliação do desempenho de controladores, onde a meta é assegurar que o sistema de controle em vigor atenda as especificações desejadas para o processo.

Para isso, algumas exigências devem ser seguidas para a avaliação de sistemas de controle:

1. determinação da capacidade do sistema de controle;
2. desenvolvimento de estatísticas para monitorar o desempenho do controlador;
3. desenvolvimento de métodos para diagnosticar as causas subjacentes de mudanças no desempenho do sistema de controle (HARRIS et al., 1999).

1.3 Gerenciador de desempenho

Neste trabalho, foi estudado, medidas de desempenho de uma estrutura de controle, utilizando-se, para isso, o conhecimento dos invariantes do processo (atraso, zeros fora do ciclo unitário etc) e de ferramentas de fatoração de modelos locais lineares para conhecimento, da matriz de interação generalizada. Utilizou-se como padrão de referência a medida da ação possível de controle para plantas operando com controladores *feedback*: de variância mínima (MVC), proporcional-integral-derivativo (PID), para o cálculo do índice de desempenho.

Avaliou-se também a presença de oscilações em sistemas de controle, através da técnica da análise de Karhunen-Loève e periodogramas (JELALI; HUANG, 2010; ODGAARD; WICKERHAUSER, 2007), na qual, uma das causas principais aponta o emperramento de válvulas, que através do método de Yamashita, foi possível demonstrar uma das técnicas mais eficaz para a detecção do emperramento de válvulas (JELALI; HUANG, 2010).

Uma das anormalidades mais comuns em sistemas controlados é a presença de


falhas, como por exemplo, o mau funcionamento de sensores. Utilizou-se também a Análise dos Componentes Principais (PCA), com o objetivo da redução da dimensão de modelos, visto que, na maioria das vezes os sistemas analisados possuem grande quantidade de dados de operação, desta forma, também foi avaliado métodos (estatísticas T^2 e Q) para a detecção de falhas em malhas de controle.

Dentro deste cenário, concebeu-se este trabalho, com o objetivo de apresentar a aplicação das técnicas CPM/CPA, através de métodos para o cálculo do índice de desempenho, identificação e localização de oscilações, detecção do emperramento de válvulas, bem como falhas em sensores e presença de perturbações.

A estrutura básica desta teste possui a seguinte forma: O Capítulo 2 apresenta os aspectos gerais da bibliografia. O Capítulo 3 apresenta com detalhes, os métodos propostos para o monitoramento de sistemas de controle. O Capítulo 4 aborda a aplicação dos métodos apresentados no Capítulo 3. Por fim, no Capítulo 5 apresentam-se as conclusões e sugestões para trabalhos futuros.

CAPÍTULO 2

Revisão bibliográfica

este capítulo serão apresentados a revisão bibliográfica e os aspectos gerais para o monitoramento de sistemas de controle, abordando métodos para o cálculo do índice de desempenho, para avaliar se o sistema controlado se comporta de maneira satisfatória bem como técnicas para a identificação e localização de oscilações, métodos para a detecção do emperramento em válvulas, falhas em sensores e presença de perturbações.

2.1 Cálculo do índice de desempenho

O desempenho de um sistema de controle relaciona a sua habilidade para lidar com as divergências entre variáveis controladas e os valores desejados (*setpoint*). Estas divergências podem ser quantificadas por um único número que é conhecido como índice de desempenho.

Existem alguns procedimentos básicos para a avaliação de sistemas de controle, dentre os quais pode-se destacar (JELALI, 2006):

- *determinação da capacidade de controle do sistema*: envolve a quantificação do desempenho atual. Dados medidos (dinâmicos) são analisados e então se

avalia o desempenho, por exemplo, as discrepâncias de produção do sistema de controle atual;

- *seleção e projeto de um comportamento de referência para avaliação de desempenho*: este passo especifica o comportamento de referência com relação ao qual o desempenho de controle atual será avaliado, podendo ser utilizado o critério da variância mínima (MV) ou qualquer outro critério que indique quanto os dados do sistema variou em um intervalo de tempo;
- *descoberta e avaliação de laços de controle com baixo desempenho*: esta fase testa a divergência do desempenho de controle atual em relação ao comportamento de referência selecionado. Além disso, a pessoa responsável pela manutenção pode determinar a melhoria possível, aumentando o desempenho do controle atual de acordo com o comportamento de referência selecionado;
- *diagnóstico das causas subjacentes*: quando a análise indica que o desempenho de um controlador diverge com relação a bom/desejado, deve-se localizar as razões para que o sistema não esteja se comportando como o desejado;
- *sugestões de medidas de melhoria*: depois de se isolar as causas de fraco desempenho, ações corretivas devem ser empregadas para restabelecer o potencial do sistema de controle. Na maioria dos casos, controladores com funcionamento insatisfatórios podem ser melhorados através de re-sintonização.

O critério mais difundido para o CPA é o da variância ou a divergência entre o que está sendo medido na planta e o comportamento de referência selecionado, sendo aplicado particularmente para controle regulador. O desempenho de um laço de controle pode ser julgado inaceitável se a variância da variável controlada excede os valores críticos do comportamento de referência, devido a sua relação direta entre o desempenho, qualidade de produto e o lucro.

Existem na literatura, vários trabalhos publicados, referentes a CPM/CPA, como Qin (1998), Harris et al. (1999), Huang e Shah (1999), Harris e Seppala (2001), Shah et al. (2001), Dittmar et al. (2003) e Thornhill et al. (2003a). Muitos pesquisadores propuseram avaliações práticas para CPM/CPA, e neste contexto, podem-se citar os trabalhos de Kozub (1996), Thornhill et al. (1999), Haarsma e Nikolaou (2003), Dumont et al. (2002) e Hoo et al. (2003).

Owen et al. (1996) propuseram maneiras automáticas de realizar o monitoramento e correções no mau funcionamento de sistemas de controle. Estudo realizado por McNabb e Qin (2003) apresenta um método de monitoramento do desempenho de controle baseado em projeções de subespaço, utilizando modelos em espaço de

estados, geralmente não quadrados, e aplicando a técnica de variância mínima. Desborough e Harris (1993) desenvolveram um sistema de controle utilizando variância mínima para sistemas de múltiplas-entradas e única-saída (MISO), observando três aspectos: variância mínima aplicada a uma fonte de perturbação, variância devida a controle *feedforward* sub-ótimo e variância devida a controle *feedforward-feedback* sub-ótimo.

Dando continuidade ao estudo desenvolvido por Desborough e Harris (1993) e utilizando o mesmo método da variância mínima, McNabb e Qin (2005) estudaram sistemas de forma que fossem incluídas perturbações e mudanças no *setpoint*, demonstrando que o método pode ser diretamente aplicado a sistemas com perturbações medidas, aumentando a matriz que contém os dados do sistema com as perturbações medidas. Seguindo esta linha, Kozub (1996), Huang et al. (1997a) e Huang et al. (1997b) propuseram índices de desempenho de controle que variavam dentro do intervalo $[0, 1]$, sendo que, índices de desempenho próximos de 1 (um) representam a existência de um controle com melhor eficiência. Estes índices podem ser avaliados conforme:

$$\eta = \frac{J_{des}}{J_{atual}} \quad (2.1)$$

em que J_{des} é o valor ideal (comportamento de referência) e J_{atual} é o valor atual medido na planta.

Harris (1989) propôs um índice de desempenho baseado em uma referência de comportamento de variância mínima inicialmente para sistema com simples entrada e simples saída (SISO), é também chamado de índice de Harris:

$$\eta_{Harris} = \frac{\sigma_{MV}^2}{\sigma_y^2} \quad (2.2)$$

em que σ_{MV}^2 é a variância do sinal de saída do sistema de controle de referência, utilizando controle de variância mínima, e σ_y^2 é a variância do sinal de saída do sistema de controle analisado (corrente).

A análise de variância (DESBOROUGH; HARRIS, 1993) realça a contribuição de várias perturbações à variância global, tais como:

$$\sigma_y^2 = \sigma_{MV,v}^2 + \sigma_{FB,v}^2 + \sum_{j=1}^{n_w} (\sigma_{MV,w_j}^2 + \sigma_{FF,w_j}^2 + \sigma_{FB/FF,w_j}^2) \quad (2.3)$$

com $\sigma_{MV,v}^2$ é a variância mínima (MV) associado ao controle *feedback* (devida a per-

turbações não medidas, v), $\sigma_{FB,v}^2$ é a MV devida à “não-otimalidade” do controle *feedback*, $\sum_{j=1}^{n_w} \sigma_{MV,w_j}^2$ é a MV aplicada ao controle *feedforward* (através de perturbações medidas, w), $\sum_{j=1}^{n_w} \sigma_{FF,w_j}^2$ é a MV devida à “não-otimalidade” do controle *feedforward* e $\sum_{j=1}^{n_w} \sigma_{FB/FF,w_j}^2$ é a MV devida à “não-otimalidade” da combinação entre os controles *feedback/feedforward*.

O índice de Harris foi estendido a sistemas com múltiplas entradas e múltiplas saídas (MIMO) por McNabb e Qin (2003), Ko e Edgar (2001b), Ettaleb (1999), Huang e Shah (1999), Huang et al. (1997b), Huang e Shah (1997) e Harris et al. (1996). O índice de Harris para estes sistemas é dado por:

$$\eta_{MIMO} = \frac{\sum_{i=1}^s \sigma_{i,MV}^2}{\sum_{i=1}^s \sigma_i^2} \quad (2.4)$$

que ao comparar com a Equação (2.2), nota-se que agora tem-se o somatório de todas as s saídas, tanto da referência quanto para o sistema corrente.

Bezergianni e Georgakis (2000) desenvolveram um índice de desempenho, baseado na variância relativa (RVI):

$$RVI = \frac{\sigma_{OL}^2 - \sigma_y^2}{\sigma_{OL}^2 - \sigma_{MVC}^2} \quad (2.5)$$

com σ_{OL}^2 a variância do sinal de saída da malha aberta, σ_y^2 a variância do sinal de saída do sistema analisado (corrente), e σ_{MVC}^2 a variância do sinal de saída da referência, utilizando controle de variância mínima.

Uma extensão direta do comportamento de referência MV sugerida por Grimble (2002) considera penalizações da ação de controle e conduz ao que se chama de variância mínima generalizada (GMV). Uma referência de comportamento baseado no controlador LQG (Linear Quadrático Gaussiano) foi proposta por Huang e Shah (1999) como alternativa à MV. Ambas referências são úteis pois permitem a obtenção de detalhes sobre as informações de desempenho do controlador. No caso do índice de desempenho baseado numa referência dada pelo controlador LQG, pode-se entender o quanto a variância de produção pode ser reduzida sem afetar o desempenho do controlador. Sendo assim, pode-se estabelecer uma relação entre as entradas e saídas do processo da seguinte forma:

$$J_{LQG} = \text{var}\{y(k)\} + \lambda \text{var}\{\Delta u(k)\} \quad (2.6)$$

com $y(k)$ os dados de saída do processo num tempo k , $\Delta u(k)$ a variação dos dados de entrada num tempo k e λ um parâmetro de ponderação que varia em $[0, \infty)$.

A derivação da lei de controle GMV é mais simples que aquela para LQG (GRIMBLE, 2002):

$$\begin{aligned} J_{GMV} &= E\{\phi_0^2\} \\ \phi_0(k) &= P_c e(k) + F_c u(k) \end{aligned} \quad (2.7)$$

com P_c e F_c são filtros aplicados ao sistema e ϕ_0 representa um sinal fictício.

Com o interesse de estabelecer um controlador que tivesse um melhor desempenho, Bender (2003) propôs um controlador Proporcional-Integral-Derivativo (PID) utilizando controle de modelo interno (IMC), onde a variância para a análise do seu desempenho pode ser calculada da seguinte forma:

$$\sigma_{PID/IMC}^2 = \min_{\lambda} \sigma_y^2 \quad (2.8)$$

com λ o único parâmetro que deve ser selecionado.

Como um processo industrial está sujeito a várias restrições, tanto quanto aos equipamentos e a instrumentação utilizada no sistema de controle, e sabendo-se que a tecnologia de controlador preditivo baseado em modelos (MPC) abrange toda esta estrutura de restrições, Julien et al. (2004) mostraram que até mesmo o projeto de um MPC perfeito e na ausência de discrepâncias planta/modelo, nunca passará pela curva LQG, a menos que as perturbações atuais sejam dadas de forma aleatórias. Assim, o índice de desempenho para sistemas MIMO utilizando a formulação MPC pode ser calculado por:

$$\eta_{MPC} = \frac{\left(\sum_{j=1}^{N_2} \mathbf{e}^T_{(k+j-N_2)} \mathbf{Q} \mathbf{e}_{(k+j-N_2)} + \sum_{j=1}^{N_u} \Delta \mathbf{u}^T_{(k+j-N_2-1)} \mathbf{R} \Delta \mathbf{u}_{(k+j-N_2-1)} \right)_{\text{referência}}}{\left(\sum_{j=1}^{N_2} \mathbf{e}^T_{(k+j-N_2)} \mathbf{Q} \mathbf{e}_{(k+j-N_2)} + \sum_{j=1}^{N_u} \Delta \mathbf{u}^T_{(k+j-N_2-1)} \mathbf{R} \Delta \mathbf{u}_{(k+j-N_2-1)} \right)_{\text{atual}}} \quad (2.9)$$

com N_2 e N_u os horizontes de predição e de controle, \mathbf{e} o erro estimado, $\Delta \mathbf{u}$ a variação da entrada, \mathbf{Q} e \mathbf{R} são pesos.

A análise de desempenho baseada em comportamentos de referência extraídos de dados históricos do processo pode ser feita conforme Huang (2003). Neste caso, o índice de desempenho é dado por:

- avaliando-se todas as saídas e todas as entradas do sistema:

$$\eta_{his} = \frac{\left(\sum_{i=1}^n k_i \sigma_{VC_i}^2 + \sum_{i=1}^m \lambda_i \sigma_{\Delta VM_i}^2 \right)_{\text{referência}}}{\left(\sum_{i=1}^n k_i \sigma_{VC_i}^2 + \sum_{i=1}^m \lambda_i \sigma_{\Delta VM_i}^2 \right)_{\text{atual}}} \quad (2.10)$$

- avaliando-se cada saídas com todas as entradas:

$$\eta_j = \frac{\left(k_j \sigma_{VC_i}^2 + \sum_{i=1}^m \lambda_i \sigma_{\Delta VM_i}^2 \right)_{\text{referência}}}{\left(k_j \sigma_{VC_i}^2 + \sum_{i=1}^m \lambda_i \sigma_{\Delta VM_i}^2 \right)_{\text{atual}}} \quad (2.11)$$

- avaliando-se a entrada do sistema:

$$\eta_u = \frac{\left(\sum_{i=1}^m \lambda_i \text{média}(\Delta VM_i) \right)_{\text{referência}}}{\left(\sum_{i=1}^m \lambda_i \text{média}(\Delta VM_i) \right)_{\text{atual}}} \quad (2.12)$$

com VC variável controlada e ΔVM a variação da variável manipulada.

Vários métodos para a determinação do comportamento de referência são descritos, como em Ordys et al. (2005), onde são comparados do ponto de vista das condições dos parâmetros, dados do processo e benefícios.

Sabe-se que há muitas razões para um desempenho fraco de um sistema de controle, como: (i) limitações em desempenho realizável que surge devido a uma combinação do sistema com o projeto do sistema de controle; (ii) mudanças na dinâmica do sistema, (iii) perturbações variadas; (iv) falhas nos sensores ou atuadores, (v) não linearidade do sistema; e (vi) fontes desconhecidas. Alguns destes problemas podem ser descobertos usando métodos especializados e índices de desempenho (SOUZA, 2007).

No caso de sistemas que apresentam não linearidade, existem testes para a detecção deste problema conhecido como NLDM (métodos para detecção da não linearidade). De maneira simplificada, quase todos os NLDMs supõem que o sistema

investigado pode ser excitado com certos sinais de entrada que nem sempre são possíveis ou permissíveis na prática industrial.

Choundhury et al. (2004) propuseram um método para a NLDM baseada em análise estatística usando bicoerência quadrática (*quadratic bicoherence*), e denominado índice de não linearidade (NLI) com 95% de confiança:

$$NLI = \left| bic_{\max}^2 - (\overline{bic^2} + 2\sigma_{bic^2}) \right| \quad (2.13)$$

com σ_{bic^2} o desvio padrão e $\overline{bic^2}$ a média calculada da bicoerência quadrática.

Com o valor de NLI pode-se chegar à seguinte conclusão:

- $NLI = 0$, o sinal gerado pelo processo é linear;
- $NLI > 0$, o sinal gerado pelo processo é não linear.

Uma das mais comuns formas de degradação de sistemas de controle é a presença de oscilações no processo. De acordo com Desborough e Miller (2002), 32% dos controladores são classificados como “de baixo desempenho”, devido a problemas nas válvulas de controle. Hägglund (1995) propôs uma maneira de calcular o índice de oscilação utilizando a integral do erro absoluto (*IAE*):

$$IAE = \int_{t_{i-1}}^{t_i} |e(t)| dt \quad (2.14)$$

Os valores das *IAEs* são separados em positivos e negativos, e o índice de oscilação gerado (OI) dado por h pode ser interpretado (FORSMAN; STATIN, 1999):

- $h > 0,4$: sistema candidato a exame mais aprofundado;
- $h > 0,8$: um padrão de oscilação muito distinto no sinal é esperado;
- apresentará ruído branco para $h \approx 0,1$.

Outro problema muito comum é a perda de eficiência no sistema de controle, apresentando respostas lentas devido ao fato de que com o passar do tempo pode se transformar em um sistema com sintonia inadequada (conservador). Hägglund (1995) apresentou um método para a detecção de sistemas conservadores, denominado de índice de eficiência (I_i):

$$I_i = \frac{t_{pos} - t_{neg}}{t_{pos} + t_{neg}} \quad (2.15)$$

no qual o I_i será calculado em um período de tempo levando em consideração os sinais positivos e negativos dentro do intervalo $[-1,1]$. Se I_i for 1 (um), o sistema é conservador, se for 0 (zero) a sintonia do sistema de controle é classificada como boa e para valores negativos significa que apresenta a melhor configuração de sintonia.

O objetivo de se aplicar métodos de CPA e índices de desempenho está relacionado com sugestões para melhorar o sistema de controle ou processo, e pode ser dividido em algumas fases:

- *inspeção e manutenção:* sempre que se notem diferenças que possam causar problemas futuros relacionados com o desempenho do sistema automático (sensores, atuadores, válvulas etc) deve-se realizar a manutenção de todo o sistema;
- *re-sintonização da malha de controle:* uma das opções de se atingir novamente o desempenho desejado é realizar a re-sintonização do sistema de controle. Neste caso, é de extrema importância que a realização da re-sintonia ocorra através de pessoas treinadas para que a nova sintonia não prejudique o processo de produção;
- *re-projeto do sistema de controle:* como na maioria dos casos emprega-se a formulação PID para sistemas de controle, e se por ventura deseja-se investir em tecnologia mais avançada, pode-se lançar mão do emprego de controladores mais sofisticados como, por exemplo, o controlador preditivo baseado em modelos (MPC), realizando assim um novo projeto do sistema de controle.

Para se realizar o CPA/CPM, necessita-se da aquisição de dados pertinentes através do sistema a ser analisado, que pode ser resumido da seguinte forma:

- *aquisição de dados:* dados obtidos do sistema são necessários para que se possa realizar uma avaliação do desempenho do sistema de controle. Porém pode se levar muito tempo para coletar os dados necessários à essa avaliação. Desta forma, devem ser empregados sistemas em linha (*on-line*) para facilitar a aquisição, dispondo-se de computadores e *softwares* adequados para que se possa também realizar o pré-processamento para indicar se os dados coletados são válidos para se realizar a análise;

- *determinação do tempo de atraso na resposta (tempo-morto)*: é necessário estimar o tempo-morto, pois será empregado na maioria dos métodos de CPA, particularmente em modelos de variância mínima. Björklund (2003) apresentou alguns métodos para realizar a estimativa do tempo-morto de um processo:

1. método da correlação: este tradicional método é baseado na correlação entre dados de saída (y) e dados de entrada (u) do processo, e pode ser representado por:

$$\hat{\tau} = \max_{\tau} E\{y(k)u(k - \tau)\} \approx \max_{\tau} \sum_k y(k)u(k - \tau) \quad (2.16)$$

2. método da aproximação relacionada: este método utiliza basicamente a aproximação de Padé para sistemas contínuos no tempo. Isaksson (1997) propôs o seguinte método para o cálculo do tempo morto utilizando zeros das funções de transferência no tempo discreto (z_i), relacionando com zeros no tempo contínuo (s_i) da seguinte forma:

$$\hat{\tau} = 1 + \frac{\hat{T}_d}{T_s} = 1 + \frac{\sum_{i=1}^r (2/s_i)}{T_s}, s_i \approx \frac{1}{T_s} \ln(z_i), \quad (2.17)$$

com r representando o número de zeros contido do lado direito do plano complexo. Este método foi modificado por Horsch (2000) aplicado ao domínio de frequência para sistemas discretos no tempo:

$$\hat{\tau} = 1 - \left. \frac{\varphi(\omega)}{\omega T_s} \right|_{\omega < 1} \quad (2.18)$$

- *determinação de um modelo para o sistema*: a primeira decisão que se deve tomar para realizar um CPA é a escolha de um modelo que descreve a resposta dinâmica do processo associada com o erro de controle. Hoje existem vários pacotes e *softwares* que utilizam modelos para identificação de processos como o ARMA (*Auto-Regressive Moving Average*), ARMAX (*Auto-Regressive Moving Average with eXogenous input*) e redes neuronais. A escolha do modelo adequado é um ponto importantíssimo para um bom desempenho na realização do CPA, e este deve ser escolhido de acordo com as características do sistema de controle e necessidades do processo.

Xia et al. (2006) propuseram índices de desempenho a partir da obtenção da

matriz de tempo morto através de dados operacionais para se estabelecer os limites inferiores e superiores do desempenho de sistemas MIMO.

O limite superior pode ser estimado por $J_{upper} = tr(var(\bar{F}a_t))$

O sinal de saída para o sistema é:

$$Y_t|_{upper} = q^d D_h^{-1} \bar{F} a_t \quad (2.19)$$

O limite inferior pode ser estimado por $J_{lower} = tr(var(F^* a_t))$

O sinal de saída para o sistema é:

$$Y_t|_{lower} = q^d D_h^{-1} F^* a_t \quad (2.20)$$

com q o operador de atraso e D_h a matriz de tempo morto.

Um índice de desempenho baseado na fatoração de modelos lineares utilizando matrizes de interação generalizadas (GIM) foi proposto por Souza (2007):

Seja um modelo G , fatorado da seguinte forma: $G = \Sigma_C \Sigma_M$, sendo que o fator Σ_C representa a parte não inversível do modelo, e Σ_M a parte que pode ser exatamente invertida numa estrutura de controle feedback.

$$\eta_{GIM} = \frac{\lambda \sum_{i=1}^j \sigma_{i, \Sigma_{M(p)}}^2 + (1 - \lambda) \sum_{i=1}^j \sigma_{i, \Sigma_{M(r)}}^2}{\sum_{i=1}^j \sigma_{i, corrente}^2} \quad (2.21)$$

com λ o parâmetro de ponderação entre as fatorações baseada em mínimo resíduo (p) e mínimo tempo (r) para degrau unitário.

Yuan e Lennox (2009), propuseram um índice de desempenho baseado no Índice de Variância Relativa (RVI) modificado, para sistemas multivariáveis.

Um índice de desempenho para sistemas não lineares utilizando decomposição da variância (ANOVA) foi proposto por Yua et al. (2010). O objetivo é determinar a sensibilidade do sinal de saída y_{t+b} para duas variações x_1 e x_2 , a partir da condição inicial I_0 :

$$\eta_t = \frac{E_{I_0}[V_1|I_0]}{V[y_{t+b}]} \quad (2.22)$$

com $V_x|I_0 = V_x[y_{t+b}|I_0] = V_1|I_0 + V_2|I_0 + V_{12}|I_0$

$$V_1|I_0 = V_{x_1}[E_{x_2}[y_{t+b}|(x_1, I_0)]]$$

$$V[y_{t+b}] = E_{I_0}[V_x[y_{t+b}|I_0]] + V_{I_0}[E_x[y_{t+b}|I_0]]$$

Na próxima seção será apresentado com mais detalhes o cálculo do índice de desempenho, utilizando controle de variância mínima como referência.

2.1.1 Cálculo do índice de desempenho utilizando controle de variância mínima (MVC)

A utilização do MVC iniciou-se em 1970, por Aström, que apresentou um estudo da aplicação do MVC para plantas lineares de fase mínima, e é utilizado até a época contemporânea como referência de comportamento, como pode se visto na Figura (2.1):




Figura 2.1: Linha do tempo para a aplicação do MVC.

No projeto da referência, a utilização do MVC pode ser explicada devido aos seguintes aspectos:

- não é invasivo;
- simples entendimento e implementação computacional;
- não requer conhecimento de sintonia da malha específica;

- facilidade para o desenvolvimento de índices de desempenho, etc.

Tham (1999) propôs algoritmos de controle tanto para o Controle de Variância Mínima (MV), quanto para o Controle de Variância Mínima Generalizado (GMV) para sistemas SISO, que de forma geral, o MVC é um tipo de controlador que busca encontrar o melhor sinal de entrada $u(t)$ que minimiza a seguinte função objetivo (SOUZA, 2007):

$$J_{MV} = E \{ [w(t) - y(t+k)]^2 |_t \} \quad (2.23)$$

A notação $E\{.\}_t$ denota a esperança matemática dos dados disponíveis, inclusive os do tempo atual. Sendo assim, a variância das variáveis pode ser calculada através do valor esperado das variáveis ao quadrado. Neste caso, refere-se à variância do erro entre o *setpoint* $w(t)$ e a saída controlada $y(t+k)$ em um passo k no futuro. Desta forma, o projeto do controlador se dá com a minimização desta variância de acordo com a Equação (2.23), e este controlador recebe o nome de Controlador de Variância Mínima (MVC).

Para realizar esta minimização com relação a $u(t)$, deve-se encontrar uma relação satisfatória entre o sinal de saída y e a variável manipulada u . Este processo pode ser realizado através de identificação de modelos, como por exemplo, o modelo CARMA (*Controlled Auto-Regressive Moving Average*):

$$Ay(t) = q^{-k}Bu(t) + C\Gamma(t) \quad (2.24)$$

A Equação (2.24) pode representar tanto um modelo ARMAX, quanto CARMA, onde $k \geq 1$ significa um atraso ou tempo-morto do processo, através de um tempo de amostragem T_s , e $A(q)$, $B(q)$ e $C(q)$ são polinômios em q^{-1} tal que:

$$\begin{aligned} A(q) &= 1 + a_1q^{-1} + a_2q^{-2} + \dots + a_{N_A}q^{-N_A}, \quad N_A = \text{grau}(A(q)) \\ B(q) &= b_0 + b_1q^{-1} + b_2q^{-2} + \dots + b_{N_B}q^{-N_B}, \quad N_B = \text{grau}(B(q)) \\ C(q) &= 1 + c_1q^{-1} + c_2q^{-2} + \dots + c_{N_C}q^{-N_C}, \quad N_C = \text{grau}(C(q)) \end{aligned} \quad (2.25)$$

em que $\Gamma(t)$ é uma sequência randômica de média zero e variância σ^2 finita, tal que:

$$E \{ \Gamma(t) \} = 0 \quad \text{e} \quad E \{ \Gamma(t)^2 \} = \sigma^2 \quad (2.26)$$

A função objetivo envolve um termo no futuro, $y(t+k)$, que não é disponível em linha (*on-line*). Então, a minimização não pode ser executada a menos que se

possa substituir $y(t+k)$ por uma estimativa realizável. Isto pode ser alcançado pelo uso da seguinte identidade

$$C = FA + q^{-k}E \quad (2.27)$$

em que E e F são polinômios em q^{-1} . Esta identidade é conhecida matematicamente como a identidade de divisão polinomial, onde se obtém essencialmente o quociente e o resto da divisão direta entre dois polinômios. Neste caso

$$\frac{C}{A} = F + q^{-k}\frac{E}{A} \quad (2.28)$$

com F representando o quociente e de grau $k-1$, e E representando o resto da divisão com grau $n-1$.

Multiplicando-se a Equação (2.24) por F , tem-se:

$$FAy(t) = q^{-k}FBu(t) + CFT(t) \quad (2.29)$$

Substituindo-se a Equação (2.27), para FA , na Equação (2.29), fazendo-se k -passos no futuro e multiplicando-se por q^{-k} , tem-se:

$$(C - q^{-k}E)y(t+k) = FBu(t) + CFT(t+k) \quad (2.30)$$

Separando-se do lado esquerdo da igualdade os termos que envolvem valores futuros, e do lado direito os termos que envolvem os valores passados e corrente, tem-se:

$$Cy(t+k) - CFT(t+k) = FBu(t) + Ey(t) \quad (2.31)$$

Definindo,

$$y^*(t+k|t) = y(t+k) - FT(t+k) \quad (2.32)$$

Pode-se obter o “preditor k -passos-à-frente” de $y(t)$ como:

$$Cy^*(t+k|t) = FBu(t) + Ey(t) \quad (2.33)$$

Agora se pode usar $y^*(t+k|t)$ no lugar de $y(t+k)$ na função objetivo, desde que a função possua valores no passado e o tempo corrente tanto para y quanto para u obedecendo ao índice $(t+k|t)$. Sendo assim, deve-se re-arranjar a Equação (2.33) na forma:

$$y^*(t+k|t) = FBu(t) + Ey(t) + Hy^*(t+k-1|t-1) \quad (2.34)$$

onde H é um polinômio em q^{-1} definido como:

$$H = (1 - C)q \quad (2.35)$$

Substituindo-se $y^*(t + k|t)$ por $y(t + k)$ na função objetivo, tem-se:

$$J_{MV} = E \{ [w(t) - FBu(t) - Ey(t) - Hy^*(t + k - 1|t - 1)]^2 | t \} \quad (2.36)$$

Quando se minimiza J_{MV} , busca-se encontrar um $u(t)$ tal que:

$$\frac{\partial J_{MV}}{\partial u(t)} = -2f_0b_0 [w(t) - FBu(t) - Ey(t) - Hy^*(t + k - 1|t - 1)] = 0 \quad (2.37)$$

Desta forma, de acordo com a Equação (2.37) obtém-se a lei de controle:

$$u(t) = \frac{[w(t) - Ey(t) - Hy^*(t + k - 1|t - 1)]}{FB} \quad (2.38)$$

O controle de variância mínima apresenta algumas propriedades interessantes. Re-arranjando a Equação (2.38) tem-se:

$$w(t) = FBu(t) + Ey(t) + Hy^*(t + k - 1|t - 1) = y^*(t + k|t) \quad (2.39)$$

A equação acima é conhecida como “lei de controle”, que ao interpretá-la conclui-se que o sinal de controle calculado através da Equação (2.38) levará em k -passos preditos ($y^*(t + k|t)$) ao *setpoint* $w(t)$. Usando a definição da Equação (2.32):

$$w(t) = y(t + k) - F\Gamma(t + k) \Rightarrow y(t)w(t - k) + F\Gamma(t) \quad (2.40)$$

Assim, se o modelo do processo for preciso, a saída controlada será direcionada ao *setpoint* depois do período de atraso (tempo-morto) e o único erro será devido a uma soma no peso do ruído do processo. Se não há nenhum ruído no processo, $\Gamma(t) = 0$, então pode ser visto que o controlador de variância mínima é equivalente a um controlador conhecido como *deadbeat*.

A Equação (2.40) também representa a malha fechada do sistema, e pode-se perceber que não há nenhum pólo ou zeros. Isto indica que o controlador de variância mínima alcança seu objetivo de desempenho através do cancelamento da dinâmica do processo. Então, não pode ser aplicado a sistemas de fase não mínima, pois tornará o sistema instável após a inversão (pólos instáveis). Outra limitação é que a

estratégia de variância mínima apresenta um esforço de controle excessivo que pode não ser tolerado do ponto de vista operacional. Estas faltas práticas conduzem ao desenvolvimento do Controlador de Variância Mínima Generalizado, no qual, busca um sinal de controle $u(t)$ minimizando a seguinte função objetivo:

$$J_{GMV} = E \left\{ [Rw(t) - Py(t+k)]^2 + [Q'u(t)]^2 |_t \right\} \quad (2.41)$$

Ao comparar a Equação (2.41) com a Equação (2.23), nota-se que se diferenciam pelo fato de que no Controlador de Variância Mínima Generalizado ocorre a adição de pesos (R e P , com $P = P_n/P_d$) tanto no *setpoint* quanto na saída do sistema, além da inclusão do termo que penaliza o esforço de controle excessivo (Q').

Considerando o mesmo modelo da Equação (2.24), o problema consiste em encontrar um preditor para substituir o termo desconhecido $\varphi(t+k) = Py(t+k)$ na função objetivo dada pela Equação (2.41). Como agora se tem pesos correspondentes, a equação identidade é dada por:

$$PC = FA + q^{-k} \frac{E}{P_d} \quad (2.42)$$

Multiplicando-se a Equação (2.24) que representa o processo por F , tem-se:

$$FAy(t) = q^{-k} FBu(t) + CFT\Gamma(t) \quad (2.43)$$

Usando-se a Equação (2.42), isolando-se FA para substituição na Equação (2.43), e fazendo-se k -passos no futuro, tem-se:

$$\left(PC - q^{-k} \frac{F}{P_d} \right) y(t+k) = FBu(t) + CFT\Gamma(t+k) \quad (2.44)$$

Separando-se os termos envolvendo os valores no futuro do lado esquerdo da equação, e os termos envolvendo os valores no presente do lado direito, tem-se:

$$CPy(t+k) - CFT\Gamma(t+k) = FBu(t) + \frac{E}{P_d} y(t) \quad (2.45)$$

Agora, usando-se as definições: $y'(t) = y(t)/P_d$; $\varphi^*(t+k|t) = \varphi(t+k) - F\Gamma(t+k)$; $G = FB$ e $H = (1 - C)q$,

$$\varphi^*(t+k|t) = Gu(t) + Ey'(t) + H\varphi^*(t+k-1|t-1) \quad (2.46)$$

Substituindo-se a Equação (2.46) na Equação (2.41), obtém-se;

$$\frac{\partial J_{GMV}}{\partial u(t)} = -2g_0 [Rw(t) - Gu(t) - Ey'(t) - H\varphi^*(t+k-1|t-1)] + 2q'_0 Q' u(t) = 0 \quad (2.47)$$

Simplificando-se e rearranjando-se a equação, tem-se a seguinte lei de controle:

$$\varphi^*(t+k|t) - Rw(t) + Qu(t) = 0 \quad (2.48)$$

com $Q = q'_0 Q' / g_0$. Novamente, se os parâmetros do processo forem conhecidos, então o sinal de controle é calculado pela equação:

$$u(t) = \frac{\left[Rw(t) - \sum_{i=1}^{N_G} g_i u(t-1) - Ey'(t) - H\varphi^*(t+k-1|t-1) \right]}{g_0 + Q} \quad (2.49)$$

A expressão para a malha fechada utilizando-se o algoritmo GMV é um pouco mais complicada que no caso do algoritmo MV, mas não é de difícil determinação. Primeiro deve-se re-escrever a lei de controle como:

$$\varphi^*(t+k|t) = Py^*(t+k|t) = Py(t+k) - F\Gamma(t+k) = Rw(t) - Qu(t) \quad (2.50)$$

Fazendo-se k -passos a trás, tem-se:

$$\begin{aligned} Py(t) - F\Gamma(t) &= Rw(t-k) - Qu(t-k) \\ u(t-k) &= \frac{Rw(t-k) - Py(t) + F\Gamma(t)}{Q} \end{aligned} \quad (2.51)$$

Substituindo-se $u(t-k)$ no modelo dado pela Equação (2.24), tem-se então a equação que representa a malha fechada:

$$y(t) = \frac{BRw(t-k) + (FB + QC)\Gamma(t)}{PB + QA} \quad (2.52)$$

Desta forma, a partir da Equação (2.52), podem-se estudar as propriedades do GMV, mas desde já, nota-se a ausência do termo de atraso da equação da malha fechada, o que denota que o GMV tem ação compensatória do tempo-morto.

Dependendo da escolha dos pesos, o GMV pode ser interpretado de vários modos:

- *controle de variância mínima:* Escolhendo $P = 1$, $R = 1$ e $Q = 0$ para a

Equação (2.49) tem-se:

$$y(t) = w(t - k) + F\Gamma(t) \quad (2.53)$$

Ficando evidente que para os valores mencionados acima para os pesos, o controlador GMV fica idêntico ao controlador MV;

- *controle seguidor de modelos*: Escolhendo-se $Q = 0$ na Equação (2.52) tem-se:

$$y(t) = \frac{Rw(t - k) + F\Gamma(t)}{P} \quad (2.54)$$

A Equação (2.54) mostra que a saída controlada irá para o *setpoint* com respostas características governadas pela relação R/P . Também, o termo de ruído é filtrado pela relação $1/P$. Então, pode-se selecionar $1/P$ para agir como um filtro de ruído e enquanto R é especificado tal que R/P é o modelo “desejado” que a malha fechada deve se aproximar. Isto conduz ao que se conhece como “seguidor de modelo” ou “modelo de referência”;

- *preditor de Smith*: Escolhendo-se $P = 1$, $R = 1$ e $Q \neq 0$, tem-se a seguinte lei de controle:

$$y^*(t + k|t) - w(t) + Qu(t) = 0 \quad (2.55)$$

ou

$$u(t) = \frac{w(t) - y^*(t + k|t)}{Q} \quad (2.56)$$

que pode ser representado pelo diagrama de blocos da Figura (2.2): A ex-




Figura 2.2: Interpretação da estratégia de controle GMV com *Preditor de Smith* (SOUZA, 2007).

pressão correspondente para a malha fechada neste caso é:

$$y(t) = \frac{Bw(t-k) + (FB + QC)\Gamma(t)}{B + QA} \quad (2.57)$$

Feita a interpretação de casos onde se escolhe o peso aplicado ao sistema de controle, um dos problemas que afetam tanto o controle MV quanto GMV, é a presença de erros permanentes (*offsets*), e há várias razões para que isso ocorra quando estes controladores forem aplicados:

1. *offsets devido a perturbações desconhecidas*: Ocorre quando o sistema é afetado por perturbações não conhecidas/não medidas e com média diferente de zero. Na tentativa de resolver este problema, Tham (1999) propôs a inclusão do termo de perturbação na equação de processo ficando da seguinte maneira:

$$Ay(t) = q^{-k}Bu(t) + C\Gamma(t) + \hat{d}(t) \quad (2.58)$$

com

$$\hat{d}(t) = \hat{d}(t-1) + (y(t) - y^*(t|t-k))$$

Sendo assim, agora com a inclusão do termo de perturbação, tem-se as seguintes leis de controle:

MVC:

$$y^*(t+k|t) = FBu(t) + Ey(t) + F\hat{d}(t) + Hy^*(t+k-1|t-1) \quad (2.59)$$

e,

$$u(t) = \frac{1}{g_0} \left[w(t) - \sum_{i=1}^{N_G} g_i u(t-i) - Ey(t) - F\hat{d}(t) - Hy^*(t+k-1|t-1) \right] \quad (2.60)$$

GMVC:

$$\varphi^*(t+k|t) = Gu(t) + Ey'(t) + F\hat{d}(t) + H\varphi^*(t+k-1|t-1) \quad (2.61)$$

$$u(t) = \frac{\left[Rw(t) - \sum_{i=1}^{N_G} g_i u(t-i) - Ey'(t) - F\hat{d}(t) - H\varphi^*(t+k-1|t-1) \right]}{g_0 + Q} \quad (2.62)$$

2. *offset a partir de um peso escalar utilizado no sistema de controle:* Para ilustrar melhor este caso, toma-se como base a Equação (2.49) com $\Gamma = 0$; $Q = \lambda$; $R = P = 1$, então o valor de saída para o estado estacionário é:

$$y(t) \rightarrow \frac{B(1)w(t-k)}{B(1) + \lambda A(1)} \neq w(t-k) \quad (2.63)$$

Não será alcançado o *setpoint* exato a menos que $A(1) = 0$, e o processo tenha propriedade integrante. Felizmente, este problema pode ser resolvido; em vez de penalizar controle excessivo, a função objetivo é modificada para penalizar mudanças excessivas em controle, o que conduz a uma função objetivo da forma:

$$J = F \left\{ [Rw(t) - Py(t+k)]^2 + [\lambda(1 - q^{-1})u(t)]^2 \right\}_t \quad (2.64)$$

A vantagem aqui é que os pesos podem ser ajustados/sintonizados como se fosse um controlador convencional que usa as numerosas regras de sintonização que estão disponíveis.

Outro método envolve o ajuste do ganho do peso para o *setpoint* R , tal qual o erro seja direcionado para zero. Isto ocorre, se e somente se:

$$\frac{B(1)R(1)}{P(1)B(1) + Q(1)A(1)} = 1 \quad (2.65)$$

Outro modo para que se consiga compensar o problema de *offset* é o projeto do controlador utilizando o modelo CARIMA (*Controlled Auto-Regressive Integrated Moving Average*) ao invés do modelo CARMA dado pela Equação (2.24):

$$Ay(t) = q^{-1}Bu(t) + C\Gamma(t)/\Delta \quad (2.66)$$

com $\Delta = 1 - q^{-1}$

A interpretação para $\Gamma(t)/\Delta$ é que mesma representa a manifestação de uma sequência de perturbação que acontece em uma sucessão de passos ocorridos em intervalos de tempo ao acaso. De certo modo, isto é mais representativo para perturbações reais no processo. Sendo assim, o controlador GMV pode ser desenvolvido a partir da Equação (2.66) e da função objetivo, dada pela Equação (2.41), de acordo com a identidade:

$$PC = FA\Delta + q^{-k} \frac{E}{P_d} \quad (2.67)$$

O resultado é dado por:

$$\varphi^*(t+k|t) = G\Delta u(t) + Ey'(t) + H\varphi^*(t+k-1|t-1) \quad (2.68)$$

com $y'(t) = y(t)/P_d$; $\varphi^*(t+k|t) = \varphi(t+k) - E\Gamma(t+k)$; $G = FB$ e $H = (1-C)q$.

Substituindo-se na Equação (2.41) e realizando-se a minimização, obtém-se a seguinte lei de controle, idêntica a Equação (2.48):

$$\varphi^*(t+k|t) - Rw(t) + Qu(t) = 0 \quad (2.69)$$

com $Q = q_0'Q'/g_0$

Mas, devido à diferença na equação de predição, o sinal de controle é calculado da seguinte maneira:

$$u(t) = \frac{Rw(t) - Ey'(t) - H\varphi^*(t+k-1|t-1)}{Q + \Delta G} \quad (2.70)$$

Assim, se Q também contém o fator $1 - q^{-1}$, a Equação (2.70) descreve a ação de controle que corresponde a seguinte malha fechada:

$$y(t) = \frac{BR\Delta w(t-k) + (FB\Delta + QC)\Gamma(t)}{\Delta(PB + QA)} \quad (2.71)$$

O cálculo da variância do sinal de saída é dado por:

$$\sigma_y^2 = (1 + f_1^2 + f_2^2 + \dots + f_{k-1}^2 + f_k^2 + f_{k+1}^2 + \dots)\sigma_a^2 \quad (2.72)$$

Para se obter a variância mínima do sistema, deve-se obedecer:

$$\sigma_y^2 \geq (1 + f_1^2 + f_2^2 + \dots + f_{k-1}^2)\sigma_a^2 = \sigma_{MV}^2 \quad (2.73)$$

com $(f_1^2 + f_2^2 + \dots + f_{k-1}^2)$ coeficientes do polinômio F , e σ_a^2 representa a variância do ruído branco.

O desenvolvimento de abordagens para sistemas SISO é bastante ilustrativo, entretanto, a realidade industrial demanda por abordagens mais amplas que incluam os sistemas MIMO, desta forma, considere o seguinte sistema MIMO localmente linear representado pela Figura (2.3) (HUANG et al., 1997b).

Com malha aberta representada por: $Y_t = GU_t + Na_t$, e a malha fechada dada




Figura 2.3: Diagrama de blocos para um sistema de controle.

por:

$$Y_t = (I + GK)^{-1}GY_t^{sp} + (I + GK)^{-1}Na_t \quad (2.74)$$

com Y_t , U_t e a_t , os vetores de saída, entrada e ruído branco, respectivamente. G , a matriz de funções de transferência do processo, K a matriz de funções de transferência do controlador, e N a matriz de funções de transferência da perturbação. Com a adição do ruído branco, deve-se garantir que o mesmo possua média zero e variância unitária.

Um dos métodos mais comumente utilizados para a obtenção do índice de desempenho com MVC é a utilização do algoritmo FCOR (*Filtering and Subsequent Correlation Analysis*), onde se obtém o resultado através da minimização da função objetivo (HUANG et al., 1997a):

$$J = E \left[\tilde{Y}_t^T \tilde{Y}_t \right] \quad (2.75)$$

com $\tilde{Y}_t = q^{-d}DY_t$, e D representa a Matriz de Interação Unitária, que pode ser obtida pela fatoração de T (ROGOZISKI et al., 1987) abordada no Apêndice A, e d representa o grau de D . A medida do sinal de saída para o MVC é obtida por:

$$E \left[\tilde{Y}_t^T \tilde{Y}_t \right]_{\min} = E(e_t^T)(e_t) = \text{tr} [\text{variância}(Fa_t)] \quad (2.76)$$

com $e_t = Fa_t$, e a matriz polinomial F depende somente da Matriz de Interação e do modelo da perturbação, satisfazendo a seguinte identidade:

$$q^{-d}DN = F_0 + \dots + F_{d-1}q^{-(d-1)} + q^{-d}R \quad (2.77)$$

com $F = F_0 + \dots + F_{d-1}q^{-(d-1)}$ e R é racional e própria, com o termo de Variância Mínima $e_t = Fa_t$ representado por F submetido ao ruído branco.

Desta forma, obtém-se o sinal de saída para o sistema MVC representado por:

$$Y_t|_{MV} = q^d D^{-1} F a_t \quad (2.78)$$

O algoritmo FCOR pode ser facilmente implementado de acordo com as seguintes etapas:

1. com as matrizes de funções de transferência do modelo (G) e da perturbação (N), obtenha a matriz de interação unitária D através da fatoração do modelo (Apêndice A);
2. com a matriz de interação unitária (D), obtenha F e R de acordo com a Equação (2.77), na qual F depende somente de D e N , e R é racional e própria;
3. com F , obtenha o sinal de saída para o sistema, de acordo com a Equação (2.78);
4. com o sinal de saída representado pela Equação (2.78), submetido a um ruído branco, chega-se ao índice de desempenho, que é representado por:

$$\eta(d) = \frac{\text{Variância Mínima}}{\text{Variância do Controle Atual}} = \frac{E[Y_t^T Y_t]_{\min}}{E[Y_t^T Y_t]} = \frac{\sigma_{Y_t|MV}^2}{\sigma_{Y_t}^2} \quad (2.79)$$

com $\sigma_{Y_t|MV}^2$ a variância do sinal de saída do sistema de referência, e $\sigma_{Y_t}^2$ a variância do sinal de saída do sistema de controle corrente (analisado).

2.2 Detecção de oscilações

Descobrir anormalidades em sistemas de controle é uma tarefa muito importante, e dentre estas, existem oscilações que podem estar ligadas a várias origens, dentre elas destacam-se a perda do desempenho da malha de controle, agarramento de válvulas, ou perturbações com mesma natureza.

De acordo com McMillan (2009) as válvulas de controle são usadas como elemento final em 95% ou mais dos sistemas de controle dos processos industriais. Desta forma, levando em consideração esta afirmação e excetuando-se o caso em que os controladores estão com problemas de sintonia ou necessitando de uma atualização do modelo da planta, o emperramento de válvulas representa uma das principais causas de oscilação de sistema de controle.

Com o objetivo de se manter o sistema de controle em sua eficiência nominal, é importante detectar, localizar e diagnosticar oscilações.

Existem na literatura diversos estudos sobre o desempenho de malhas de controle, muito deles abordando a questão da oscilação.

Thornhill et al. (2003) desenvolveram um método baseado na regularidade dos cruzamentos de zeros e de funções de autocovariância filtradas.

Tangirala et al. (2005) trabalharam com uma ferramenta de visualização como o mapa de correlação do espectro de potência. O mapa apresenta cores que estão baseadas em uma nova medida, definida como o índice de correlação do espectro de potência, que é definido pela correlação entre o espectro de potência de duas diferentes medidas X_1 e X_2 , como:

$$PSCI = \frac{\sum_{\omega_k} |X_i(\omega_k)|^2 |X_j(\omega_k)|^2}{\sqrt{\sum_{\omega_k} |X_i(\omega_k)|^4 \sum_{\omega_k} |X_j(\omega_k)|^4}} \quad (2.80)$$

com X_i e X_j medidas e ω_k a frequência.

De acordo com Jiang et al. (2007), são comuns as oscilações em processos de grande dimensão. Os efeitos destas se propagam a muitas unidades e podem comprometer o desempenho do processo global, sendo assim, os autores apresentaram um procedimento para descobrir e diagnosticar oscilações em processos de grandes dimensões usando dados operacionais. Esta técnica é denominada como envelope espectral, que pode ser descrita pela equação abaixo:

$$\lambda(\omega) = \sup_{\beta \neq 0} \left\{ \frac{\beta^* P_X(\omega) \beta}{\beta^* V_X \beta} \right\} \quad (2.81)$$

em que $P_X(\omega)$ é a densidade do espectro de potência das medidas X , V_X é a covariância da matriz X , e seja $g(t, \beta) = \beta^* x(t)$ uma série escalar de \mathbb{R}^m em \mathbb{R} , com β um vetor de $m \times 1$ elementos de X real ou complexo. O símbolo $*$ representa o conjugado transposto da variável.

Odgaard e Wickerhauser (2007) apresentaram um esquema de detecção da oscilação baseada na análise Karhunen-Loève para sistemas em que não há transições operacionais. Uma extensão dessa metodologia será o foco deste trabalho.

Jiang et al. (2009) propuseram um método para diagnosticar a causa raiz das oscilações em processos de grande dimensão, usando o conceito de matriz de ad-

jacência. Uma característica nova deste método é que o mesmo utiliza apenas as informações dos fluxos do processo. Embora não seja baseado em dados operacionais, este método complementa outros que necessitam de dados de operação da planta.

Li et al. (2010) propuseram um método baseado na transformação discretizada do cosseno para descobrir oscilações simples em séries temporais. A ideia principal introduzida pelo método é o isolamento de componentes de diferentes frequências das séries temporais, e descobrir oscilações conferindo as regularidades dos cruzamentos dos zeros, tendo como principais características:

- uso somente das informação de séries temporais;
- habilidade para lidar com variáveis com resposta lenta;
- robustez para ruídos brancos e coloridos;
- capacidade de detectar a presença de oscilações múltiplas;
- não utiliza a intervenção humana.

Mesmo com todas as técnicas existentes, nota-se ainda que há a necessidade de uma abordagem que seja de implementação simples, capaz de detectar oscilações complexas e portanto apropriadas para a utilização no monitoramento automático de plantas industriais. Assim, na Seção 3.3.1 será introduzida uma modificação da técnica proposta por Odgaard e Wickerhauser (2007), de forma que a localização das oscilações não necessite do conhecimento específico da planta monitorada (SOUZA; OLIVEIRA-LOPES, 2010).

2.3 Detecção do emperramento de válvulas

Como visto na Seção 2.2, uma das causas mais comuns de degradação do desempenho de sistemas de controle é a presença de oscilações e estas podem ser causadas pelo emperramento, podendo degradar o desempenho global do sistema controlado e, eventualmente, a qualidade de produto final (SCALI; GHELARDONI, 2008). Oscilações também podem ser o resultado de outros fatores, como perturbações externas ou sintonização pobre dos controladores. Quando detectado o problema, deve ser executada manutenção da válvula ou compensação do emperramento, por exemplo, através de redundâncias físicas, utilizando outro elemento final de controle. A

re-sintonização de controladores ou a implementação de mudanças na estrutura de controle, também são medidas para atenuar este problema. Desta forma, descobrir as causas de umas oscilações em sistemas de controle é de extrema importância, para um sistema de monitoramento eficiente (CHITRALEKHA et al., 2010).

A Figura 2.4 representa esquematicamente o funcionamento de uma válvula, e o local onde ocorre o emperramento.




Figura 2.4: Válvula de controle (JELALI; HUANG, 2010).

Seja o diagrama de blocos, representando um sistema de controle, de acordo com a Figura 2.5:



Figura 2.5: Diagrama de blocos do sistema de controle *feedback* (JELALI; HUANG, 2010).

Na qual,

SP - setpoint;

OP - saída do controlador;

MV - variável manipulada ou sinal de saída da válvula (posição da válvula);

PV - variável do processo (saída);

O estudo da detecção do emperramento de válvulas está diretamente ligado a OP e MV, ou seja, o sinal de entrada da válvula e o sinal de saída da válvula respectivamente.

Para entender melhor a não linearidade das válvulas, deve-se conhecer alguns conceitos:

- **Backlash:** um movimento entre peças mecânicas, resultantes de folga, quando o movimento é inverso;
- **Histerese:** diferença entre a indicação para um dado valor do mensurando quando este foi atingido por valores crescentes e a indicação quando o mensurando é atingido por valores decrescentes. Valores no estado atual dependem de valores no estado anterior;
- **Deadband:** faixa da variação do sinal de entrada, mesmo sobre a reversão de sentido, sem modificação perceptível no sinal de saída;
- **Deadzone:** faixa predeterminada de entrada através do qual a saída permanece inalterada, independentemente do sentido da mudança do sinal de entrada.

A Figura 2.6 ilustra esquematicamente o movimento de uma válvula, abordando os conceitos de histerese, deadband e deadzone.




Figura 2.6: Movimento da válvula (JELALI; HUANG, 2010).

Observando a Figura 2.6(c), pode-se detalhar melhor o movimento da válvula, de acordo com a Figura 2.7:

Observando a Figura 2.7, se a válvula se movimentar na linha tracejada-pontuada, que passa pela origem, indica que a mesma não possui emperramento. O comportamento de entrada e saída de uma válvula pode ser resumido em quatro componentes:




Figura 2.7: Relação entre OP e MV (JELALI; HUANG, 2010).

deadband, fase de movimentação, *slip jump* e banda de emperramento, sendo assim, caracterizado por três fases (JELALI; HUANG, 2010):

- **Emperramento** - MV é constante com o tempo, e a válvula está presa pela presença da força de fricção estática F_s (Deadband + Emperramento). A fase deadband da válvula é devido à presença da força de fricção de Coulomb F_c , que age no oposto da velocidade;
- **Salto** - MV muda repentinamente, e a força ativa F_a , desbloqueia a válvula, entrando na fase de movimentação;
- **Movimento** - MV varia gradualmente.

Com o objetivo de caracterizar o emperramento de válvulas, as quantidades S (deadband + emperramento) e J (*slip jump*), foram utilizadas (CHOUDHURY et al., 2005), de acordo com a Figura 2.7. Esta caracterização pode ser obtida, porque OP e MV são geralmente obtidos através da percentagem do movimento nos limites do range da válvula, enquanto todas as outras variáveis, S , J , $u(OP)$, $y(PV)$, e $u_V(MV)$ são traduzidas em percentagem do range da válvula de tal forma que a álgebra (valores quantitativos) pode ser executada diretamente entre elas. Os parâmetros f_s

(fricção de Coulomb normalizada) e f_d (fricção dinâmica/cinética/Coulomb normalizada) podem ser relacionadas com S e J da seguinte forma:

$$S = f_s + f_d \quad (2.82)$$

$$J = f_s - f_d \quad (2.83)$$

que também pode ser escrito:

$$f_s = \frac{S + J}{2} \quad (2.84)$$

$$f_d = \frac{S - J}{2} \quad (2.85)$$

Muitos métodos para a identificação do emperramento de válvulas estão disponíveis na literatura, alguns dos métodos são manuais ou requer interação forte com o usuário, sendo estes, conhecidos como métodos intrusivos para a detecção do emperramento, na qual é enviado um sinal para a válvula com amplitude maior e sentido contrário ao sinal normal, fazendo com que a válvula responda através de uma movimentação repentina, que deverá ser acompanhada para a verificação se a válvula está emperrada ou não.

Outras técnicas são baseadas em conhecimento adicional sobre a curva característica da válvula e valores da variável manipulada ou de posição da válvula. Algumas técnicas são capazes de detectar o emperramento através de modelos matemáticos, conhecidos como métodos não intrusivos, porém esses métodos têm sua eficiência comprovada, apenas em malhas de controle individuais e que não levam a propagação da oscilação.

Algumas técnicas só é capaz de descobrir a presença de emperramento, outras aproximações também mostram apenas uma estimativa da extensão do emperramento. Além disso, os métodos diferem na robustez, presença de ruídos, sistemas que não estão em estado estacionário, e tendências a oscilações múltiplas, que podem estar presente em dados industriais (JELALI; HUANG, 2010).

Jelali e Huang (2010) fizeram um estudo comparativo de diversos métodos para a identificação do emperramento de válvulas em sistemas de controle. Foram comparados diversos métodos, e o estudo envolveu 93 conjuntos de dados de diversos

processos industriais, tais como indústria envolvendo processos químicos, de papel, construção civil, comércio e metalúrgica.

A Figura 2.8 mostra em linha do tempo, diversos métodos para identificar o emperramento de válvulas.

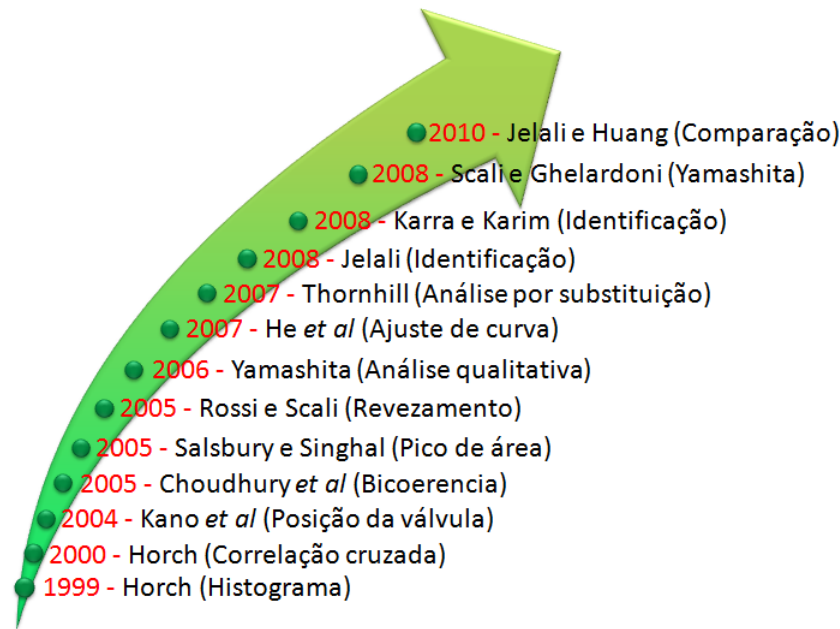


Figura 2.8: Métodos para detecção do emperramento de válvulas.

O estudo realizado por Jelali e Huang (2010) contou com os seguintes métodos: Horch (1999) desenvolveu uma técnica que pode ser aplicado em sistemas integrantes e auto-regulatórios. Não é um método muito simples, pois sua principal desvantagem é a sensibilidade a ruídos. Este método está baseado nas suposições de que, em processos integrantes, o sinal PV possui a forma triangular para o caso em que há emperramento (e senoidal quando não há emperramento). A Figura 2.9 mostra a suposição do sinal PV.

Um ano depois, Horch (2000) desenvolveu um método para a detecção do emperramento de válvulas, baseado na correlação cruzada. É simples e de fácil implementação, além do que, necessita apenas de dados operacionais normais (sem emperramento), e não necessita de um conhecimento detalhado do processo, por parte do usuário. As características principais do método são:

1. o método não pode ser aplicado a sistemas integrantes;
2. a troca de fase depende da sintonia do controlador: o atraso de fase é π para um controlador agressivo quando a malha de controle é saturada; porém, quando ocorre emperramento da válvula, e a malha de controle não é saturada, o atraso de fase pode estar entre $\pi/2$ e π para um controlador PI.

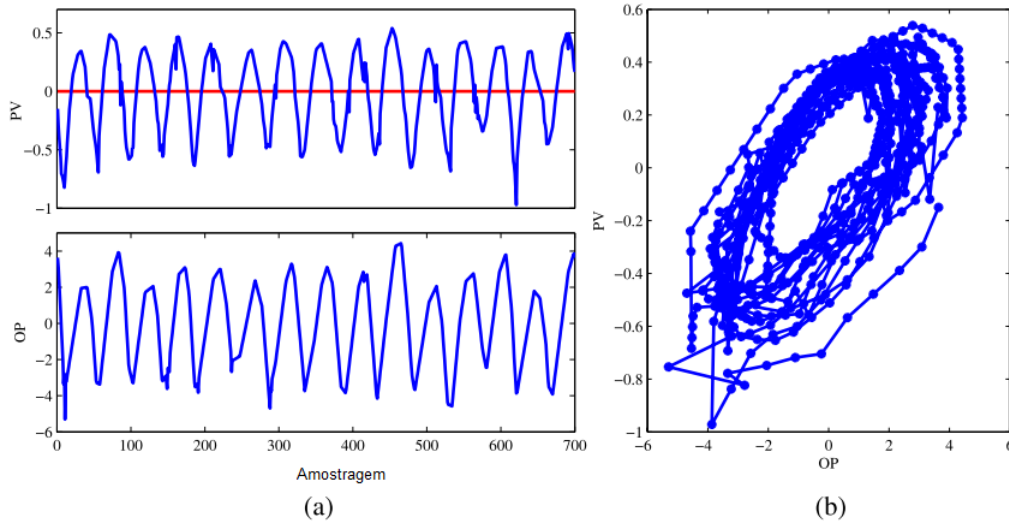


Figura 2.9: a) Tendências para PV e OP; b) Comportamento de PV-OP (JELALI; HUANG, 2010).

A detecção do emperramento através da correlação cruzada é realizada através da função:

$$r_{uy}(\tau) = \sum_{k=0}^{N-|\tau|-1} u(k)y(k+\tau) \quad (2.86)$$

com N o número finito de dados.

Kano et al. (2004) propuseram uma técnica para detecção do emperramento de válvulas, que requer a medida da posição válvula. Se a posição da válvula não estiver disponível, a razão do fluxo pode ser usada. As dificuldades principais, associado com a aplicação deste método são:

1. presença de ruídos;
2. dependendo da dinâmica do fluxo, estas informações podem distorcer a forma padrão do emperramento.

A detecção do emperramento é obtida através de função:

$$F(t) = \max\{\min\{F(t-1) + \Delta u(t), F_{\max}\}, 0\} \quad (2.87)$$

com F sendo a diferença entre o sinal de saída do controlador (u) e a posição da válvula e F_{\max} é o máximo valor de F .

Choudhury et al. (2005) propuseram uma técnica para a detecção do emperra-

mento de válvulas através da modelagem física da válvula.

Salsbury e Singhal (2005) desenvolveram um método simples e de fácil implementação computacional, utilizando a estimativa de pólos do modelo ARMA, porém, necessitando de dados que permitem boas estimativas para o pico de área e local do zero, no erro de controle.

Rossi e Scali (2005) propuseram um método para a detecção do emperramento, conhecido como revezamento, através do cálculo do índice:

$$S_1 \triangleq \frac{\overline{E_S} - \overline{E_{RT}}}{\overline{E_S} + \overline{E_{RT}}} \quad (2.88)$$

com E_S o mínimo erro quadrado, obtido através de uma aproximação sinusoidal e E_{RT} é a melhor aproximação entre o revezamento e as ondas triangulares da aproximação sinusoidal. Quando $S_1 > 0,21$, o emperramento é detectado.

Yamashita (2006) propôs um método para detecção do emperramento, baseado na descrição qualitativa dos sinais de entrada e saída da válvula, desta forma o método proposto, como o de Kano et al. (2004), também requer a medida da posição válvula. Se a posição da válvula não estiver disponível, a razão do fluxo pode ser usada. As dificuldades principais, associado com a aplicação deste método são, como em Kano et al. (2004):

1. presença de ruídos;
2. dependendo da dinâmica do fluxo, estas informações podem distorcer a forma padrão do emperramento.

Apesar das dificuldades apresentadas, este método proposto por Yamashita, tem sido o método mais seguro e de fácil implementação para a detecção do emperramento de válvulas.

He et al. (2007) propuseram um método para detectar o emperramento de válvulas, baseado em ajuste de curva do sinal de saída do primeiro componente integrante após a válvula, se o controlador for do tipo regulador ou o processo for integrante. O índice proposto foi chamado de índice de emperramento (SI), com o objetivo de detectar de forma automática o emperramento de válvulas.

O SI é obtido através da equação:

$$SI = \frac{MSE_{Sin}}{MSE_{Sin} + MSE_{Tri}} \quad (2.89)$$

com MSE_{Sin} é o erro quadrado médio para o ajuste sinusoidal entre OP e MV, e MSE_{Tri} é o erro quadrado médio para o ajuste triangular entre OP e MV.

Os autores concluíram que:

$$\begin{cases} SI \leq 0,4 \Rightarrow \text{Sem emperramento} \\ 0,4 < SI < 0,6 \Rightarrow \text{Indeterminado} \\ SI \geq 0,6 \Rightarrow \text{Emperramento} \end{cases} \quad (2.90)$$

Thornhill (2007) propôs um método baseado na análise de substituição, combinado ao ajuste elíptico para a detecção do emperramento de válvulas.

Jelali (2008) apresentou um novo procedimento para a detecção do emperramento de válvulas, utilizando otimização. O método é baseado na identificação de sistemas através do modelo ARMAX, utilizando a estrutura de Hammerstein, com os sinais de saída do controlador (OP), e os sinais de saída PV, de acordo com a Figura 2.10.

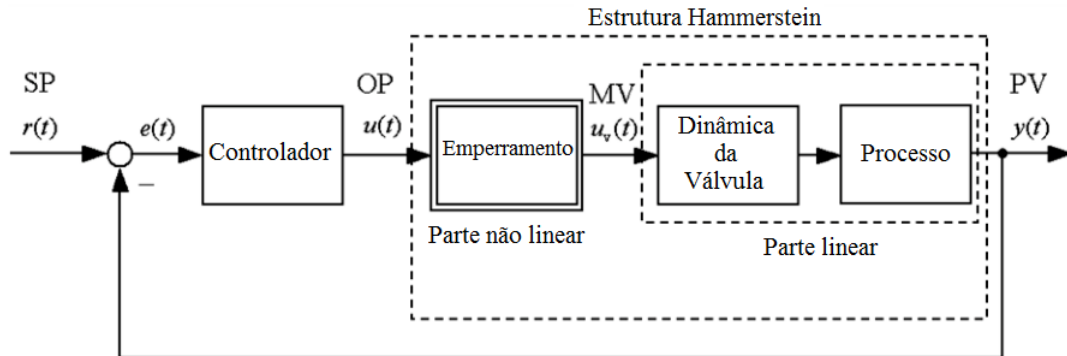


Figura 2.10: Estrutura Hammerstein (JELALI, 2008).

Karra e Karim (2009) também utilizaram técnicas de identificação de sistemas para detectar o emperramento de válvulas de controle. A técnica apresentada tem a vantagem de que, não apenas detecta o emperramento, mas também as quantifica.

Chitrlekha et al. (2010) propuseram um método para detecção do emperramento de válvulas, estimando o sinal de saída da válvula (MV) que é desconhecido.

Jelali e Huang (2010) em seus estudos comparativos, concluíram que, dos 93 casos estudados o método de Yamashita, embora seja bastante sensível à presença de ruídos, é o mais seguro e também é de fácil implementação. Desta forma, a utilização deste método (SOUZA; OLIVEIRA-LOPES, 2011a), será o foco desta tese para a detecção do emperramento de válvulas em processos de controle, e que será apresentado com mais detalhes na Seção 3.4.

2.4 Detecção de falhas: perturbações e sensores

Na literatura existem diferentes técnicas para a detecção de falhas em processos (LSERMANN, 1997; MISRA et al., 2002; HUANG; WU, 2003; ZHIMIN et al., 2007; SAMY et al., 2011; YANG et al., 2011). Para monitorar sistemas utilizando dados históricos do processo, a técnica mais utilizada é a Análise dos Componentes Principais, que tem como base a análise estrutural, podendo descrever o modelo de maneira mais simples.

Nas próximas seções deste capítulo, serão discutidos com maiores detalhes a técnica de detecção de falhas utilizando Análise dos Componentes Principais (PCA).

2.4.1 Análise dos componentes principais (PCA)

A técnica PCA é utilizada para a construção de modelos estatísticos baseados em dados históricos do processo, indicado principalmente para processos industriais de grande porte, com grande quantidade de variáveis importantes para controle de processos.

Com o modelo estatístico obtido através do PCA, é possível detectar falhas utilizando as variáveis mais importantes do processo, projetando os dados do mesmo em um espaço de dimensão reduzida, ou seja, todas as informações do processo são preservadas, porém, a técnica PCA permite a utilização de um conjunto de dados de dimensão reduzida e que captura a variabilidade do sistema.

Existem na literatura, diversos pesquisadores que tem utilizado a PCA como uma ferramenta para o monitoramento de processos industriais, principalmente porque a técnica permite a redução da dimensão de um conjunto de dados de um processo multivariável em análise, e é de fácil implementação (PIOVOSO; KOSANOVICH, 1992; PIOVOSO; KOSANOVICH, 1994; WISE; GALLAGHER, 1996; MISRA et al., 2002; HUANG; WU, 2003; ZHIMIN et al., 2007; DING et al., 2010; ALKAYA; EKER, 2011).

Para obter um modelo estatístico de dimensão reduzida utilizando a PCA, necessita-se de um conjunto de dados históricos do processo, na qual, através de tratamentos estatísticos, consegue-se então obter uma representação generalizada para dados independentes do processo através de um espaço dimensional menor, ou seja, este novo modelo consegue descrever de forma geral o processo com dimensão reduzida.

Reis (2008) utilizou a técnica PCA propondo um controle tolerante com recon-

figuração estrutural acoplado à sistemas de diagnósticos de falha.

A utilização de uma dimensão reduzida melhora a eficiência de detecção de falhas. Uma outra característica importante da PCA é a sua utilização para identificar variáveis responsáveis ou afetadas por algum comportamento anormal (WISE et al., 1989). O monitoramento por PCA pode se tornar mais completo quando utiliza-se, além do monitoramento das variações de estado, a do ruído aleatório, que é a parte descartada pelo processo de redução de dimensionalidade da PCA. Tal fato justifica-se devido ao conhecimento de que alguns tipos de falhas afetam primeiro um dos dois subespaços (estados ou ruídos), logo, desenvolver medidas específicas para cada um deles pode significar em um aumento da sensibilidade do monitoramento (REIS, 2008).

A aplicação da técnica PCA está relacionada com a resolução de um problema de valor característico no qual um conjunto de vetores característicos ortogonais são associados com os maiores valores característicos, ordenados assim pela quantidade de variância explicada pelas direções destes vetores (REIS, 2008).

Considere um conjunto de dados históricos de um processo, com n observações e m variáveis de processo dispostas em uma matriz \mathbf{X} :

$$X = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1m} \\ x_{21} & x_{22} & \cdots & x_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nm} \end{bmatrix} \quad (2.91)$$

Calcula-se os vetores característicos através da solução dos pontos estacionários do problemas de otimização:

$$\max_{v \neq 0} \frac{v^T X^T X v}{v^T v} \quad (2.92)$$

com que $v \in \mathbb{R}^m$.

Através da decomposição dos valores singulares SVD (Singular Value Decomposition) de $\frac{1}{\sqrt{n-1}}X$, calcula-se os pontos estacionários da Equação 2.92:

$$\frac{1}{\sqrt{n-1}}X = U \Sigma V^T \quad (2.93)$$

com $U \in \mathbb{R}^{n \times n}$ e $V \in \mathbb{R}^{m \times m}$ são matrizes unitárias, e a matriz $\Sigma \in \mathbb{R}^{n \times m}$ contém valores singulares reais não negativos com magnitudes decrescente ao longo da dia-

gonal principal ($\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_{\min(m,n)} \geq 0$) com os elementos não pertencentes a diagonal principal iguais a zero (REIS, 2008). Os vetores característicos são vetores coluna ortogonais na matriz V , e a variação do conjunto de dados experimentais projetada ao longo da i -ésima coluna de V é igual a σ_i^2 (CHIANG et al., 2001).

Para resolver a Equação (2.93) deve-se utilizar uma decomposição em valores característicos da matriz de covariância amostral S :

$$S = \frac{1}{n-1} X^T X = V \Lambda V^T \quad (2.94)$$

em que a matriz diagonal $\Lambda = \Sigma^T \Sigma \in \mathbb{R}^{m \times m}$ contém os valores característicos reais não negativos de magnitude decrescente ($\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m \geq 0$) e o i -ésimo valor característico (λ_i) é igual ao quadrado do i -ésimo valor singular (λ_i^2).

O objetivo principal da PCA é capturar de forma ótima as variações dos dados e ao mesmo tempo minimizar o efeito da presença de possíveis ruídos aleatórios, visto que este prejudicam a representação por PCA, sendo assim, é muito comum utilizar os a (número do componente principal) maiores valores característicos para garantir o principal objetivo da técnica. Esta redução de dimensão é motivada para que se proteja sistemas de detecção de falhas que separem as partes do processo que contém ruído aleatório, monitorando assim, de forma independente, esse dois tipos de situação (REIS, 2008).

Com os a maiores valores característicos pertencentes as colunas da matriz \mathbf{V} obtém-se a matriz $\mathbf{P} \in \mathbb{R}^{m \times a}$, assim:

$$T = X P \quad (2.95)$$

A matriz \mathbf{T} contém a projeção das observações em \mathbf{X} num espaço de menor dimensão, e a projeção de \mathbf{T} , novamente no espaço de observação m -dimensional, é

$$\hat{X} = T P^T \quad (2.96)$$

A matriz residual \mathbf{E} pode ser determinada, pela diferença de \mathbf{X} com $\hat{\mathbf{X}}$:

$$E = X - \hat{X} \quad (2.97)$$

É muito importante a escolha de a , pois $\mathbf{T} \mathbf{P}^T$ representa a principal fonte de

variabilidade do processo e \mathbf{E} representa a variabilidade correspondente ao ruído no processo, como pode ser observado na Figura 2.11:

Desta forma, o processo de modelagem da PCA pode ser descrito de acordo com o fluxograma, representado pela Figura 2.12:

Reis (2008) em seu trabalho, mostrou que definindo t_i como a i -ésima coluna de \mathbf{T} no conjunto de dados experimentais, as seguintes propriedades podem ser demonstradas:

1. variância $(t_1) \geq \text{variância}(t_2) \geq \dots \geq \text{variância}(t_a)$;
2. média de $t_i = 0; \forall_i$;
3. $t_i^T t_k = 0; \forall_i \neq k$;
4. não existe outra expansão ortogonal de a componente que capture mais variações dos dados.

Assim, quando um novo vetor coluna de observações no conjunto de teste, $\mathbf{X} \in \mathbb{R}^m$, é projetado dentro do espaço de pontos de menor dimensão, $t_i = \mathbf{X}^T \mathbf{P}_i$, em que \mathbf{P}_i é o i -ésimo vetor característico, obtém-se o i -ésimo componente principal de \mathbf{X} , t_i .




Figura 2.11: Espaço de menor dimensão (ALKAYA; EKER, 2011).

O fato de que a análise baseia-se em um número reduzido de componentes do modelo, denominados de componentes principais, o monitoramento de processos pode ser realizado através da utilização de técnicas de estatísticas multivariáveis tais como T^2 de Hotelling e Q .

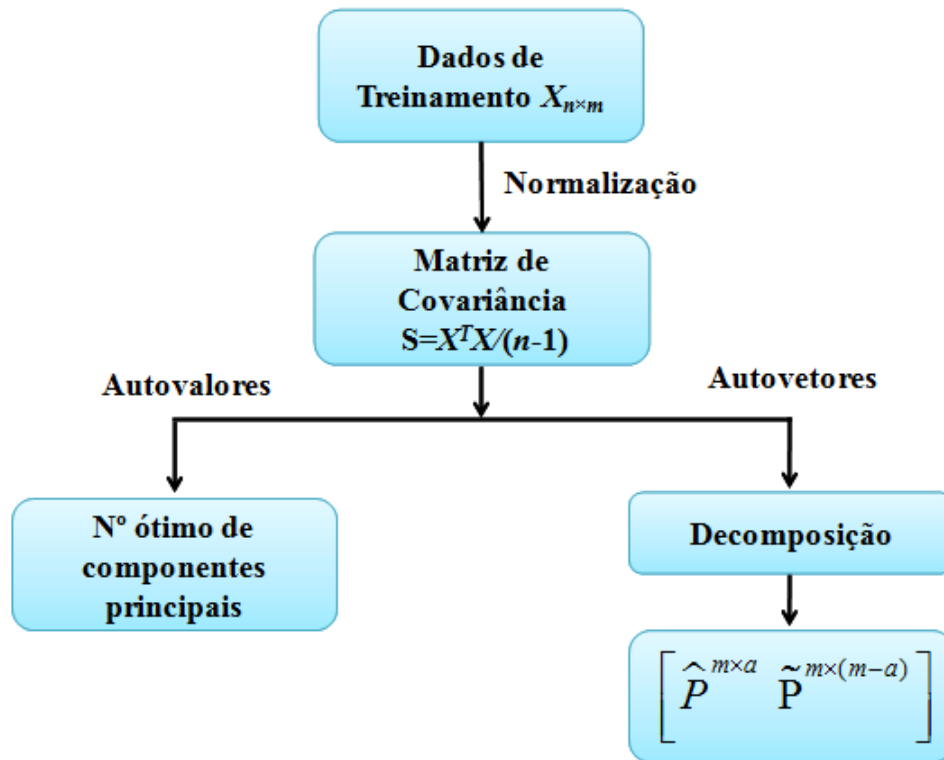


Figura 2.12: Modelagem da PCA (ALKAYA; EKER, 2011).

2.4.2 Técnicas para redução de ordem

Na literatura existem diversas técnicas para a obtenção do número de componentes principais a (REIS, 2008). Estas técnicas tem como essência desacoplar as variações de estado das variações aleatórias, para isto, determinando um número apropriado de valores característicos que devem ser mantidos no modelo PCA.

Com a obtenção de um modelo PCA, é possível obter duas partes: a correspondente aos maiores valores característicos que descreve a maior parte das variações sistemáticas ou de estado de um processo, e aos menores valores característicos que descreve o ruído aleatório.

Alguns métodos para a obtenção do número do componente principal são:

- o procedimento *Scree* (JACKSON, 1991): Trata-se de um método gráfico construído através dos autovalores em ordem decrescente. O cálculo de a se dá através do número mínimo de componentes principais que captura uma maior variabilidade do processo. A Figura 2.13, mostra um exemplo que o valor de a seria 7, ou seja, para o modelo PCA seria utilizado 7 componentes principais;
- procedimento da variância percentual cumulativa - CPV (ZUMOFFEN; BASUALDO, 2007): É a medida da variância percentual ($CPV(a) \geq 90\%$), capturado




Figura 2.13: Procedimento *Scree* para cálculo de a .

pelos a componentes principais adotados:

$$CPV(a) = \frac{\sum_{i=1}^a \lambda_i}{\text{traço}(S)} 100 \quad (2.98)$$

- procedimento da soma dos quadrados da predição residual, estatística PRESS (*Prediction Residual Sum of Squares*);
- procedimento da validação cruzada;
- procedimento da análise paralela: Possui o maior desempenho ao comparar com outras técnicas e é a mais utilizada (KU et al., 1995). Trata-se de um método que utiliza a comparação do perfil de variância dos dados reais, com um conjunto de dados gerados e normalmente distribuídos. O número de componentes principais a é obtido através do ponto em que os dois perfis se cruzam. Reis (2008) aplicou um algoritmo para o cálculo de a que compreende as seguintes etapas:
 1. gerar um conjunto de dados normalmente distribuídos com média zero e variância unitária com a mesma dimensão do conjunto de dados reais (m variáveis e n observações);
 2. realizar uma PCA sobre os dados;
 3. obter os valores característicos classificados em ordem decrescente;

4. plotar os valores característicos dos dados originais juntamente com os dados normalmente distribuídos;
5. obter a através do cruzamento entre os perfis.

Como mencionado anteriormente, o procedimento da Análise Paralela é uma das técnicas mais utilizadas e possui um maior desempenho ao comparar com outras técnicas, desta forma, esta técnica foi utilizada para a obtenção do número de componentes principais a neste trabalho. Na Seção 3.5.1 será apresentada a utilização da estatística como proposta deste trabalho para a realização da detecção de falhas em processos industriais, combinando com a técnica PCA.

CAPÍTULO 3

Monitoramento de sistemas de controle na indústria química



este capítulo será apresentada a proposta deste trabalho, que se trata de uma sistemática para a realização do monitoramento de sistemas de controle na indústria química.

3.1 Metodologia para o monitoramento

Como mencionado na Seção 1.3, o objetivo deste trabalho, é apresentar a proposta de uma sistemática para a aplicação das técnicas CPM/CPA, no monitoramento de sistemas de controle na indústria química, através de métodos para o cálculo do índice de desempenho, identificação e localização de oscilações, detecção do emperamento de válvulas, bem como falhas em sensores e presença de perturbações.

A estrutura proposta neste trabalho, para o monitoramento, pode ser observado na Figura 3.1.

A ideia é a aplicação das técnicas CPM/CPA através de um Gerenciador de desempenho que contenha em seu banco de dados as técnicas mais simples e seguras

encontradas na literatura para a realização do monitoramento contínuo de sistemas controlados na indústria química.

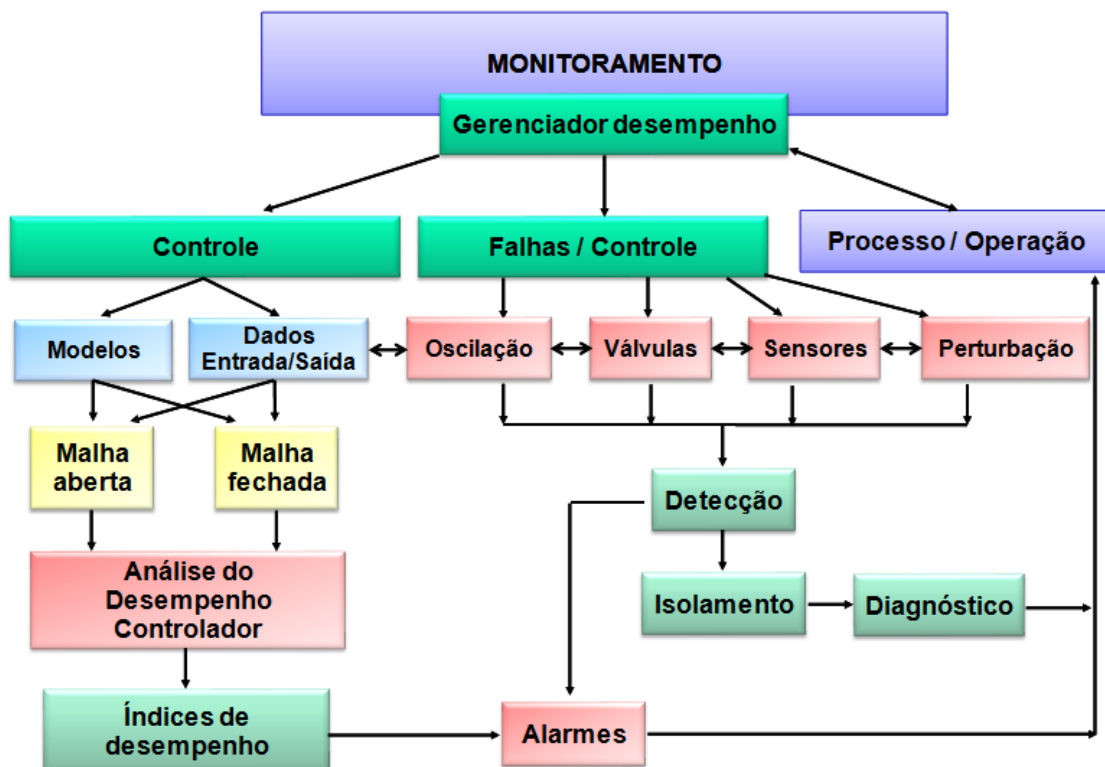


Figura 3.1: Gerenciador de desempenho.

Observando a Figura 3.1, a sistemática proposta contempla as seguintes características:

- cálculo do índice de desempenho através de modelos matemáticos de processos ou de dados históricos do mesmo, tanto em malha aberta quanto em malha fechada, para a verificação da degradação na estrutura de controle corrente, através da fatoração de modelos lineares. O modelo da referência é projetado contendo as informações do processo na ausência dos invariantes (atrasos, zeros e pólos instáveis, etc) (SOUZA; OLIVEIRA-LOPES, 2008; SOUZA; OLIVEIRA-LOPES, 2009; SOUZA; OLIVEIRA-LOPES, 2011). A técnica proposta será discutida com mais detalhe na próxima seção;
- detecção e localização de oscilações em malhas de controle, utilizando dados históricos ou correntes do processo analisado, através da análise Karhunen-Loève e periodograma. A escolha do método é justificada por apresentar implementação simples e capaz de detectar oscilações complexas. Na Seção 3.3.1 serão apresentados os detalhes do método, bem como uma proposta de modificação no método para a localização das oscilações, com o objetivo de torná-la

automática, sem a necessidade do conhecimento específico de planta (SOUZA; OLIVEIRA-LOPES, 2010);

- detecção do emperramento de válvulas através de dados históricos ou correntes do processo analisado, utilizando o método qualitativo de Yamashita, que através de estudos realizados (JELALI; HUANG, 2010), se trata do método mais seguro e também é de fácil implementação. Na Seção 3.4 o método será apresentado com mais detalhe (SOUZA; OLIVEIRA-LOPES, 2011a);
- detecção de falhas e presença de perturbações, utilizando dados históricos, técnica PCA e estatística multivariável para a avaliação *online* do processo analisado.

Nas próximas seções, serão apresentados com detalhes os métodos propostos para compor o Gerenciador de desempenho.

3.2 Cálculo do índice de desempenho

A proposta para o cálculo do índice de desempenho pode ser entendida analisando o diagrama de blocos da Figura (3.2), com G , K e N as matrizes de funções de transferência da planta, do controlador e da perturbação, respectivamente.:




Figura 3.2: Diagrama de blocos - malha *feedback*.

A representação da malha fechada é dada por:

$$y = (I + GK)^{-1}GKy_{sp} + (I + GK)^{-1}Na_t \quad (3.1)$$

Para processos em malha aberta, o modelo da planta a ser utilizado como referência é obtido diretamente através da fatoração do modelo G pela matriz de interação generalizada (ξ , Seção 3.2.2). Nos processos em malha fechada, admite-se que se conheça (por técnicas de identificação, por exemplo) o modelo da planta

e do controlador corrente, então, pode-se identificar o modelo N da perturbação, através de dados de malha fechada e considerando que toda perturbação é dada pela dinâmica de N , chega-se a:

$$y_N = y - y_p \quad (3.2)$$

com y_N o resíduo na saída do sistema, y a saída do sistema de controle com os efeitos de perturbação e y_p a saída do sistema de controle na ausência da perturbação.

Com y_N e a_t pode-se, então, identificar a matriz de funções de transferência da perturbação através de alguma técnica de identificação, que neste trabalho, foi utilizada a de Espaço de Estados.

Como mencionado anteriormente, o objetivo é trabalhar com dados de operações, que para esta caso, não conhecemos a matriz de funções de transferência da perturbação $N(z)$ da Figura (3.2), ou seja, se conhecermos $N(z)$ teríamos então os dados de operação da planta em malha fechada.

Com a estrutura em malha fechada, acrescenta-se um ruído aleatório ao sinal de saída, e admite-se que toda e qualquer interferência na leitura do sinal será dado pela dinâmica de N . Com a Equação (3.2), obtém-se o sinal y_N , e admitindo a_t sendo um ruído branco, pode-se realizar a identificação de N .

Na próxima seção, será apresentado a metodologia para a obtenção do modelo de referência através da fatoração de modelos lineares utilizando matrizes de interação generalizadas.

3.2.1 Fatoração de modelos para o cálculo do índice de desempenho

O sistema a ser avaliado pode está sujeito a limitações, dificultando o alcance dos objetivos de desempenho pré-estabelecidos, desta forma projetar o controle adequado a um determinado sistema pode ser uma tarefa dispendiosa.

O projeto de sistemas de controle deve, portanto, incorporar os conceitos de *estabilidade robusta* e *desempenho robusto*, ou seja, o projeto deve ser realizado de tal forma a se manter a estabilidade e os objetivos de desempenho.

De acordo com Maruyama (2007), os objetivos de desempenho são representados através de suas características no domínio do tempo, tais como:

- erro estático (e_{ss}): $e_{ss} = \lim_{t \rightarrow \infty} e(t)$ para uma entrada padronizada;
- tempo de subida (t_r): tempo que a saída do sistema $y(t)$ demora entre 0 e 100% do valor final, $y(\infty)$;
- tempo de assentamento (t_s): O tempo de assentamento t_s é definido como o instante de tempo tal que o sinal de erro $e(t)$ passa a ser menor que um determinado valor percentual, em geral, definido como 2% ou 5%;
- máximo sobressinal (M_p): O máximo sobressinal (*overshoot* ou sobrelevação) é o maior erro percentual em relação ao valor final $y(\infty)$. O maior valor de $y(t)$ é denominado $y(t_p)$ onde t_p é o instante de ocorrência do valor de pico. O máximo sobressinal é definido da seguinte forma:

$$M_p = \frac{y(t_p) - y(\infty)}{y(\infty)} \times 100\%$$

Em princípio, pode-se imaginar que seria possível, através da introdução de um controlador *feedback*, alterar os pólos e zeros representativos do comportamento de uma planta, para qualquer valor desejável. Entretanto, várias limitações teóricas e físicas não permitem tal flexibilidade.

A utilização de estruturas de controle com complexidade polinomial pré-definida pode ser uma restrição para se atingir os objetivos de desempenho, a não linearidade em atuadores (por exemplo: válvulas pneumáticas, válvulas hidráulicas, amplificadores, motores elétricos etc.) que possuem sempre algum comportamento não linear (principalmente saturação e histerese) merecem destaque. Outro fator importante é a presença de perturbações na entrada da planta que usualmente são devido a atrito e folgas. Tais distúrbios podem ser representados como sinais de entrada no sistema que afetam diretamente a planta a ser controlada.

As limitações físicas são fatores que podem ser solucionados, modificando a estrutura do processo onde se deseja implementar a malha de controle, já as limitações teóricas tais como: erro no modelo, presença de tempo morto (atraso na resposta), pólos e zeros fora do ciclo unitário, pólos e zeros com localizações próximas (pois o cancelamento de zeros com pólos instáveis leva a sistemas com comportamentos não-observáveis e internamente instáveis etc). Assim, cabe ao projetista utilizar técnicas e artifícios que consigam resolver ou amenizar tais problemas. Desta forma, a utilização da fatoração de modelos lineares para a obtenção da referência, é um método alternativo, à utilização do MVC, que possui vários pontos negativos, tais como:

- não considera características de zeros que levam a um comportamento de fase não mínima e resposta inversa;
- não compensa outras características limitantes, como restrições em variáveis manipuladas;
- não considera nenhuma limitação no atuador de controle, como abertura e velocidade máxima de abertura de válvulas de controle;
- não é robusto etc.

Frente a esses pontos negativos, e com o interesse em amenizar as limitações de controle para o projeto da referência, a técnica GIM visa fatorar o modelo da planta em duas partes: uma não inversível, e que contenha os invariantes do sistema, e outra de interesse que será totalmente inversível e que esteja livre dos invariantes.

Desta forma, a técnica de seleção da referência para o monitoramento se dá pela utilização de técnicas de fatoração com o objetivo de se extrair invariantes do modelo do sistema, e tornando a representação virtual do processo mais facilmente controlável visto que o modelo fatorado apresenta as informações do modelo original livre dos invariantes.

De fato, cada técnica de fatoração transfere características intrínsecas para o modelo fatorado. Nas próximas seções apresentam-se técnicas de fatoração que serão utilizadas para seleção do sistema de referência.

A seleção da estratégia para avaliação do comportamento de referência segue a ideia desenvolvida em Oliveira-Lopes (2000) para projetar um Controlador Preditivo baseado em Modelos de Referências (RS-MPC, *Reference System Model Predictive Control*), no qual, o modelo de referência é projetado para incorporar informações das limitações de desempenho, tais como a ordem relativa de cada saída. Assim, o modelo de referência é apenas um modelo que especifica o desempenho para o sistema de controle.

Da mesma forma, pode-se utilizar esse procedimento para se avaliar o melhor desempenho possível de um controlador *feedback* através da seleção do comportamento de referência. Para um controlador *feedback* genérico projetado de forma a que a malha fechada seja estável, tem-se que os efeitos dos invariantes da malha fechada consistem em uma medida significativa do que pode ou não ser desempenhado pelo controlador.

Para sistemas MIMO, perturbações, zeros da planta, e pólos fora do círculo unitário possuem direções associadas com eles. Assim, o controle perfeito, resul-

tante da inversão da planta, é em geral, não viável, e consequentemente o melhor controle possível é resultante das limitações inerentes de desempenho, tais como: comportamento de fase não mínima, restrições, perturbações, e incertezas no modelo. Fora da situação nominal, o controle necessita ser sintonizado para melhor comportamento na região de altas frequências. Assim, embora exista o invariante relativo aos zeros numa estrutura *feedback*, mesmo com a direção de resposta fixada, pode-se ainda mover os efeitos de um zero para uma dada saída (que seja de menor importância se controlar com elevado desempenho).

Considere o modelo de ordem mínima de uma planta estável, e suponha que o mesmo possa ser fatorado em duas partes. O comportamento de referência será definido levando-se em consideração a malha fechada em condição nominal. Se a representação do modelo do processo é dada por $\Sigma = \Sigma_c \Sigma_M$. O comportamento de referência para monitoramento será formulado usando-se o modelo estável e de fase mínima, expresso por $\Sigma_M(\mathbf{x}_M, \mathbf{u}) : (\mathbf{A}_M, \mathbf{B}_M, \mathbf{C}_M, \mathbf{D}_M)$, chamado neste trabalho de parte inversível do processo. Devido ao fato de que controladores baseado em modelo podem apresentar problemas de robustez, a seleção do modelo para o comportamento de referência irá adotar a sintonia do controlador de forma a se ter uma condição estável. Supondo que um sistema estável em malha fechada com zeros fora do círculo unitário da função de transferência da malha, $L(z) = G(z)K(z)$, dado por σ_i , com $L(1) \neq 0$ e ordem relativa β , então a integral de Bode para T é dada por (OLIVEIRA-LOPES, 2000):

$$\int_0^\pi \log \left| \frac{T(e^{j\theta})}{T(1)} \right| \frac{d\theta}{1 - \cos\theta} = \frac{\pi}{T(1)} \lim_{z \rightarrow 1} \frac{dT(z)}{dz} + \pi \sum_{i=1}^{n_\sigma} \frac{|\sigma_i|^2 - 1}{|\sigma_i - 1|^2} + \pi\beta \quad (3.3)$$

Enquanto o primeiro termo do lado direito da Equação (3.3) relaciona-se como as propriedades do estado estacionário, o segundo e terceiros termos são dados pelas contribuições dos zeros fora do círculo unitário e ordem relativa de $L(z)$, respectivamente.

3.2.2 Matriz de interação generalizada (GIM)

Na literatura, existem diferentes alternativas de fatoração para os sistemas lineares e invariantes no tempo (LTI) discretos. A técnica mais básica para esta análise é provavelmente a que utiliza métodos desenvolvidos na literatura para sistemas contínuos, com adaptações. Nesta abordagem, pela aplicação da transformação bilinear do domínio discreto (z) para o domínio contínuo (w), utiliza-se diretamente o resultado para sistemas contínuos. O mapeamento inverso completa o processo

(OLIVEIRA-LOPES, 2000).

Para sistemas SISO esta análise é bastante direta. O modo mais simples de se fatorar um modelo do processo Σ , dá-se da seguinte forma:

$$\Sigma_C = \prod_{j=1}^{N_S} \frac{(1 - (\sigma_j)^{-1})(z - \sigma_j)}{(z - (\sigma_j)^{-1})(1 - \sigma_j)} \quad (3.4)$$

com N_S o número de zeros finitos fora do ciclo unitário, e σ_j o zero finito j fora do ciclo unitário.

Desta forma, obtém Σ_M de acordo com $\Sigma = \Sigma_C \Sigma_M$. Esta fatoração é conhecida como INNER-OUTER.

Outra forma simples de se fatorar um sistema é utilizar o mapeamento do sistema discreto no domínio w , de acordo com $z = (1 + wT_s/2)/(1 - wT_s/2)$, com T_s o tempo de amostragem, e logo em seguida retorna-se ao domínio discreto, na qual este mapeamento é representado da seguinte forma:

$$G(z) = C[zI - A]^{-1}B + D$$

com $z = (1 + wT_s/2)/(1 - wT_s/2)$, e na ausência de pólos em $z = -1$,

$$G(w) = \begin{bmatrix} \frac{2}{T_s}(A - I)(A + I)^{-1} & \frac{2}{\sqrt{T_s}}(A + I)^{-1}B \\ \frac{2}{\sqrt{T_s}}C(A + I)^{-1} & D - C(A + I)^{-1}B \end{bmatrix}$$

Esta fatoração é apresentada em Chu (1988) e Morari e Zafiriou (1989). Neste caso, o deslocamento dos zeros é dado a partir da fatoração conhecida como *Blaschke factorization* (ZHANG; FREUDENBERG, 1993) conforme:

$$\begin{aligned} G(z) &= G_C^{(1)}(z)G_M^{(1)}(z), \\ G_M^{(1)}(z) &= G_C^{(2)}(z)G_M^{(2)}(z) \\ &\dots \\ G_M^{(N_S-1)}(z) &= G_C^{(N_S)}(z)G_M^{(N_S)}(z) \end{aligned}$$

e

$$G_C^{(i)} = I - \left(\frac{\alpha_i \bar{\alpha}_i - 1}{\alpha_i + 1} \right) \left(\frac{z + 1}{\bar{\alpha}_i z + 1} \right) \bar{\omega}_i \omega_i^T$$

$$C_M^{(i)} = C_M^{(i-1)} - \left(\frac{\alpha_i \bar{\alpha}_i - 1}{\alpha_i + 1} \right) \bar{\omega}_i v_i^T (A + I)$$

com v_i a direção do zero e ω_i a direção de saída do zero (α_i).

Outras possibilidades de implementação da fatoração são apresentadas na literatura tais como Varga (1998), Tsiligiannis e Svoronos (1989), Tsiligiannis e Svoronos (1988) e Chu (1988). O objetivo em cada caso é o de expressar um modelo linear Σ , como fatores conforme $\Sigma = \Sigma_C \Sigma_M$. Assim, de forma resumida, a essência das técnicas de fatoração pode ser representada para o um sistema LTI dado por (OLIVEIRA-LOPES, 2000):

1. determinação de uma inversa generalizada-(1,2) Σ^+ de Σ tal que os pólos instáveis de Σ^+ sejam exatamente os zeros instáveis de Σ ;
2. computação da fatoração co-prima à direita com denominador interno de Σ^+ como, $\Sigma^+ = N \Sigma_C^{-1}$, com N e Σ_C estáveis, e Σ_C *inner* e de ordem mínima;
3. cálculo de $\Sigma_M = \Sigma_C^{-1} \Sigma$.

Uma forma de fatoração com características muito interessantes é aquela da fatoração que introduz o conceito de matriz de interação. Ela pode ser apresentada para sistemas discretos no tempo conforme a definição 1:

Definição 1: Para qualquer matriz de transferência quadrada $G(z)$ de dimensão $m \times m$, existe uma única matriz polinomial $\xi_G(z)$, chamada de matriz de interação, que é da forma:

$$\xi_G(z) = H_G(z) \text{diag}(z^{k_1}, z^{k_2}, \dots, z^{k_m})$$

com

$$H_G(z) = \begin{bmatrix} 1 & 0 & \cdots & 0 \\ h_{21}(z) & 1 & \cdots & \\ \vdots & \vdots & & \vdots \\ h_{m1}(z) & h_{m2}(z) & \cdots & 1 \end{bmatrix} \quad (3.5)$$

e $h_{ij}(z)$ divisível por z (ou zero), tal que:

1. $\lim_{z \rightarrow \infty} \xi_G(z)G(z) = K_G$ com K_G não singular;
2. $G(z)^{-1}\xi_G(z)^{-1}$, um sistema próprio;
3. se $G_1(z)$, $G_2(z)$ são matrizes de transferência cheias e próprias, então existe uma matriz própria $G(z)$ tal que $G_1(z)G(z) = G_2(z)$ se e somente se $\xi_{G_1}(z)\xi_{G_2}(z)^{-1}$ é própria.

A matriz de interação de Wolowich-Falb (WF) extrai os elementos não inversíveis de um sistema se eles são originados apenas de atrasos, isto é, zeros no infinito. Os zeros que resultam em comportamento de fase não mínima (NMP) finitos continuam presentes, necessitando-se assim de uma técnica para a sua extração. Pode-se fazer a extração do zero finito fora do círculo unitário através da fatoração generalizada, utilizando-se mapeamentos que levem os zeros NMP finitos para o infinito. Aqui se discute a fatoração w , onde w representa as duas interações generalizadas básicas (interação p e interação r) introduzidas por Tsiligiannis e Svoronos (1989) e que pode ser observado no Apêndice B. A interação generalizada utiliza a transformação para mudar cada zero finito (fora do círculo unitário) e então usa a interação p , $z = \frac{1+\sigma p}{p+\sigma}$ e a interação r , $z = \frac{\sigma r}{r+\sigma-1}$, representando mínimo resíduo e mínimo tempo, respectivamente. Note que para zeros no infinito (atrasos puros), as duas transformações se degeneram para uma simples identidade, $p = r = z$.

É possível provar (TSILIGIANNIS; SVORONOS, 1989) que para um sistema quadrado, próprio, não singular e estável, sem cancelamento de pólos e zeros, existe uma única matriz triangular inferior, chamada matriz de interação- w - σ_i que extrai o elemento σ_i de Σ , e ela é dada por:

$$\xi_\sigma^w = \Gamma_\sigma(w) \text{diag} [w^{k_{1\sigma}}, \dots, w^{k_{n\sigma}}] \quad (3.6)$$

em que n é a dimensão do sistema, $k_{i\sigma} \geq 0$, e,

$$\Gamma_\sigma(w) = \begin{bmatrix} 1 & 0 & 0 & \cdots & 0 \\ \gamma_{21}(w) & 1 & 0 & \cdots & 0 \\ \gamma_{31}(w) & \gamma_{32}(w) & 1 & 0 & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \gamma_{n1}(w) & \gamma_{n2}(w) & \gamma_{n3}(w) & \cdots & 1 \end{bmatrix} \quad (3.7)$$

com $\gamma_{ij}(w)$ polinômios em w , divisível por w ou zero.

Então a matriz de interação generalizada w é dada por:

$$\xi^w(z) = \xi_M^w(z)\xi_{M-1}^w(z)\dots\xi_2^w(z)\xi_1^w(z) \quad (3.8)$$

$\xi_i^w(z)$ é a matriz de interação- σ_i - w de K_{i-1}^w , $K_0^w = G(z)$, e $K_i^w = \xi_i^w(z)K_{i-1}^w$. A multiplicação à esquerda de Σ , transfere a matriz $\xi^w(z)$ para extrair as partes de Σ . Portanto, a fatoração de interesse pode ser representada como $\Sigma = \xi^w(z)^{-1}K$. Para a proposta a ser estudada, uma normalização de interação de matriz é usada, então, $\Sigma_C = \xi^w(z)^{-1}\xi^w(z)$ e Σ_M é tal que pode ser descrito conforme $\Sigma_M = \Sigma_C^{-1}\Sigma$.

A matriz de interação descreve, então, características de invariantes de um sistema, tais como aquelas expressas pela matriz de atrasos de um sistema. Pode-se conhecer o comportamento possível para um sistema através da utilização do conceito apresentado na seção anterior. Assim, pode-se fatorar um modelo de processo em duas partes: $\Sigma_M = \Sigma_C^{-1}\Sigma$, sendo que o fator Σ_C representa a parte não inversível do modelo, e Σ_M a parte que pode ser exatamente invertida numa estrutura de controle *feedback*. Neste trabalho, propõe-se que a parte Σ_M seja utilizada como modelo de referência para o monitoramento de sistemas de controle.

A mais rápida resposta para o sistema de controle *feedback* é dada por Σ_C . Assim, com o seu conhecimento pode-se escolher a resposta desejada para o processo e com ela avaliar o desempenho de controladores baseados nessa resposta. De forma análoga, o modelo definido por Σ_M representa características do modelo da planta, mas com a possibilidade de inversão perfeita sem problemas associados à perda de estabilidade interna da malha de controle.

Desta forma, é que, frente às limitações dos sistemas a serem controlados, a referência pode ser projetada com a fatoração do modelo da planta, usando outras configurações de controladores (PID, MPC etc.), e com a ferramenta necessária para a fatoração de modelos lineares, por exemplo através de matrizes de interação generalizadas, em duas partes: a parte não inversível e a parte totalmente inversível (Figura (3.3)), pois:

$$G = \Sigma_C \Sigma_M \quad (3.9)$$

com $\Sigma_C = \xi_G^w(z)^{-1}$ representando a parte não inversível e $\Sigma_M = \xi_G^w(z)G(z)$ representando a parte totalmente inversível e livre dos invariantes do sistema, onde $\xi_G^w(z)$ pode ser, por exemplo, a matriz de interação generalizada em w , que representa as transformações em p ou r .

De acordo com este cenário, novos índices de desempenho, utilizando o sistema livre dos invariantes podem ser descritos como:

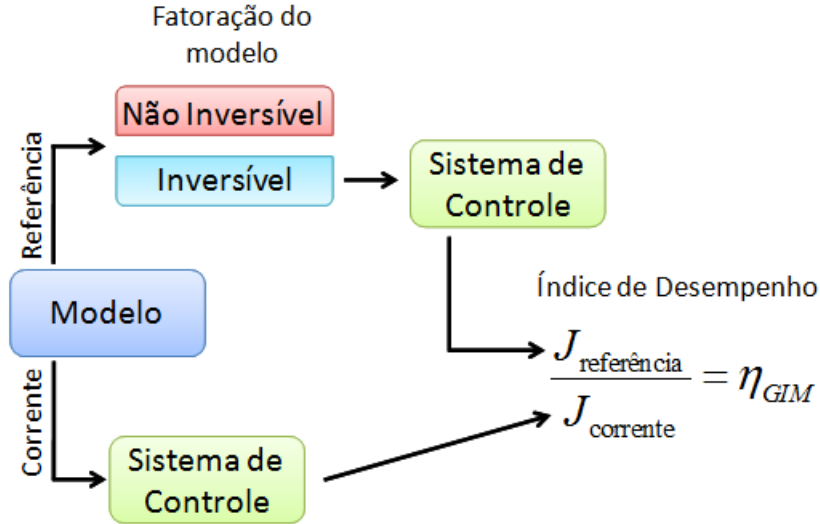


Figura 3.3: Projeto do sistema de referência.

1. índice de desempenho com modelo de referência aplicado ao modelo fatorado e o sistema de controle atual aplicado ao sistema original:

$$\eta = \frac{\text{Medida do Desempenho do Sistema sem Invariantes}}{\text{Medida do Desempenho do Sistema Original}}$$

2. índice de desempenho que mede o envelhecimento do sistema de controle.

$$\eta = \frac{\text{Medida do Desempenho do Sistema Mantido com Referência Inicial}}{\text{Medida do Desempenho do Sistema Atual}}$$

No caso de se utilizar a fatoração de modelos através da matriz de interação, tem-se:

$$\eta_{GIM} = \frac{\left(\lambda \sigma_{\sum M(p)}^2 + (1 - \lambda) \sigma_{\sum M(r)}^2 \right)_{\text{referência}}}{(\sigma_k^2)_{\text{corrente}}} \quad (3.10)$$

com $0 \leq \lambda \leq 1$ um parâmetro de ponderação, $\sigma_{\sum M(p)}^2$ é a variância do sinal de saída do sistema de controle com fatoração p do modelo, $\sigma_{\sum M(r)}^2$ é a variância do sinal de saída do sistema de controle com fatoração r do modelo e σ_k^2 é a variância do sinal de saída do controlador corrente que será analisado.

Sendo assim, de acordo com a Equação (3.10), a referência poderá ser representada então por um controlador P, PI, PID e MPC, ou outra estratégia de controlador. De uma maneira mais simples, a Figura (3.3) mostra como se projeta a referência proposta, na qual se utiliza o mesmo modelo da planta submetida ao controle corrente para realizar a fatoração, e então se projeta o controlador para o modelo sem os invariantes, utilizando-se então este sistema como referência.

Com o objetivo de demonstrar a degradação do sistema de controle corrente, foi utilizado neste trabalho o cálculo do índice de desempenho com base nos trabalhos de McNabb e Qin (2003), Bezergianni e Georgakis (2000), Xia et al. (2006), Souza e Oliveira-Lopes (2008), Souza e Oliveira-Lopes (2009) e Souza e Oliveira-Lopes (2011).

3.3 Detecção de oscilações

3.3.1 Análise Karhunen-Loève e Periodograma

A proposta neste trabalho é realizar a detecção e a localização de oscilações presentes em processos de grandes dimensões, conhecendo os sinais de saída de diferentes locais da planta. Para cumprir esse objetivo, sugere-se a utilização de periodogramas e uma base de Karhunen-Loève.

O método introduzido nesta seção supõe que não exista tempo morto no processo. A metodologia proposta permite o tratamento de sistemas com perturbações e considera medidas com ruídos.

Considere que os sinais de um sistema sejam descritos pela adição de efeitos, similar ao descrito por Odgaard e Wickerhauser (2007) e representada por:

$$y[n] = \sum_{0 < i < m} y_{0,i}[n] + n_m[n] \quad (3.11)$$

com $y[n] \in \mathbb{R}^k$ o vetor de sinal analisado e discreto no tempo, k é o número de amostragens e medidas analisadas, $y_{0,i}[n]$ é o i -ésimo vetor componente do sinal oscilatório e $n_m[n]$ é o vetor de sinal restante composto por perturbações e ruídos, supostos independentes, com distribuição normal, média zero e variância d .

Os sinais foram analisados através de bloco de dados com tempo de amostragem n . O tamanho do bloco de dados é denotado como M , e o bloco $\mathbf{Y}[\mathbf{n}]$:

$$Y[n] = \begin{bmatrix} y_1[n - M + 1] & y_1[n - M + 2] & \cdots & y_1[n] \\ y_2[n - M + 1] & y_2[n - M + 2] & \cdots & y_2[n] \\ \vdots & \vdots & \vdots & \vdots \\ y_k[n - M + 1] & y_k[n - M + 2] & \cdots & y_k[n] \end{bmatrix} \quad (3.12)$$

com toda a medida de k armazenada para as últimas amostras de M . A primeira

linha contém as M mais recentes amostras da primeira variável medida, e assim sucessivamente para as outras linhas.

A análise Karhunen-Loève consiste em estabelecer uma base relacionando os autovalores dos dados de entrada, ou seja, para a matriz \mathbf{Y} de k vetores em linha para \mathbb{R}^m , com $k > m$, a base que minimiza o erro de aproximação linear desses vetores. Outra vantagem da base de Karhunen-Loève é que aproxima as estruturas gerais de todos os sinais em \mathbf{Y} utilizando alguns vetores da base (ODGAARD; WICKERHAUSER, 2007).

A base de Karhunen-Loève pode ser calculada através da matriz \mathbf{Y} , na qual todas as linhas devem ter média igual à zero, sendo esta, uma característica necessária para a realização da análise. O monitoramento durante transições operacionais necessita de adaptações, pois a técnica apresentada na forma atual não se aplica.

A base de Karhunen-Loève pode ser definida como:

$$\kappa = \{v_1, \dots, v_m\} \quad (3.13)$$

com κ uma base ortogonal dos autovetores da matriz $\mathbf{Y}\mathbf{Y}^T$, ordenado de tal forma que v_n seja associado com os autovalores λ_n , e $\lambda_i \geq \lambda_j$ para $i > j$. Desta forma, a base formada pelos vetores pode ser descrita pela matriz:

$$K_L = \{v_1, \dots, v_m\} \quad (3.14)$$

Sendo assim, como a base de Karhunen-Loève são os autovetores da autocorrelação de \mathbf{Y} . Os autovalores correspondem à variância dos vetores que formam a base de Karhunen-Loève.

Para aplicar a técnica proposta, deve-se assegurar que os vetores das medidas sejam normalizados pelo máximo valor de cada medida, e os mesmos possuam média igual a zero.

A detecção da oscilação pela análise de Karhunen-Loève é baseada na matriz $\mathbf{Y}[\mathbf{n}]$ e nas M mais recentes amostras de cada variável medida, ou seja, M pode ser considerada uma janela de observação, sendo esta, especificada pelo projetista.

Para se ter uma ideia de M , trata-se de um número inteiro e que geralmente pode assumir em média, 35 a 50% do número de variáveis medidas, por exemplo, para uma análise com 30 variáveis medidas, M pode assumir o valor entre 11 a 15. Esses valores são aconselhados devido ao fato de estar relacionado diretamente com a variância

dos autovalores $\lambda[n]$ que é comparada com um parâmetro de referência, que pode ser obtido, por exemplo, pela análise 6σ da variância de $\lambda[n]$, sendo consideradas oscilações quando os valores de $\lambda[n]$ forem maiores que o valor de referência Ω , como descrito:

$$O_d = \begin{cases} 1 & \text{se } \text{var}(\lambda[n]) \geq \Omega \\ 0 & \text{se } \text{var}(\lambda[n]) < \Omega \end{cases} \quad (3.15)$$

Ou seja, quando O_d for igual a 1, o sinal analisado é oscilatório, e quando O_d for igual a zero, o sinal analisado não é oscilatório.

Para a determinação do número de oscilações em $\mathbf{Y}[\mathbf{n}]$, basta realizar a comparação dos autovalores $\lambda[n]$, agora com outro valor de referência, que também pode ser obtido, pela análise 6σ de $\lambda[n]$, e não da variância de $\lambda[n]$. O algoritmo para o cálculo do número de oscilações é similar ao proposto por Odgaard e Wickerhauser (2007) e dado por:

$j = 0$;

$N_0 = 0$;

Enquanto $\lambda_{m-j}[n] \geq \alpha$ **faça**:

$j = j + 1$;

$N_0 = N_0 + 1$;

Fim

Para este algoritmo, j é um contador, N_0 é o número de oscilações, $\lambda_m[n]$ o n -ésimo elemento de $\lambda[n]$ e α o valor de referência.

Odgaard e Wickerhauser (2007) propuseram uma maneira de localizar as oscilações, porém, com a necessidade do conhecimento específico da planta. Neste trabalho, a proposta é fazer uma análise estatística da variabilidade dos sinais, comparando-se a média da variância de cada variável medida, com o ponto médio entre a máxima e a mínima variância de cada variável medida, de acordo com:

$$\overline{OS_M} = \frac{\max(\bar{y}_{\text{var}}) - \min(\bar{y}_{\text{var}})}{2} \quad (3.16)$$

com \bar{y}_{var} a média da variância das medidas de $\mathbf{Y}[\mathbf{n}]$ de acordo com a janela M na presença de ruído branco.

Desta forma, ao se comparar as médias das variâncias de cada variável medida,

com o ponto médio entre a máxima média das variâncias e a mínima média das variâncias, tem se:

$$OS = \begin{cases} \text{Sinal oscilatório se } \bar{y}_{i,\text{var}} > \overline{OS_M} + \delta \\ \text{Sinal não oscilatório se } \bar{y}_{i,\text{var}} < \overline{OS_M} + \delta \end{cases} \quad (3.17)$$

com i representando o número de variáveis medidas, ou seja, $i = 1, 2, 3, \dots, k$, e δ o valor acrescentado ao índice $\overline{OS_M}$ como margem de segurança para falsos alarmes.

A utilização da análise por periodograma justifica-se para obter a densidade espectral de potência dos sinais, que indica os pontos de frequências que constituem o sinal avaliado.

O método da análise Karhunen-Loève, não se aplica para a detecção de oscilações em processos com transições operacionais. Para estes casos, outras técnicas devem ser aplicadas, que não é o objetivo deste trabalho.

3.4 Detecção do emperramento de válvulas

Como já apresentado anteriormente, o método de Yamashita, necessita da informação da posição da válvula, porém esta informação normalmente não é medida na realidade, mas a razão de fluxo correspondente pode ser usada como uma alternativa, visto que a razão de fluxo é praticamente proporcional à posição da válvula (YAMASHITA, 2006).

A detecção do emperramento de válvulas utilizando o método de Yamashita tem como objetivo qualitativo, encontrar os padrões típicos da válvula utilizando o sinal de saída do controlador e a razão de fluxo da válvula. A Figura 3.4, mostra esquematicamente as características típicas de uma válvula com emperramento.




Figura 3.4: Características de uma válvula emperrada. (a)-Deadband, (b)-Slip Jump, (c)-Combinação de (a) e (b) (YAMASHITA, 2006).

A movimentação da válvula pode ser representada simbolicamente de três maneiras:

- (I) Aumentando
- (S) Estacionário
- (D) Diminuindo

A Figura 3.6 mostra esquematicamente a representação simbólica da movimentação da válvula.




Figura 3.5: Representação simbólica da movimentação da válvula (YAMASHITA, 2006).

Para realizar a análise destes sinais, utiliza-se a combinação de duas variáveis simbólicas simultaneamente. Yamashita (2006) propôs que uma sucessão destes símbolos representa um movimento padrão da válvula. Um fragmento da sucessão deste movimento pode ser representado por uma sucessão de dois padrões, como por exemplo, se um padrão IS precede o padrão II, então o movimento pode ser representado por (IS, II).

A Figura 3.6 mostra os possíveis movimentos, de acordo com a técnica proposta por Yamashita (2006):




Figura 3.6: Padrões de movimento para válvula emperrada (YAMASHITA, 2006).

Yamashita (2006) propôs inicialmente, de maneira mais simples, que o emperramento da válvula poderia ser detectado através do período de movimentação da válvula dentro dos padrões IS e DS, sendo estes padrões, quantificados pelo índice:

$$\rho_1 = \frac{(\tau_{IS} + \tau_{DS})}{(\tau_{total} - \tau_{SS})} \quad (3.18)$$

com τ_{total} é a duração total dos padrões, e τ_{IS} e τ_{DS} são os períodos de tempo para os padrões IS e DS, respectivamente.

Se houver emperramento na válvula analisada, este índice irá aumentar significativamente dentro do intervalo $0 \leq \rho_1 \leq 1$, sendo que em um caso extremo, se o índice ρ_1 for igual a um, a válvula não se move para nenhuma ação do controlador.

Em primeira análise Yamashita (2006) concluiu que para ρ_1 ser maior do que 0,25, a válvula possui emperramento, sendo que, estes dois padrões (IS, DS) podem acontecer através de várias causas, tais como: perturbações, tempo morto, e ruído, porém, ficou claro que, melhoria na precisão da detecção, reduzindo estas causas deveriam ser consideradas.

Para aumentar a precisão na detecção do emperramento, foi utilizado uma sucessão de dois padrões:

$$\rho_2 = \frac{(\tau_{IS,II} + \tau_{IS,SI} + \tau_{DS,DD} + \tau_{DS,SD})}{(\tau_{total} - \tau_{SS})} \quad (3.19)$$

com $\tau_{IS,II}$ é o número total de amostras de IS dentro de todo o padrão (IS, II), $\tau_{DS,DD}$ é o número de amostras de DS nos padrões (DS, DD), e assim sucessivamente.

Este índice inclui não somente um padrão de movimento, mas sim uma sequência de dois padrões. Se todo o padrão for um padrão típico de emperramento, então o valor de ρ_2 , será idêntico a ρ_1 . Da mesma forma, se ρ_2 for maior do que 0,25, a válvula possui emperramento.

Para o caso extremo, em que a válvula não se move, são encontrados somente os padrões IS, SS e DS, desta forma, o índice ρ_2 se torna 0 e não 1, assim, para corrigir esta inconsistência um novo índice foi proposto (YAMASHITA, 2006):

$$\rho_3 = \rho_1 - \frac{\sum_{X \in W} \tau_X}{(\tau_{total} - \tau_{SS})} \quad (3.20)$$

com W contendo todos os padrões:

$$W = [IS, DD; IS, DI; IS, SD; IS, ID; IS, DS; DS, DI; DS, SI; DS, ID; DS, II; DS, IS]$$

Agora o índice ρ_3 contém todos os padrões de emperramento, e se ρ_3 for maior do que 0,25, a válvula possui emperramento.

Um algoritmo foi proposto para a detecção do emperramento de válvulas (YA-

MASHITA, 2006):

1. obtenha os sinais de saída do controlador e a posição de válvula (ou a razão de fluxo correspondente);
2. calcule os diferenciais dos sinais;
3. normalize os diferenciais com a média e o desvio padrão;
4. quantifique cada variável em três símbolos (I, S e D), se o sinal normalizado for > 1 então o símbolo é (I), se o sinal normalizado for < -1 então o símbolo é (D), e se estiver entre -1 e 1, então o símbolo é (S);
5. descreva qualitativamente os movimentos por valores simbólicos, combinando cada variável;
6. retire o padrão SS da sucessão de símbolos;
7. avalie o índice ρ_1 contando os períodos IS e DS nos padrões encontrados;
8. encontre os padrões específicos e contabilize os períodos. Então avalie o índice ρ_3 .

Scali e Ghelardoni (2008) perceberam que padrões adicionais presentes em dados de plantas industriais não foram incluídos no algoritmo original. A confirmação da introdução do tempo morto entre OP e MV, no modelo original de Choudhury (CHOUDHURY et al., 2005), foi possível reproduzir quatro padrões de emperramento: SP_A , SP_B , SP_C e SP_D , como pode ser observado na Figura 3.7:




Figura 3.7: Padrões adicionais: SP_A , SP_B , SP_C e SP_D (SCALI; GHELARDONI, 2008).

De acordo com estas informações, Scali e Ghelardoni (2008) propuseram o novo índice para a detecção do emperramento de válvulas, mas considerando os quatro padrões:

$$\rho_{3,\alpha} = \rho_1 - \frac{\left(\sum_{x \in W_\alpha} \tau_x \right)}{(\tau_{tot} - \tau_{SS})} \quad (3.21)$$

com $\alpha = A, B, C$ e D , sendo que W_A são os padrões do algoritmo original de Yamashita (YAMASHITA, 2006). Desta forma, os demais padrões são:

$$W_B = [IS,DD; IS,DI; IS,SD; IS,II; IS,DS; DS,DI; DS,SI; DS,DD; DS,II; DS,IS]$$

$$W_C = [IS,DS; IS,DI; IS,SI; IS,II; IS,ID; DS,IS; DS,ID; DS,SD; DS,DD; DS,DI]$$

$$W_D = [IS,DD; IS,DS; IS,DI; IS,SI; IS,II; DS,II; DS,IS; DS,ID; DS,SD; DS,DD]$$

Note que, ao observar a Figura 3.7, os padrões C e D , são os movimentos inversos dos padrões A e B respectivamente.

Analogamente ao método original de Yamashita, se $\rho_{3,\alpha}$, for maior do que 0,25, a válvula possui emperramento, em seus movimentos diretos ($\alpha = A, B$) e inversos ($\alpha = C, D$).

3.5 Detecção de falhas: perturbações e sensores

3.5.1 O uso da estatística para o monitoramento de sistemas

As estatísticas mais comuns utilizadas na detecção e diagnóstico de falhas em processos multivariáveis são:

- Estatística T^2 de *Hotelling*;
- Estatística Q .

Estas duas técnicas foram utilizadas para a detecção de falhas neste trabalho.

Com a obtenção de dados normais, ou seja, sem falhas, de acordo com a Equação 2.91, com m variáveis e n observações para cada variável, denominados de dados experimentais, é comum um tratamento estatístico prévio destes dados antes da aplicação das técnicas T^2 e Q .

O tratamento estatístico é através da normalização dos dados, subtraindo-se de todas as n observações, a média, e em seguida dividindo-se pelo desvio padrão de

cada m variável, na sequência, calcula-se a matriz de covariância amostral:

$$S = \frac{1}{n-1} X^T X \quad (3.22)$$

Supondo que a matriz de covariância amostral \mathbf{S} admita inversa e a mesma pode ser decomposta em valores característicos:

$$S = V \Lambda V^T \quad (3.23)$$

e com a seguinte definição:

$$z = \Lambda^{-1/2} V^T x \quad (3.24)$$

A estatística T^2 de Hotelling é dada da seguinte forma (JACKSON, 1959):

$$T^2 = z^T z \quad (3.25)$$

Para a aplicação da estatística T^2 como método para a detecção de falhas em processos multivariáveis, é necessário um conjunto de dados experimentais. Este conjunto de dados não deve possuir falhas, ou seja, é um conjunto de dados históricos normais de operação.

Um fator importante que deve ser levado em consideração na utilização da estatística T^2 , é a quantidade de dados disponíveis, que se for relativamente pequena, pode ocasionar uma representação não satisfatória do comportamento do processo, aumentando o erro na modelagem, pois ocorrerá imprecisões nos menores valores característicos, corrompendo a aplicação da estatística T^2 pelo fato da pequena contribuição da razão de ruído.

A partir dos dados experimentais, aplica-se a PCA para obter a estrutura de correlação dos dados, e no momento em que novas informações do processo forem adicionadas, \mathbf{x} , ao mesmo tempo, supondo que $\Lambda = \Sigma^T \Sigma$ admita inversa, pode-se calcular a estatística T^2 diretamente da seguinte forma (CHIANG et al., 2001):

$$T^2 = x^T V (\Sigma^T \Sigma)^{-1} V^T x \quad (3.26)$$

De acordo com as técnicas de redução de ordem do modelo, e que foi apresentado na seção anterior, a estatística T^2 pode ser representada a partir do cálculo do número do componente principal a da seguinte forma:

$$T^2 = x^T P \Sigma_a^{-2} P^T x \quad (3.27)$$

com Σ_a os valores característicos dispostos na diagonal principal das a primeiras linhas e colunas de Σ .

Quando a média amostral e a matriz de covariância são conhecidas, o limite para a estatística T^2 pode ser calculado da seguinte maneira (REIS, 2008):

$$T_\alpha^2 = x_\alpha^2(a) \quad (3.28)$$

Porém, quando não se conhece a matriz de covariância real, mas sim, a mesma for estimada pela matriz de covariância amostral, de acordo com a Equação 3.23 o limite para a estatística T^2 pode ser calculado como:

$$T_\alpha^2 = \frac{a(n-1)(n+1)}{n(n-a)} F_\alpha(a, n-a) \quad (3.29)$$

com $F_\alpha(a, n-a)$ conhecida como distribuição de Fisher com a e $n-a$ graus de liberdade.

Para detectar *outliers* no conjunto de dados experimentais, o seguinte limite deve ser calculado:

$$T_\alpha^2 = \frac{(n-1)^2 \left(\frac{a}{n-a-1} \right) F_\alpha(a, n-a-1)}{n \left(1 + \left(\frac{a}{n-a-1} \right) \right) F_\alpha(a, n-a-1)} \quad (3.30)$$

A estatística T^2 é uma medida menos afetada por ruídos do processo, pois os menores valores característicos não fazem parte da análise, como pode ser observado na Equação 3.27, desta forma a estatística T^2 é capaz de expressar o comportamento normal do processo, e que não é o caso da Equação 3.26 que considera todos os valores característicos, o que acaba levando em consideração o ruído. A utilização da estatística Q é mais adequada para este tipo de situação, visto que a parte do espaço de observação contida nos $m-a$ valores característicos pode ser monitorada mais precisamente, medindo as variações aleatórias do processo. A estatística Q também é conhecida como Erro de Predição ao Quadrado - SPE (*Squared prediction Error*) e pode ser obtida por:

$$\begin{aligned} Q &= r^T r, \\ r &= (I - PP^T) x \end{aligned} \quad (3.31)$$

com \mathbf{r} o vetor de resíduos, ou seja, uma projeção do vetor de observação \mathbf{x} dentro do espaço residual (REIS, 2008).

A estatística Q foi proposta por Jackson e Mudholkar (1979) e é uma norma quadrada que mede o desvio das observações do espaço de menor dimensão da representação PCA. O limite para a estatística Q pode ser calculado com:

$$Q_\alpha = \theta_1 \left[\frac{h_0 c_\alpha \sqrt{2\theta_2}}{\theta_1} + 1 + \frac{\theta_2 h_0 (h_0 - 1)}{\theta_1^2} \right]^{1/h_0} \quad (3.32)$$

em que,

$$\theta_i = \sum_{j=a+1}^n \sigma_j^{2i}$$

$$h_0 = 1 - \frac{2\theta_1\theta_3}{3\theta_2^2}$$

c_α é o desvio normal da distribuição, correspondendo ao percentil $(1 - \alpha)$ para um dado nível de significância α .

Desta forma, a detecção de falhas em um sistema de controle é obtida através do cálculo das estatísticas T^2 e Q , pelas Equações 3.27 e 3.31 dos dados do processo, e comparados com os limites através das Equações 3.29 e 3.32 respectivamente. Se os valores das estatísticas T^2 e Q monitoradas forem maiores que as de seus limites, indica que há uma falha naquele instante.

Até o momento, o que foi discutido utilizando a técnica PCA para o monitoramento de sistemas de controle, não leva em consideração à dependência estatística de observações passadas, ou seja, a técnica apresentada considera apenas observações em um determinado instante de tempo, o que em processos industriais essa afirmação não é válida devido ao pequeno intervalo de tempo de amostragem, que em muitos casos são em segundos (REIS, 2008).

De acordo com Chiang et al. (2001), a independência estatística é obtida apenas para intervalos de amostragem entre 2 a 12 horas.

Reis (2008) mostrou em seu trabalho, uma maneira para contabilizar o efeito desta dependência para processos com curtos intervalos de tempo de amostragem, levando em consideração as correlações temporais, fazendo agora, com que o método PCA seja ampliado com as g observações anteriores em cada vetor de observação, da seguinte maneira:

$$X(k - g, :) = [x_k^T x_{k-1}^T x_{k-2}^T \cdots x_{k-g}^T], k = 1, 2, \dots, n, \quad (3.33)$$

com x_k^T o vetor de observação de dimensão m no instante de amostragem k .

Este método é conhecido com PCA dinâmica ou DPCAm, que foi denominado por Reis (2008). Estudos foram realizados para a obtenção de g de forma automática, como em Ku et al. (1995), porém experiências indicam que $g = 1$ ou 2 , quando se utiliza PCA no monitoramento de processos.


No próximo capítulo, serão apresentados 2 exemplos com a aplicação do método DPCAm e utilizando as estatísticas T^2 e Q para a detecção de falhas.

Com as ferramentas apresentadas neste capítulo, pode-se então realizar de modo geral, o monitoramento contínuo de sistemas de controle na indústria química.

Embora o método Karhunen-Loève para detecção de oscilações não se aplica à sistemas com transições operacionais, a maioria dos processos químicos não apresenta esta característica, e quando estas transições existem, logo o sistema entra em estado estacionário para condições normais de operações, justificando a aplicação do método. As demais técnicas propostas se aplicam em todos os sistemas de controle na indústria química.

CAPÍTULO 4

Resultados e Discussões

este capítulo serão abordadas as aplicações das ferramentas para monitoramento de sistemas controlados, apresentadas neste trabalho: cálculo do índice de desempenho utilizando como referência o controlador clássico MVC, os limites UPPER e LOWER, RVI e GIM que é a técnica que utiliza a fatoração de modelos através da matriz de interação generalizada, detecção de oscilações, detecção do emperramento de válvulas, e detecção de falhas, causadas por perturbações e mau funcionamento de sensores. O objetivo deste capítulo é demonstrar a aplicabilidade das técnicas mais comuns e utilizadas para o monitoramento de sistemas de controle, por isso, ao longo deste capítulo serão apresentados diferentes estudos de casos. Foi utilizado como plataforma de programação para obtenção dos resultados, o *software* livre Scilab® 5.3.3. Os casos estudados nesta seção, foram escolhidos por apresentarem dentro do cenário da indústria química, grande dificuldade no monitoramento, devido às características dinâmicas do processo, ou seja, são estudos de casos que representaram fielmente a aplicabilidade da metodologia proposta.

4.1 Cálculo do índice de desempenho

4.1.1 Coluna de destilação binária

Considere o modelo $G(q)$ de uma coluna de destilação binária em planta piloto, usada para a separação metanol-água, e o modelo $N_q(q)$ da perturbação (MAURATH, 1988), obtido através da identificação utilizando modelo em Espaço de Estados:

$$G(q) = \begin{bmatrix} \frac{-0,098q + 0,337}{q^2 - 1,338q + 0,357} & \frac{-0,311q + 0,437}{q^2 - 1,693q + 0,699} \\ \frac{-0,255q + 0,294}{q^2 - 1,822q + 0,828} & \frac{0,462q - 0,650}{q^2 - 1,682q + 0,692} \end{bmatrix} \quad (4.1)$$

$$N(q) = \begin{bmatrix} \frac{0,464}{q - 0,860} & 0 \\ 0 & \frac{0,442}{q - 0,778} \end{bmatrix} \quad (4.2)$$

com q o operador deslocamento.

Com o objetivo de trabalhar com dados operacionais, utilizou-se o modelo fenomenológico proposto por Maurath (1988) para gerar os dados e em seguida, utilizou-se a técnica de identificação em Espaço de Estados. A Figura (4.1) mostra o comportamento do modelo identificado por excitação PRBS (*Pseudo-Random Binary Sequence*), frente a uma perturbação pulso.

O objetivo é determinar o desempenho de um controlador do tipo PI , sujeito ao aumento do ganho de $G(q)$ ao longo do tempo, para analisar a degradação do sistema de controle.

O controlador PI é representado por:

$$K = \begin{bmatrix} \frac{-0,028q + 0,028}{q - 1} & 0 \\ 0 & \frac{-0,070q + 0,069}{q - 1} \end{bmatrix} \quad (4.3)$$

Para simular uma degradação no sistema de controle, fez-se um acréscimo crescente no ganho do modelo $G(q)$, que pode ser calculado como $\lim_{q \rightarrow 1} G(q)$, caracterizando-




Figura 4.1: Validação do modelo $G(q)$ frente a uma perturbação pulso.

se assim, uma degradação do sistema de controle corrente.

Para avaliar a degradação deste sistema de controle, calculou-se os índices de desempenho utilizando como referência o MVC, pela Equação (2.79), os limites UPPER e LOWER através das Equações (2.19) e (2.20), e também utilizando a fatoração do modelo por matriz de interação generalizada, ou GIM, através da Equação (3.10). O objetivo da utilização destes métodos para o cálculo do índice de desempenho, é realizar a comparação entre eles.

Para calcular o índice de desempenho MVC, calculou-se a matriz de interação unitária através da fatoração do modelo:

$$D = \begin{bmatrix} -0,557q & -0,829q \\ -0,829q & 0,557q \end{bmatrix} \quad (4.4)$$

A obtenção dos limites de desempenho UPPER e LOWER foi a partir da matriz diagonal de tempo morto:

$$D_h = \begin{bmatrix} q^{-2} & 0 \\ 0 & q^{-2} \end{bmatrix} \quad (4.5)$$

A utilização do índice de desempenho GIM, conta com a fatoração do modelo

$G(q)$ utilizando matriz de interação generalizada, o que resulta no modelo para a referência:

$$\Sigma_{M(p_1)} = \begin{bmatrix} \frac{5,95q - 1,73q^2}{0,35 - 1,33q + q^2} & \frac{-7,71q + 5,48q^2}{0,69 - 1,69q + q^2} \\ \frac{-1,74q - 1,84q^2 + 9,58q^3 - 6,02q^4}{0,29 - 1,75q + 3,62q^2 - 3,16q^3 + q^4} & \frac{0,03q + 0,07q^2 - 0,06q^3}{-0,67 + 2,33q - 2,65q^2 + q^3} \end{bmatrix} \quad (4.6)$$

$$\Sigma_{M(p_2)} = \begin{bmatrix} \frac{5,95q - 1,73q^2}{0,35 - 1,33q + q^2} & \frac{-7,71q + 5,48q^2}{0,69 - 1,69q + q^2} \\ \frac{-7,23q^2 + 15,14q^3 - 7,93q^4}{0,29 - 1,75q + 3,62q^2 - 3,16q^3 + q^4} & \frac{0,12q^2 - 0,08q^3}{-0,67 + 2,33q - 2,65q^2 + q^3} \end{bmatrix} \quad (4.7)$$

Os limites de desempenho superior e inferior dão a ideia de uma faixa de desempenho do sistema utilizando variância mínima frente a uma degradação do sistema de controle, caracterizando o comportamento do sistema com o controle corrente a ser analisado ao longo do tempo. Já o desempenho utilizando a fatoração do modelo nos dá a ideia do comportamento do sistema ao comparar com ele mesmo, mas na ausência de invariantes (tempo morto, pólos ou zeros instáveis etc.).

A Figura (4.2) mostra o comportamento do índice de desempenho do sistema, utilizando como referência o MVC, limites UPPER e LOWER, e fatoração do modelo com $\lambda = 0,2$ (GIM):

A Figura (4.3) mostra o desempenho do sistema com fatoração do modelo sob variação de λ na faixa $[0,1]$, demonstrando o comportamento com relação à opção de ponderação frente ao índice de desempenho proposto por Souza (2007).

A avaliação da faixa de desempenho para sistemas de controle com base em dados informativos de entrada-saída do processo foi realizada com sucesso. Neste trabalho, mostrou-se a adequabilidade de descrição da faixa de desempenho para um sistema de controle baseando-se numa estrutura de matriz de atrasos para o processo num contexto de variância mínima.

Os resultados dos índices de desempenho avaliados utilizando o MVC como referência e o GIM, que tem o desempenho baseado na aplicação do controle corrente ao sistema idealizado, são compatíveis, mostrando que pode-se avaliar a faixa de de-




Figura 4.2: Desempenho do sistema de controle.

sempenho do sistema de controle somente com o conhecimento da matriz de atrasos da planta (que pode ser determinada com dados de entrada-saída).

A técnica proposta para avaliação da faixa de desempenho possui limitações inerentes oriundas das bases de referência com o MVC e não se aplica na fase atual ao monitoramento de sistemas de controle com restrições. Entretanto, mostra que o conhecimento de uma faixa aproximada de desempenho esperado para o controle pode ser determinada apenas com dados de entrada-saída da planta. Essa mesma metodologia pode ser aplicada com dados operacionais em malha-fechada desde que algoritmos adequados para identificação da estrutura de atrasos sejam utilizados.

Como pôde ser observado nas Figuras (4.2) e (4.3) o índice de desempenho proposto por Souza (2007) capturou com eficiência a perda de desempenho do sistema de controle, e pode ser configurado, a depender do valor de λ , para um comportamento próximo aos limites UPPER e LOWER.

4.1.2 CSTR isotérmico

Considere o seguinte sistema representado por um CSTR isotérmico e de volume constante (SISTU; BEQUETTE, 1995):




Figura 4.3: Desempenho do sistema com fatoração do modelo sob variação de λ .

$$\begin{aligned} \frac{dx_1}{dt} &= -k_1x_1 - k_3x_1^2 + (x_{1f} - x_1)u \\ \frac{dx_2}{dt} &= k_1x_1 - k_2x_2 - x_2u \end{aligned} \quad (4.8)$$

Este modelo é representado pela reação clássica de van der Vusse:



Com x_1 e x_2 as concentrações das espécies A e B , respectivamente, x_{1f} representa a concentração de A alimentada ao reator e u representa a razão de diluição da alimentação no tanque.

Os parâmetros k_1 , k_2 , k_3 e x_{1f} para o caso estudado possuem os seguintes valores: $50h^{-1}$, $100h^{-1}$, $10L/(mol\ h)$, $10mol/L$, respectivamente. O objetivo de controle é manter a concentração de B em $1mol/L$ manipulando a razão de diluição u , desta forma: $y = x_2$.

Nesta seção, deseja-se fazer a avaliação local do sistema. Se o objetivo fosse conhecer o desempenho ao longo de uma trajetória, precisaria implementar o processo de linearização sucessiva. No caso de interesse, deseja-se avaliar o efeito da utilização de uma cinética com desativação para o controle do reator, nas proximidades do ponto de operação desejado. O modelo local (linearizado) pode ser escrito

como (OLIVEIRA-LOPES, 2000):

$$\frac{dx}{dt} = A_p x + B_p u$$

com

$$A_p = \begin{bmatrix} -k_1 - 2k_3x_1 - u_1 & 0 \\ k_1 & -k_2 - u \end{bmatrix}_{ss} \quad \text{e} \quad B_p = \begin{bmatrix} x_{1f} - x_1 \\ -x_2 \end{bmatrix}_{ss}$$

Supondo que o modelo seja perfeito, pode-se encontrar duas soluções para o estado estacionário com $x_2 = 1$. A condição operacional 1: ($x_1 = 2,5, x_2 = 1, u = 25$) e a condição operacional 2: ($x_1 = 6,6667, x_2 = 1, u = 233,33$). Assim, existem duas condições para as quais o valor de $x_2 = 1$. A esta ocorrência, chama-se de multiplicidade de sinais de entrada. Desta forma, se o controlador estiver operando neste processo apenas seguindo o erro em x_2 , pode acontecer de se ter alguma perturbação que leve o valor de $x_1 = 2,5$ para $x_1 = 6,6667$. De outra forma, pode-se desejar manter o sistema em $x_2 = 1$, mas operado sob outra condição de produtividade.

A Figura (4.4) mostra a simulação do processo estudado frente a uma perturbação degrau unitário para o modelo não linear e o linearizado. No caso de interesse, deseja-se avaliar o sistema nas vizinhanças do ponto de operação.

Desta forma, seguindo a mesma sistemática mostrada anteriormente na Seção (4.1.1), a referência será projetada, utilizando MVC, pela Equação (2.79), através fatoração do modelo linearizado, por matriz de interação generalizada, ou GIM, através da Equação (3.10), e também pela fatoração INNER-OUTER através da Equação (3.4) com o objetivo de comparar os índices, que serão obtidos pela fatoração do modelo linearizado no ponto dado pela condição operacional 1 do estado estacionário $x_1 = 2,5, x_2 = 1, u = 25$, e com $C = [0 \ 1]$ e $D = 0$.

A representação discreta do modelo para um tempo de amostragem $T_s = 0,002$ h pode ser investigada e a aplicação da metodologia GIM, resulta num modelo de referência dado por (4.9) e (4.10), conforme:

$$\Sigma_{M(p_1)} = \frac{0,001z^2 + 0,001z}{z^2 - 1,557z + 0,606} \quad (4.9)$$

e,

$$\Sigma_{M(p_2)} = \frac{0,0007z^2}{z^2 - 1,557z + 0,606} \quad (4.10)$$




Figura 4.4: Comportamento dinâmico do sistema não linear e para a aproximação linear utilizada.

Foi avaliado um sistema de controle PI para o processo descrito, com os parâmetros $K_C = 1,125$ e $\tau_I = 8,333$, para o controle corrente, já para a referência, os controladores foram:

$$K_{\Sigma M(p_1)} = \frac{76,5z - 67,32}{z - 1} \quad \text{e} \quad K_{\Sigma M(p_2)} = \frac{67,5z - 59,4}{z - 1}$$

A Figura (4.5) mostra a resposta do processo controlado com estratégia PI. As Figuras (4.6a) e (4.6b) mostram as respostas dos processos de referência associados ao processo.

Frente ao desenvolvimento da estrutura de controle corrente, bem como o projeto da referência, de acordo com a Equação (3.10) com $\lambda = 0,5$, tem-se que o desempenho do sistema corrente para uma variação na constante de velocidade k_2 , simulando o efeito de inibição ou desativação catalítica ao longo do tempo, pode ser observado na Figura (4.7).

A Figura (4.8) mostra o índice de desempenho para o MVC como referência. Notou-se que ao utilizar o MVC como referência para este caso, não foi possível detectar com eficiência, a degradação para uma variação na constante de velocidade k_2 .

A utilização do controle de variância mínima (MVC) como referência, possui vários pontos negativos, que podem explicar o comportamento observado na Figura (4.8), tais como:






Figura 4.5: Controle corrente PI.



(a) Controle de referência PI dado por $K_{\Sigma M(p_1)}$.



(b) Controle de referência PI dado por $K_{\Sigma M(p_2)}$.

Figura 4.6: Comportamento do sistema fatorado sob ação de controladores PIs.

- não considera características de zeros que levam a um comportamento de fase não mínima e resposta inversa;
- não compensa outras características limitantes, como restrições em variáveis manipuladas;
- não considera nenhuma limitação no atuador de controle, como abertura e velocidade máxima de abertura de válvulas de controle;
- não é robusto etc.




Figura 4.7: Índice de Desempenho para o CSTR isotérmico.

Desta forma, mais uma vez ficou comprovado a eficiência do método de fatoração de modelos para obter a referência para o cálculo do índice de desempenho de sistemas controlados.

O ponto negativo da utilização da técnica de fatoração, é a dependência da modelagem, porém, a técnica se estende a qualquer tipo de configuração de controle, como por exemplo, a utilização de controladores preditivos (MPC), apresentado em Souza (2007).

4.1.3 Tanque para o aquecimento de substâncias

Considere o tanque para aquecimento de substâncias mostrado na Figura (4.9) (BEQUETTE, 1998), em que a corrente de entrada é recebida de outro processo. O




Figura 4.8: Índice de Desempenho para o CSTR isotérmico utilizando o MVC como referência.

objetivo é elevar a temperatura da corrente de saída para um valor desejado. Um fluido de aquecimento é circulado através de uma jaqueta para aquecer o líquido no tanque, supondo que não exista mudança de fase do fluido de aquecimento.




Figura 4.9: Tanque de aquecimento.

Com o objetivo de facilitar e organizar a modelagem, a Tabela (4.1) mostra a notação utilizada neste exemplo.

A modelagem deste sistema pode ser obtida mediante algumas simplificações:

Tabela 4.1: Notação.

Variáveis	Significado
A	Área de troca térmica (ft^2)
H	Altura do tanque (ft)
β	Parâmetro da válvula de alimentação
C_p	Capacidade calorífica ($Btu/lb/min$)
F	Vazão volumétrica (ft^3/min)
ρ	Densidade (lb/ft^3)
T	Temperatura ($^{\circ}F$)
t	Tempo (min)
Q	Taxa de transferência de calor (Btu/min)
U	Coefficiente de transferência de calor
V	Volume (ft^3)
Índices	Significado
0	Entrada
j	Jaqueta
$j0$	Entrada na jaqueta
ee	Estado estacionário

1. o volume é constante, bem como a densidade e a capacidade calorífica;
2. a camisa e tanque possuem misturas perfeitas;
3. consideram-se como variáveis de entrada a vazão de entrada na camisa de aquecimento e o fluxo de entrada no tanque;
4. a taxa de calor transferida da camisa para o tanque é modelada por $Q=UA(T_j-T)$, em que U é o coeficiente global de transferência de calor e A é a área de troca térmica, assim, o modelo é descrito pelo conjunto de equações (4.11).

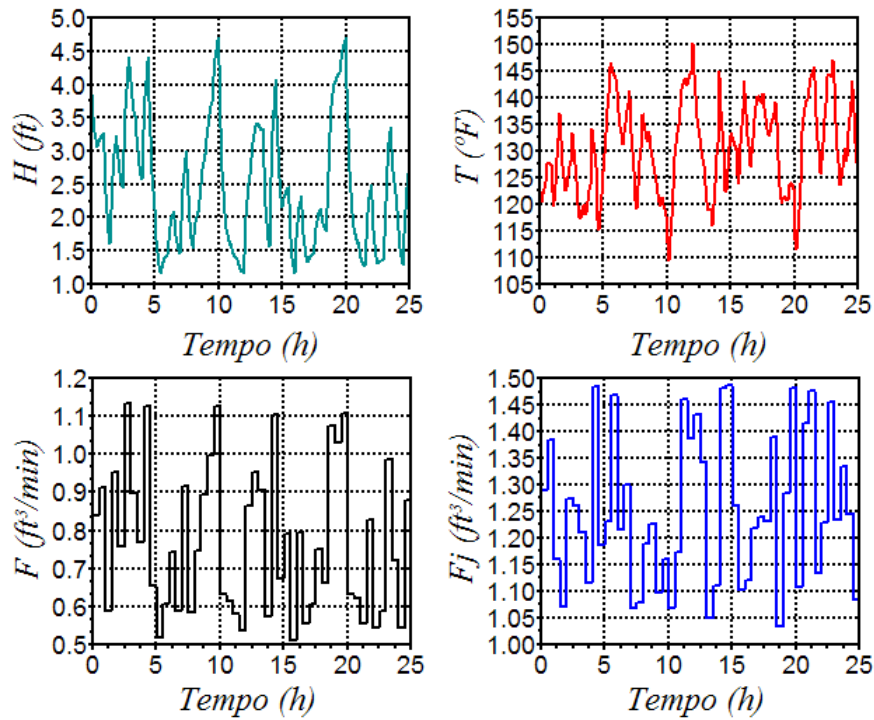
$$\begin{aligned}
\frac{dH}{dt} &= \frac{F - F_T}{A} \\
\frac{dT}{dt} &= \frac{F}{V}(T_0 - T) + \frac{UA(T_j - T)}{V\rho C_p} \\
\frac{dT_j}{dt} &= \frac{F_j}{V_j}(T_{j0} - T_j) - \frac{UA(T_j - T)}{V_j\rho_j C_{pj}}
\end{aligned} \tag{4.11}$$

A Tabela (4.2) mostra os parâmetros no estado estacionário:

Com o objetivo de trabalhar com dados de operação de planta, utilizou-se o modelo representado pelo conjunto de equações (4.11) para gerar dados de entrada e saída para a identificação do modelo, com entradas F e F_j , como pode ser observado na Figura (4.10).

Tabela 4.2: Parâmetros no estado estacionário.

$F_{ee} = 1 \text{ ft}^3/\text{min}$	$\rho C_p = 61,3 \text{ Btu}/^\circ\text{F}/\text{ft}^3$
$T_{0ee} = 50^\circ\text{F}$	$T_{ee} = 125^\circ\text{F}$
$T_{j0ee} = 200^\circ\text{F}$	$T_{jee} = 150^\circ\text{F}$
$UA = 183,9 \text{ Btu}/^\circ\text{F}/\text{min}$	$F_{jee} = 1,5 \text{ ft}^3/\text{min}$
$\rho_j C_{pj} = 61,3 \text{ Btu}/^\circ\text{F}/\text{ft}^3$	$V = 10 \text{ ft}^3$
$V_j = 1 \text{ ft}^3$	$\beta = 0,5$

**Figura 4.10:** Excitação persistente para identificação.

Com os dados de entrada e saída da malha aberta conseguiu-se chegar à matriz de funções de transferência que representa o modelo da planta com tempo de amostragem $T_s = 2,5min$:

$$G(z) = \begin{bmatrix} \frac{1,462z - 0,787}{z - 0,895} & \frac{0,378z - 0,416}{z - 0,895} \\ \frac{18,936z - 23,601}{z - 0,895} & \frac{18,484z - 15,562}{z - 0,895} \end{bmatrix} \quad (4.12)$$

A Figura (4.11) mostra o ajuste no processo de identificação. Foram utilizados 50 % dos pontos para identificação, e o restante para validação. As Figuras (4.12) e (4.13) mostram o histograma da distribuição de frequência dos dados para identificação e os resíduos utilizando os critérios de informação *MSE* e *Akaike* (AIC) para a escolha da ordem do modelo, respectivamente. Ao observar a Figura (4.13), nota-se que a melhor escolha seria o modelo de ordem 1, por possuir menor resíduo e ser o de menor grau.




Figura 4.11: Identificação do modelo da planta.

A estrutura de controle *feedback* corrente analisada, de acordo com o diagrama de blocos da Figura (4.14), foi a de um PID com os parâmetros para o controle de nível: $K_C = 1 \text{ ft}^2/min$, $\tau_I = 10 \text{ min}$, $\tau_D = 120 \text{ min}$ e para o controle de

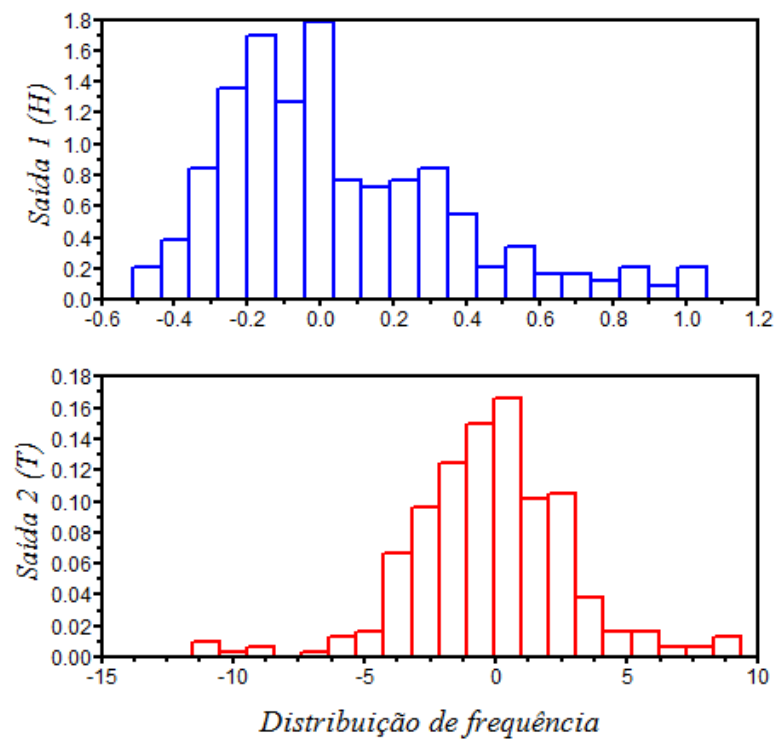


Figura 4.12: Histograma.

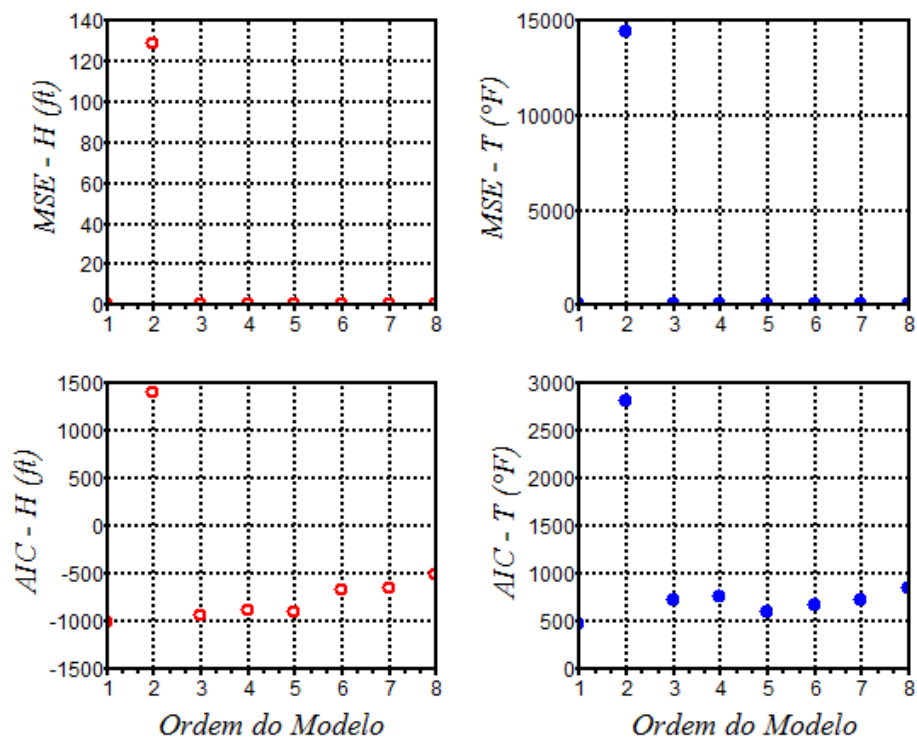


Figura 4.13: Resíduos.

temperatura: $K_C = 1,5 \text{ } ft^3/({}^\circ Fmin)$, $\tau_I = 20 \text{ } min$, $\tau_D = 150 \text{ } min$.

Com o objetivo de trabalhar com o problema regulador, tem-se $y_{sp} = 0$, desta forma a Equação (3.1) se reduz à: $y = (I + GK)^{-1}Na_t$.

Através do método descrito na Seção 3.2 obteve-se a matriz de funções de transferência da perturbação N utilizando o sinal descrito na Equação 3.2:

$$N(z) = \begin{bmatrix} \frac{0,01z}{z - 0,5} & \frac{-0,06z}{z - 0,5} \\ \frac{0,05z}{z - 0,5} & \frac{0,01z}{z - 0,5} \end{bmatrix} \quad (4.13)$$

A Figura (4.14) mostra o ajuste no processo de identificação. Foram utilizados 50 % dos pontos para identificação, e o restante para validação. As Figuras (4.15) e (4.16) mostram o histograma da distribuição de frequência dos dados para identificação e os resíduos utilizando os critérios de informação MSE e $Akaike$ (AIC) para a escolha da ordem do modelo, respectivamente. Ao observar a Figura (4.16), nota-se que a melhor escolha seria o modelo de ordem 1, por possuir menor resíduo e ser o de menor grau.




Figura 4.14: Identificação do modelo da perturbação.

Com a identificação da matriz de funções de transferência do modelo da planta $G(z)$ e da perturbação $N(z)$, e conhecendo-se o controlador corrente K , pode-se

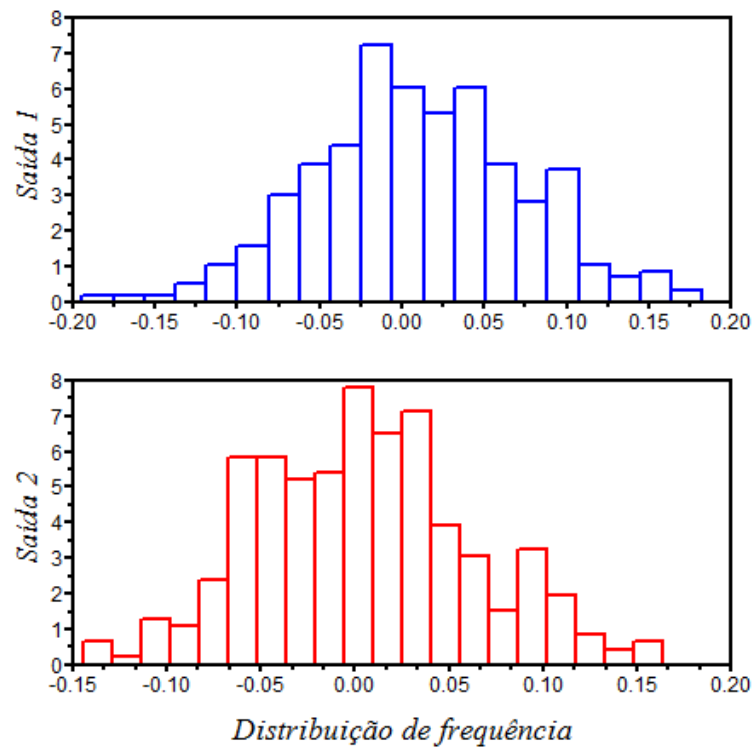


Figura 4.15: Histograma.

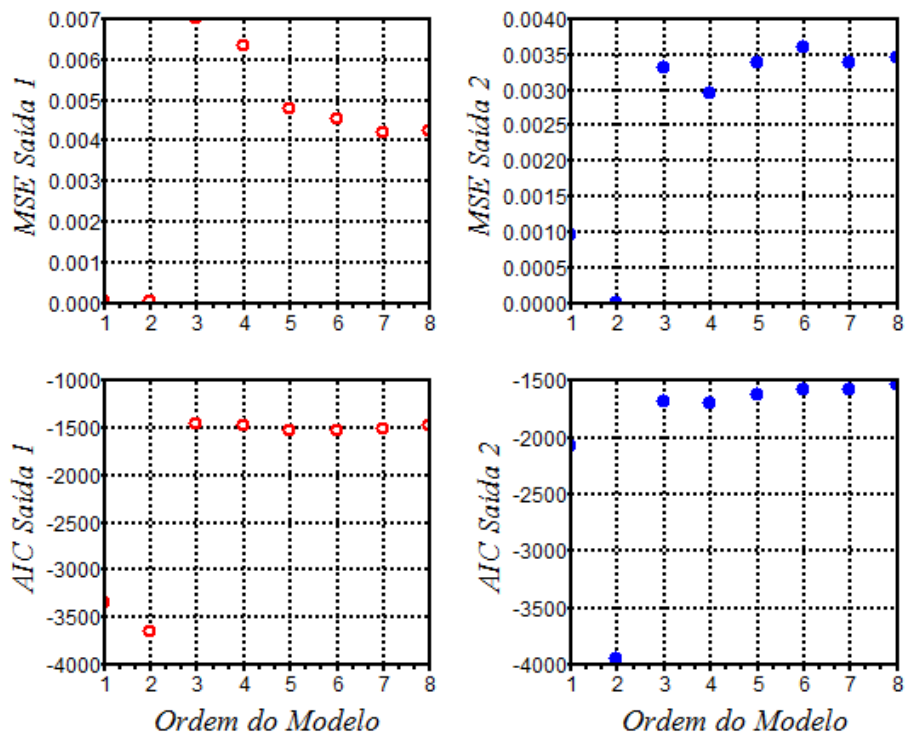


Figura 4.16: Resíduos.

então analisar o desempenho do sistema de controle calculando o Índice de Desempenho.

Admitindo-se que não ocorra nenhuma falha no sistema de controle corrente, a análise do desempenho será realizada frente a uma possível mudança no modelo da planta, para isso, será simulado um acréscimo no ganho do modelo de até 12 % para simular uma degradação no sistema.

Neste caso, como $G(z)$ é um modelo de fase não-mínima, a fatoração utilizando matriz de interação generalizada, gera:

$$\Sigma_{M(p_1)} = \Sigma_{M(p_2)} = G(z)$$

ou seja, em casos de modelos de fase não-mínima, as referências projetadas pela técnica GIM ($\Sigma_{M(p_1)}$ e $\Sigma_{M(p_2)}$), são iguais ao modelo do processo a ser fatorado ($G(z)$), que é uma característica do algoritmo.

Para avaliar a degradação deste sistema de controle, calculou-se os índices de desempenho utilizando como referência o MVC, pela Equação (2.79), os limites UPPER e LOWER através das Equações (2.19) e (2.20), e também utilizando a fatoração do modelo por matriz de interação generalizada, ou GIM, através da Equação (3.10). Também, para este caso, foi calculado o índice de desempenho, levando em consideração a variabilidade de malha aberta, conhecido como Índice de Desempenho de Variância Relativa (RVI), proposto por Bezergianni e Georgakis (2000), através da Equação (2.5). O objetivo da utilização destes métodos para o cálculo do índice de desempenho, é mais uma vez, realizar a comparação entre eles, porém, desta vez, foi realizado a normalização dos índices.

A Figura 4.17 mostra o comportamento ao longo do tempo para o desempenho do sistema corrente submetido à mudança no ganho do modelo da planta. Como mencionado, os índices de desempenho apresentados na Figura 4.17 são todos normalizados, e fica evidente a degradação do sistema de controle.

Nota-se que, após normalizar os índices de desempenho, apenas o comportamento do índice RVI não obedeceu à similaridade que houve entre os demais, ou seja, após a normalização, a grandeza dos valores não é igual ao se comparar com os índices MVC, UPPER, LOWER e GIM. Este fato, pode ser explicado, pois o RVI considera a variabilidade da saída do sistema em malha aberta, mas serve também de medida para observar o comportamento do sistema com o passar do tempo, ficando evidente que a utilização de qualquer uma das técnicas satisfaz a necessidade de monitorar continuamente sistemas de controle.

Os índices de desempenho calculados, fornecem a ideia do quanto o controle corrente do sistema está distante do melhor controle idealizado com mesma estrutura. Desta forma, o método utilizando fatoração do sistema com base em matriz de interação generalizada, como cálculo do índice de desempenho é válido, tanto no ponto de vista físico, pois se trata de uma referência realizável, quanto do ponto de vista teórico, na qual, ao realizar a fatoração, os invariantes dos sistemas deixam de ser considerados, tornando o sistema mais fácil de ser controlado, e então servindo como referência para o controle. A opção de se deslocar as dificuldades de controle de uma variável de saída permite que as variáveis sejam ordenadas segundo o grau de importância e o índice de desempenho refletirá essa preferência.




Figura 4.17: Desempenho do sistema de controle corrente.

4.2 Detecção de oscilações

4.2.1 Sinais sintéticos

Com o objetivo de ilustrar as técnicas apresentadas na Seção 3.3.1 deste trabalho, criou-se aleatoriamente 6 variáveis medidas com 700 amostras. Foi acrescentada propositalmente uma oscilação na primeira e na quarta medida, descrita pela soma de dois senos de frequência 100 e 200 Hz, iniciando-se na amostragem 350. Este conjunto de dados sintéticos foi normalizado de acordo com a exigência do método, apresentado na Seção 3.3.1, e possui média igual a zero. A Figura (4.18) representa o conjunto de dados analisados.




Figura 4.18: Dados sintéticos para análise de oscilação.

Na Figura (4.19), a linha tracejada representa o valor de referência Ω , e quando acrescentada a oscilação, notou-se mudanças no comportamento da variância de $\lambda[n]$, ultrapassando o valor Ω , denotado uma possível presença de oscilação. A Tabela (4.3) apresenta os resultados obtidos através da análise Karhunen-Loève descrito na Seção 3.3.1.




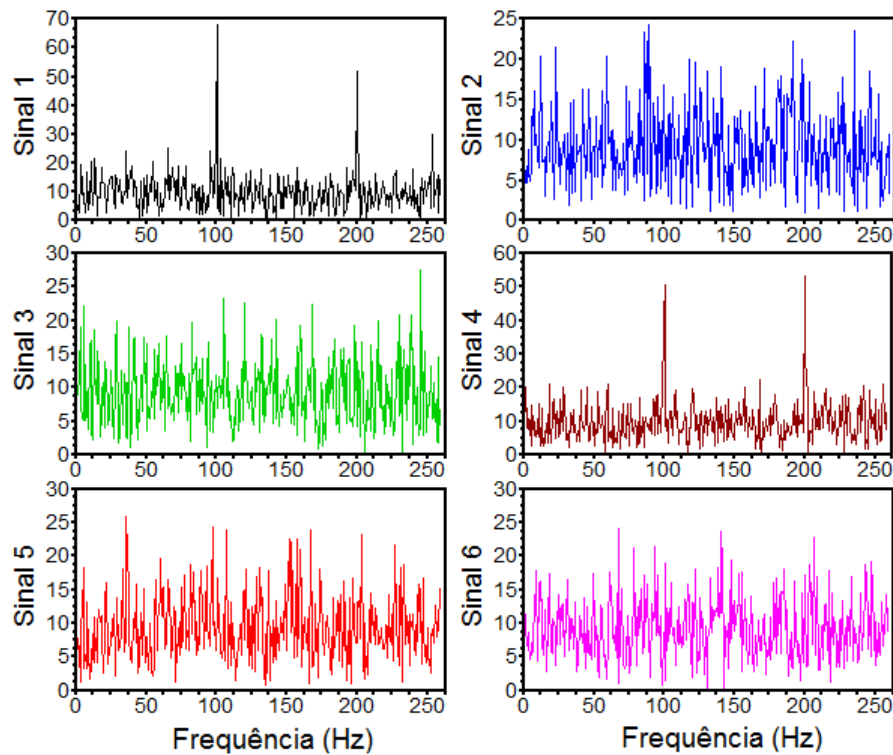
Figura 4.19: Variância de $\lambda[n]$.

Como observado na Tabela (4.3), pode-se notar que os sinais 1 e 4 possuem média da variância maior que o valor de $\overline{OS_M} + \delta$, calculado pela Equação (3.16) com $\delta = 1\%$, ou seja, trata-se dos sinais que contém as oscilações, que pelo método somam $N_0 = 223$.

Tabela 4.3: Análise Karhunen-Loève para sinais sintéticos.

Sinais	\bar{y}_{var}	$\overline{OS_M} + \delta$	N_0
1	0,1954046	0,1861969	223
2	0,1507964		
3	0,1551051		
4	0,1977103		
5	0,1577253		
6	0,1566122		

A Figura (4.20) mostra o periodograma dos sinais analisados, em que fica evidente que nos sinais 1 e 4, os pontos de 100 e 200 Hz apresentaram uma densidade espectral bem maior que os demais sinais, indicando a oscilação acrescentada propositalmente para fins de demonstração da técnica.

**Figura 4.20:** Espectro de potência dos sinais aleatórios.

4.2.2 Reatores em série

Considere dois reatores contínuos, operando em série conforme a Figura (4.21), no qual ocorre uma reação isotérmica e irreversível (LIU et al., 2004). Os dois reatores são resfriados por água através de uma jaqueta, com vazões F_{j1} e F_{j2} e temperaturas T_{j1}

e T_{j2} , respectivamente. Supondo-se que $V_{j1} = V_{j2} = V_j$, $V_1 = V_2 = V$, $F_0 = F_2 = F$, $F_1 = F + F_R$.




Figura 4.21: Reatores contínuos em série.

O processo dinâmico é descrito por (4.14).

$$\begin{aligned}
 \frac{dC_{A1}}{dt} &= \frac{F_0 C_{A0}}{V} - \frac{(F + F_R) C_{A1}}{V} + \frac{F_R C_{A2}}{V} - \alpha C_{A1} e^{-E/RT_1} \\
 \frac{dC_{A2}}{dt} &= \frac{(F + F_R) C_{A1}}{V} - \frac{(F + F_R) C_{A2}}{V} - \alpha C_{A1} e^{-E/RT_2} \\
 \frac{dT_1}{dt} &= \frac{F_0 T_0}{V} - \frac{(F + F_R) T_1}{V} + \frac{F_R T_2}{V} - \frac{UA}{\rho c_p V} (T_1 - T_{j1}) - \frac{\alpha \lambda}{\rho c_p} C_{A1} e^{-E/RT_1} \\
 \frac{dT_2}{dt} &= \frac{(F + F_R) T_1}{V} - \frac{(F + F_R) T_2}{V} - \frac{UA}{\rho c_p V} (T_2 - T_{j2}) - \frac{\alpha \lambda}{\rho c_p} C_{A1} e^{-E/RT_2} \\
 \frac{dT_{j1}}{dt} &= \frac{(T_{j10} - T_{j1}) F_{j1}}{V_j} + \frac{UA(T_1 - T_{j1})}{\rho_j c_{pj} V_j} \\
 \frac{dT_{j2}}{dt} &= \frac{(T_{j20} - T_{j2}) F_{j2}}{V_j} + \frac{UA(T_2 - T_{j2})}{\rho_j c_{pj} V_j}
 \end{aligned} \tag{4.14}$$

A Tabela (4.4) mostra os parâmetros do processo.

O objetivo do controle é manter C_{A2} , T_1 e T_2 nos seus valores do estado estacionário: $10,42 \text{ mol/m}^3$, $750,04^\circ\text{C}$ e $737,38^\circ\text{C}$, respectivamente. Para isto, manipularam-se as variáveis F_0 , T_{j10} e T_{j20} .

Tabela 4.4: Parâmetros do sistema de reatores.

$\alpha = 7,08 \times 10^1 0h^{-1}$	$E = 3,1644 \times 10^7 J/mol$
$R = 1679,2 J/mol/^\circ C$	$\lambda = -3,1644 \times 10^7 J/mol$
$U = 1,3625 \times 10^6 J/h/m^2/^\circ C$	$C_{A0} = 18,3728 mol/m^3$
$T_{j10} = 629,2^\circ C$	$T_{j20} = 608,2^\circ C$
$\rho = 800,9 kg/m^3$	$\rho_j = 997,9 kg/m^3$
$c_p = 1395,3 J/kg/^\circ C$	$c_{pj} = 1395,3 J/kg/^\circ C$
$F = 2,8317 m^3/h$	$F_{j1} = F_{j2} = 1,4130 m^3/h$
$F_R = 2,8317 m^3/h$	$A = 23,2 m^2$
$V_j = 0,1090 m^3$	$V = 1,3592 m^3$
$T_{10} = 750^\circ C$	$T_{20} = 730^\circ C$

O controlador utilizado para manter este objetivo, é do tipo PI (Proporcional-Integral), de acordo com (4.15):

$$\begin{aligned}
 F_0 &= -3,8(C_{A2} - C_{A2}^d) - 0,038 \int (C_{A2} - C_{A2}^d)dt \\
 T_{j10} &= -60(T_1 - T_1^d) - 6 \int (T_1 - T_1^d)dt \\
 T_{j20} &= -100(T_2 - T_2^d) - 125 \int (T_2 - T_2^d)dt
 \end{aligned} \tag{4.15}$$

O tempo de amostragem foi de $T_s = 0,01$ horas, e a Figura 5 mostra a dinâmica do processo na ausência de oscilação. A linha tracejada indica o *setpoint* (estado estacionário).

Segundo Choudhury et al. (2004), o emperramento de válvulas pode ocasionar saídas oscilatórias no processo, desta forma, com o objetivo de ilustrar a técnica proposta será colocada propositalmente uma oscilação na saída da planta, simulando o emperramento da válvula de vazão de entrada (F_0) do reagente, e se avalia o desempenho da metodologia proposta na detecção e localização da oscilação. Desta forma, adicionou-se nas saídas C_{A1} , C_{A2} , T_1 e T_2 após atingir o estado estacionário, a soma de dois senos de frequência 80 e 100 Hz, visto que um possível emperramento na válvula de F_0 pode causar a oscilação nos sinais de saída para as concentrações e temperaturas dentro dos reatores.

A Figura (4.23) representa o conjunto de dados analisados, e como observado na Figura (4.24), a linha tracejada representa o valor de referência Ω , e quando acrescentada a oscilação, notou-se mudanças no comportamento da variância de $\lambda[n]$, ultrapassando o valor de Ω , denotado uma possível presença de oscilação. A Tabela (4.5) apresenta os resultados obtidos através da análise Karhunen-Loève




Figura 4.22: Dinâmica do sistema de reatores.

descrito na Seção 3.3.1.




Figura 4.23: Sinais de saída para o sistema de reatores.




Figura 4.24: Variância de $\lambda[n]$ para o sistema de reatores.

Tabela 4.5: Análise Karhunen-Loève para os reatores em série.

Sinais	\bar{y}_{var}	$\overline{OS_M} + \delta$	N_0
C_{A1}	0,1561595	0,1224334	80
C_{A2}	0,1734585		
T_1	0,1559767		
T_2	0,1519993		
T_{j1}	0,0868767		
T_{j1}	0,0689838		

Como observado na Tabela (4.5), pode-se notar que os sinais de saídas C_{A1} , C_{A2} , T_1 e T_2 possuem média da variância maior que $\overline{OS_M} + \delta$, calculado pela Equação (3.16) com $\delta = 1\%$, ou seja, trata-se dos sinais que contêm as oscilações, que pelo método somam $N_0 = 80$.

A Figura (4.25) mostra o periodograma dos sinais analisados, que fica bastante evidente que nos sinais de saídas C_{A1} , C_{A2} , T_1 e T_2 , os pontos de 80 e 100 Hz apresentaram uma densidade espectral bem maior que os demais sinais, indicando a oscilação acrescentada propositalmente para fins de demonstração da técnica.

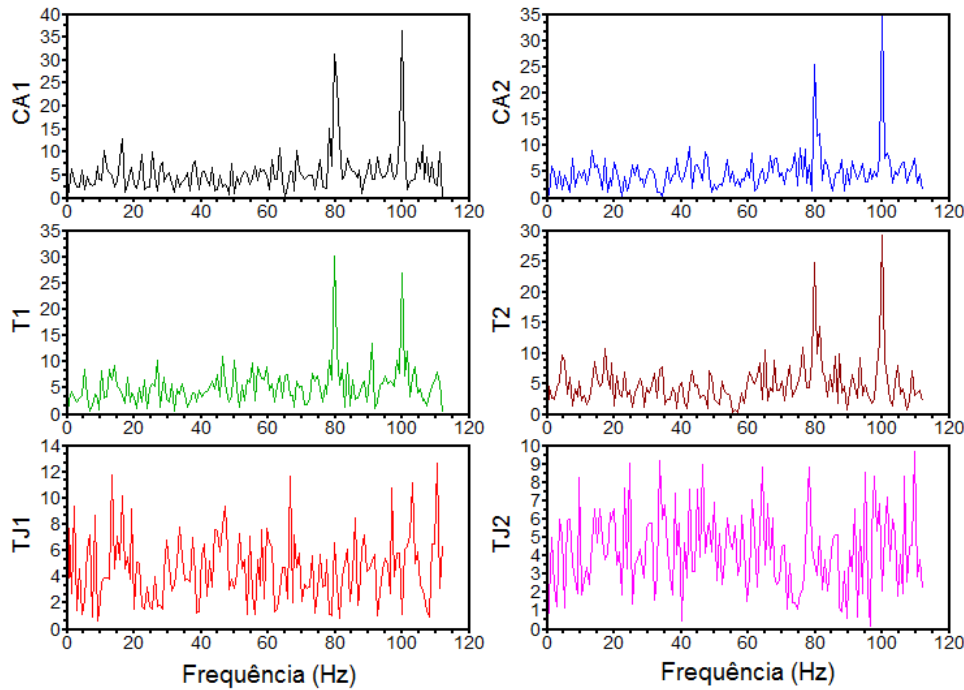


Figura 4.25: Espectro de potência para o sistema de reatores.

Nesta seção, mostrou-se a adequabilidade da técnica aplicada a casos em que não existam transições operacionais no processo. Do contrário, novas técnicas de localização das oscilações devem ser estudadas, como mencionado na Seção 2.2.

Os resultados obtidos foram satisfatórios e conseguiu-se detectar a presença de oscilação nos sinais de saída dos casos estudados, bem como a localização das mesmas, sendo assim, fica comprovada a eficiência da técnica, ao aplicar-se em sistemas de grandes dimensões e que não possuam transições operacionais.

Para sumarizar, esta seção mostra que uma metodologia bastante simples e eficiente pode ser aplicada na indústria para os sistemas de monitoramento automático de processo, que pode levar a informações muito importantes para avaliação de problemas de sintonia de controladores, problemas de emperramento (emperramento de válvulas) ou mesmo detecção de perturbações oscilatórias no processo.

4.3 Detecção do emperramento de válvulas

4.3.1 Coluna de destilação de alta pureza

Seja uma coluna de destilação de alta pureza composta de 25 pratos, um condensador e um refeedor. A composição do destilado (x_d) é a saída do sistema e a razão de refluxo (R) é a entrada do sistema. O modelo dinâmico pode ser descrito segundo as equações (STOGESTAD; MORARI, 1987), considerando:

- volatilidade relativa constante;
- 100% de eficiência nos estágios;
- resposta imediata de vapor e líquido;
- perfeito controle de nível no refluxo e na base da coluna.

Base e refeedor:

$$M_b \frac{dx_b}{dt} = L_1 x_1 - B x_b - V y_b \quad (4.16)$$

Condensador:

$$M_d \frac{dx_d}{dt} = V y_{nt} - R x_d - D x_d \quad (4.17)$$

Prato de alimentação:

$$M_{nf} \frac{dx_{nf}}{dt} = V(y_{nf-1} - y_{nf}) + L_{nf+1} x_{nf+1} - L_{nf} x_{nf} + F z_f \quad (4.18)$$

Prato de topo:

$$M_{nt} \frac{dx_{nt}}{dt} = V(y_{nt-1} - y_{nt}) + R x_d - L_{nt} x_{nt} \quad (4.19)$$

Outros pratos:

$$M_i \frac{dx_i}{dt} = V(y_{i-1} - y_i) + L_{i+1} x_{i+1} - L_i x_i \quad (4.20)$$

onde x_i são as composições de líquido, y_i são as composições de vapor, M_i são os *holdups*, L , V , B , F e D são as vazões do líquido, vapor, base, alimentação e destilado, respectivamente. Pode-se assumir ainda que:

$$L_i = \begin{cases} R & i > n_f \\ R + F & i \leq n_f \end{cases} \quad (4.21)$$

Com a seguinte relação de equilíbrio:

$$y_i = \frac{\alpha x_i}{1 + (\alpha - 1)x_i} \quad (4.22)$$

As propriedades da coluna de destilação utilizadas na simulação em unidades consistentes são apresentadas na Tabela (4.6). A Figura (4.26) representa o esquema da coluna de destilação.

Tabela 4.6: Propriedades da coluna de destilação.

Número de pratos (n_t)	25
Prato alimentação (n_f)	12
Comp. alimentação (x_{nf})	0,5kmol
Composição do topo (x_d)	0,995kmol
Composição da base (x_b)	0,005kmol
Refluxo (R)	1,477kmol/min
Boilup (V)	1,977kmol/min
Volatilidade relativa (α)	2
Vazão de alimentação (F)	1,0kmol/min
Vazão do destilado (D)	0,5kmol/min
Vazão de condensado (B)	0,5kmol/min
Holdup dos pratos (M_i)	0,5kmol
Holdup condensador (M_d)	0,5kmol
Holdup do refeedor (M_b)	0,5kmol

As condições nominais da Tabela (4.6) correspondem ao ponto de operação em torno do qual a simulação deverá realizada. Tal ponto de operação é interessante do ponto de vista de identificação e controle de processos por apresentar um comportamento altamente não linear com variação brusca do valor do ganho em estado estacionário, como mostra a Figura (4.27).

O objetivo é controlar a composição de topo x_d , manipulando a razão de refluxo R , para isto, com o objetivo de trabalhar com os dados operacionais, utilizou-se o modelo das Equações (4.16, 4.17, 4.18, 4.19, 4.20, 4.21, e 4.22) para gerar os dados,




Figura 4.26: Diagrama esquemático da coluna de destilação.




Figura 4.27: Curva de operação do estado estacionário.

então, realizou-se a identificação em Espaço de Estados, resultando no modelo:

$$G(z) = \frac{0.1491990 - 0.4754480z}{-0.6386913 + z} \quad (4.23)$$

O controle utilizado é do tipo PID, com os parâmetros: $K_C = 50$, $\tau_I = 10 \text{ min}$ e $\tau_D = 0,5 \text{ min}$.

A figura (4.28) mostra o ajuste no processo de identificação. Foram utilizados 50 % dos pontos para identificação, e o restante para validação.




Figura 4.28: Identificação em Espaço de Estados. Com x_{ds} os valores de x_d sem tendência.

Com o objetivo de demonstrar a aplicação da técnica de detecção do emperramento de válvulas proposto por Yamashita (2006), descrito na Seção 2.3 foi simulado um agarramento na válvula que controla a vazão de refluxo R .

A dinâmica do processo controlado sem a presença do emperramento na válvula de R , de acordo com as mudanças no *setpoint* para $\text{Tempo} = 0 \text{ min} \rightarrow x_d = 0,9$, $\text{Tempo} = 40 \text{ min} \rightarrow x_d = 0,99$, $\text{Tempo} = 80 \text{ min} \rightarrow x_d = 0,9$, é representado pela Figura (4.29).

A Figura (4.30) mostra a dinâmica do processo controlado com a presença do emperramento na válvula de R , para a mesma variação no *setpoint* observado na Figura (4.29).

A simulação do emperramento da válvula foi obtido fixando os valores do sinal de saída da válvula durante a dinâmica observado na Figura (4.29). Os valores fixados durante a simulação produziu um erro no *setpoint* devido ao emperramento da válvula, como observado na Figura (4.30). A ausência da oscilação em torno do *setpoint* é explicada devido ao fato de que a mudança no *setpoint* nos intervalos de 40min, a válvula ficou emperrada em uma posição em todo o período até que o valor desejado para x_d fosse alterado.




Figura 4.29: Dinâmica do processo controlado sem a presença do emperramento na válvula de R .




Figura 4.30: Dinâmica do processo controlado com a presença do emperramento na válvula de R .

Com a simulação do emperramento na válvula de refluxo, notou-se que a variável de operação (OP), ou seja, o sinal de saída do controlador, representado por R sem emperramento, observado na Figura (4.29), é diferente da variável manipulada (MV), que é o sinal de saída da válvula, representado por R com emperramento, observado na Figura (4.30), de acordo com a Figura (2.5) da Seção 2.3.

Na Figura (4.31) estão representadas as variáveis OP e MV.




Figura 4.31: $OP \times MV$.

Utilizando o método de Yamashita modificado (SCALI; GHELARDONI, 2008), demonstrado na Seção 2.3, chegou-se ao seguinte resultado de acordo com a Equação (3.21):

$$\Rightarrow \rho_{3,A} = \rho_{3,B} = 0,42, \text{ concluindo-se que há emperramento, pois } \rho_{3,\alpha} > 0,25.$$

Foi feito também a taxa de sucesso do método, para n amostras, com $n/2$ amostras com emperramento e $n/2$ amostras na ausência de emperramento. O resultado para $n = 2000$ foi:

- 78,4% dos emperramentos foram detectados quando estes existiam;
- 21,6% dos emperramentos não foram detectados quando estes existiam;
- 0% dos emperramentos foram detectados quando estes não existiam;

- 100% dos emperramentos não foram detectados quando estes não existiam.

Como a simulação foi realizada com ruído aleatório os 21,6% de falha do método, quando havia emperramento, mas não foi detectado, pode ser explicado pela sensibilidade da técnica na presença de ruídos. Apesar deste ponto negativo, e da necessidade do conhecimento da posição da válvula, o método é simples, de fácil implementação e o mais seguro (JELALI; HUANG, 2010).

4.4 Detecção de falhas: perturbações e sensores

Nesta seção, serão apresentados dois estudos de casos dentro de um cenário de falhas não simultâneas.

4.4.1 CSTR não-isotérmico

Seja um CSTR Não-isotérmico de acordo com a Figura (4.32) (CONNER; SEBORG, 2005). A escolha deste processo para aplicação dos métodos de detecção de falhas, é justificada devido à não-linearidade e as possibilidades de simulação dos tipos de falhas.

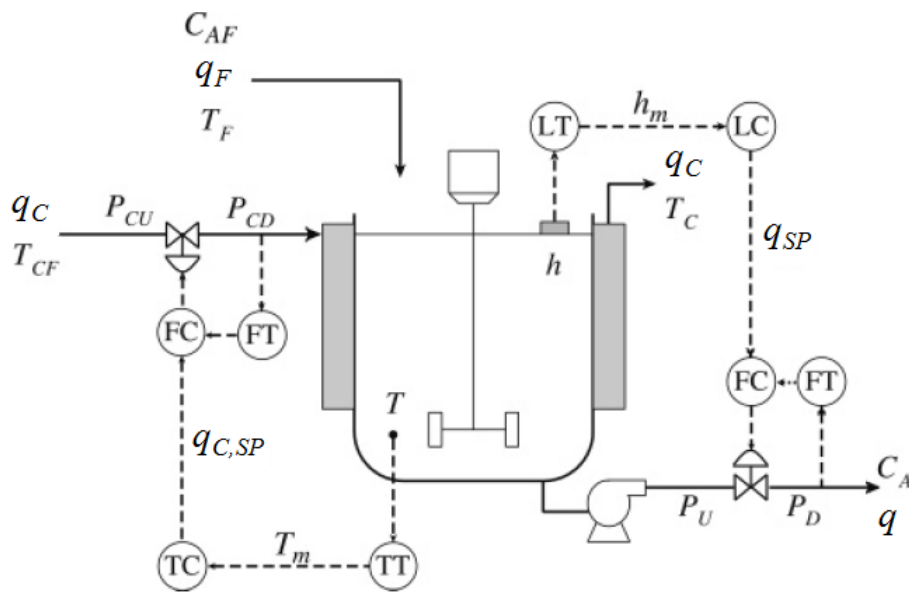


Figura 4.32: CSTR Não Isotérmico (CONNER; SEBORG, 2005).

O conjunto de Equações (4.24) representa o modelo observado na Figura (4.32):

$$\begin{aligned}
\frac{dh}{dt} &= \frac{q_F - q}{A} \\
\frac{dC_A}{dt} &= \frac{1}{Ah}(q_F C_{AF} - q C_A) - k_0 C_A e^{\left(\frac{-E}{RT}\right)} \\
\frac{dT}{dt} &= \frac{1}{Ah}(q_F T_F - q T) + \frac{U A_C}{\rho C_p Ah}(T_C - T) + \frac{-\Delta H}{\rho C_p} C_A k_0 e^{\left(\frac{-E}{RT}\right)} \\
\frac{dT_C}{dt} &= \frac{q_C}{V_C}(T_{CF} - T_C) + \frac{U A_C}{\rho_C C_{pC} V_C}(T - T_C)
\end{aligned} \tag{4.24}$$

Os símbolos e as unidades estão descritos na Tabela (4.7).

Tabela 4.7: Símbolos e unidades do CSTR Não-isotérmico.

h = Nível no CSTR (dm)
q_F = Vazão de entrada no CSTR (L/min)
q = Vazão de saída do CSTR (L/min)
q_C = Vazão de líquido refrigerante na jaqueta (L/min)
A = Área de seção transversal do CSTR (dm^2)
T = Temperatura do CSTR (K)
T_F = Temperatura da corrente de entrada no CSTR (K)
ΔH = Entalpia de reação (J/mol)
C_p = Capacidade calorífica do líquido no CSTR ($J/g/K$)
C_{pc} = Capacidade calorífica do líquido na jaqueta ($J/g/K$)
C_A = Concentração de A no CSTR (mol/L)
C_{AF} = Concentração de A na alimentação (mol/L)
k_0 = Fator de reação (min^{-1})
E = Energia de ativação (J/mol)
R = Constante universal dos gases ($J/mol/K$)
U = Coeficiente de transferência de calor ($J/min/K/dm^2$)
A_C = Área de troca térmica (dm^2)
T_C = Temperatura do fluido de resfriamento na jaqueta (K)
T_{CF} = Temperatura de alimentação do fluido refrigerante (K)
ρ = Densidade do líquido no CSTR (g/L)
ρ_C = Densidade do fluido de resfriamento (g/L)

As variáveis de estado são: o nível do líquido do CSTR (h), Concentração de A no CSTR (C_A), temperatura do CSTR (T) e temperatura da jaqueta (T_C), as variáveis manipuladas são: vazão de saída do CSTR (q) e vazão de fluido refrigerante na jaqueta (q_C) e as variáveis de saída são: O nível de líquido do CSTR (h) e a temperatura do CSTR (T).

A Tabela (4.8) apresenta os valores das variáveis em estado estacionário.

O sistema de controle de nível (h) e temperatura (T), como observado na Figura (4.32) é do tipo PI, com os seguintes parâmetros: $K_C = -3$, $\tau_I = 1,5 \text{ min}$ e $K_C =$

Tabela 4.8: Valores nominais da variáveis para o CSTR.

$h = 6,0 \text{ dm}$	$\rho_C C_{pc} = 4175 \text{ J/L/K}$
$q_F = 100 \text{ L/min}$	$C_A = 0,0372 \text{ mol/L}$
$q = 100 \text{ L/min}$	$C_{AF} = 1,0 \text{ mol/L}$
$q_C = 15 \text{ L/min}$	$k_0 = 7,2 \times 10^{10} \text{ min}^{-1}$
$A = 16,66 \text{ dm}^2$	$E/R = 8750 \text{ K}$
$T = 402,35 \text{ K}$	$UA_C = 5 \times 10^4 \text{ J/min/K/dm}^2$
$T_F = 320 \text{ K}$	$T_C = 345,44 \text{ K}$
$\Delta H = -5 \times 10^4 \text{ J/mol}$	$T_{CF} = 300 \text{ K}$
$\rho C_p = 239 \text{ J/L/K}$	$V_C = 10 \text{ L}$

-0,2, $\tau_I = 0,3 \text{ min}$, manipulando as variáveis q e q_C , respectivamente.

Para ilustrar a aplicação dos métodos apresentados na Seção 2.4 foram criados 2 cenários:

- falha 1 \Rightarrow considerada uma perturbação de carga após 20 min , através de uma mudança degrau na concentração de entrada do reagente (C_{AF}) no CSTR, que inicialmente era $1,0 \text{ mol/L}$ e após a perturbação, passou para $0,92 \text{ mol/L}$. As Figuras (4.33) e (4.34) mostram o comportamento do sistema de controle perante a Falha 1. Notou-se que o controlador da temperatura (T) do CSTR foi capaz de compensar a mudança na concentração de entrada do reagente, porém a variável manipulada q_C passou a operar em outra região para compensar a alteração no processo;
- falha 2 \Rightarrow considerada uma falha no sensor de nível do CSTR após 20 min , provocada pela danificação do instrumento, ocasionando uma medida incorreta de 3% menor que a última medida correta. As Figuras (4.35) e (4.36) mostram o comportamento do sistema de controle perante a Falha 2. Notou-se que a falha do sensor provocou uma instabilidade na malha de controle, por causa da informação incorreta do sensor e nem foi possível que as variáveis manipuladas operassem em outra região, para compensar a falha do sensor.

Utilizou-se neste trabalho, a técnica DPCAm (Análise dos Componentes Principais Dinâmica) descrito na Seção 3.5.1 para o processo de detecção das falhas 1 e 2, e que depende dos dados experimentais, oriundos de condições operacionais normais, ou seja, sem falhas. Estes dados são tratados fora de linha com o objetivo de obter as informações essenciais para a detecção de uma falha em tempo real.

Para este exemplo, os dados foram obtidos através do sistema controlado por um PI regulador, em torno dos pontos estacionários projetados. As Figuras (4.37),




Figura 4.33: Simulação da Falha 1 - Comportamento de h e q .




Figura 4.34: Simulação da Falha 1 - Comportamento de T e q_C .




Figura 4.35: Simulação da Falha 2 - Comportamento de h e q .




Figura 4.36: Simulação da Falha 2 - Comportamento de T e q_C .

(4.38) e (4.39) mostram os dados de operação em condições normais para o CSTR Não-isotérmico em torno dos pontos estacionários projetados para as variáveis controladas (h e T), manipuladas (q e q_C) e as outras variáveis de estado (C_A e T_C).

O conjunto de dados experimentais é composto pelas variáveis:

- nível de líquido no CSTR (h);
- temperatura do CSTR (T);
- concentração da espécie A no CSTR (C_A);
- temperatura da jaqueta (T_C);
- vazão de saída do CSTR (q);
- vazão de fluido refrigerante na jaqueta (q_C).




Figura 4.37: Dados normais para h e q .

Utilizou-se a técnica da análise paralela, descrito na Seção 2.4.2 para determinar o número de dimensões a serem retiradas do modelo PCA, totalizando 3, sendo que este exemplo possui 6 variáveis medidas, então $a = 3$. A variância percentual cumulativa (CPV), calculada a partir da Equação (2.98), foi de 95,82%.

Através da Equação (3.33) a matriz de dados é construída com 2 atrasos ($g = 2$), sendo que a utilização da técnica DPCAm, faz com que a dimensão de \mathbf{X} aumente,




Figura 4.38: Dados normais para T e q_C .




Figura 4.39: Dados normais para C_A e T_C .

como por exemplo, para os dados de operação normal, são 6 variáveis medidas com 3 instantes de atraso, e com 1001 observações (1001 amostras) para cada variável, fazendo com que a dimensão de $\mathbf{X} \in \mathbb{R}^{999 \times 18}$.

Para a detecção das falhas 1 e 2, foram utilizadas as estatísticas T^2 semelhante a Equação (3.27), porém, agora com g atrasos, como observado na Equação (4.25), e que leva em consideração somente os maiores valores característico, e também a estatística Q através da Equação (3.31), que é o monitoramento das variáveis aleatórias, considerando os valores característicos descartados pela análise paralela. Ambas as técnicas estão descritas na Seção 3.5.1.

$$T^2 = x_g^T P \Sigma_a^{-2} P^T x_g \quad (4.25)$$

A Figura (4.40) mostra a estatística T^2 e Q aplicadas aos dados experimentais. Nota-se que as estatísticas encontram-se abaixo dos limites especificados para a indicação de falha, calculados pelas Equações (3.29) e (3.32), respectivamente. Definiu-se também uma região de alarme, com um limite de 10% superior do calculado (T_α^2 , Q_α) pelas Equações (3.29) e (3.32). As Figuras (4.41) e (4.42) mostram as estatísticas T^2 e Q para as falhas 1 e 2, respectivamente. Notou-se que no instante em que foi simulado as falhas, (após 20 *min*) os métodos conseguiram indicar a presença de falha, pois as estatísticas T^2 e Q ficaram bem superiores aos limites T_α^2 e Q_α , comprovando a eficiência das técnicas.




Figura 4.40: Estatísticas T^2 e Q para os dados de operação normal.




Figura 4.41: Estatísticas T^2 e Q para a Falha 1 no CSTR Não-isotérmico.




Figura 4.42: Estatísticas T^2 e Q para a Falha 2 no CSTR Não-isotérmico.

4.4.2 CSTR em série

Seja o mesmo exemplo dos reatores em série, apresentado na Seção 4.2.2. Assim como a seção anterior, para ilustrar a aplicação dos métodos apresentados na Seção 2.4, também foram criados 2 senários:

- falha 1 \Rightarrow considerada uma perturbação de carga após 2 horas, através de uma mudança degrau na vazão de reciclo (F_R) no CSTR 1, que inicialmente era $1,4158 \text{ m}^3/\text{h}$ e após a perturbação, passou para $1,3025 \text{ m}^3/\text{h}$. As Figuras (4.43), (4.44) e (4.45) mostram o comportamento do sistema de controle perante a Falha 1. Notou-se que o controlador foi capaz de compensar a mudança na vazão de reciclo (F_R), porém as variáveis manipulada passaram a operar em outra região para compensar a alteração no processo;
- falha 2 \Rightarrow considerada uma falha no sensor de temperatura do CSTR 2 após 2 horas, provocada pela danificação do instrumento, ocasionando uma medida incorreta de 0,1% maior que a última medida correta. As Figuras (4.46), (4.47) e (4.48) mostram o comportamento do sistema de controle perante a Falha 2. Notou-se que a falha do sensor de temperatura do CSTR 2 provocou uma instabilidade na malha de controle, por causa da informação incorreta do sensor e nem foi possível que as variáveis manipuladas operassem em outra região, para compensar a falha do sensor.




Figura 4.43: Simulação da Falha 1 - Comportamento de C_{A2} e C_{A0} .




Figura 4.44: Simulação da Falha 1 - Comportamento de T_1 e T_{j10} .




Figura 4.45: Simulação da Falha 1 - Comportamento de T_2 e T_{j20} .




Figura 4.46: Simulação da Falha 2 - Comportamento de C_{A2} e C_{A0} .




Figura 4.47: Simulação da Falha 2 - Comportamento de T_1 e T_{j10} .




Figura 4.48: Simulação da Falha 2 - Comportamento de T_2 e T_{j20} .

Utilizou-se também, a técnica DPCAm (Análise dos Componentes Principais Dinâmica) descrito na Seção 3.5.1 para o processo de detecção das falhas 1 e 2, e que depende dos dados experimentais, oriundos de condições operacionais normais, ou seja, sem falhas.

Estes dados também foram tratados fora de linha com o objetivo de obter as informações essenciais para a detecção de uma falha em tempo real.

Para este exemplo, os dados foram obtidos através do sistema controlado por um PI regulador, em torno dos pontos estacionários projetados.

As Figuras (4.49), (4.50) e (4.51) mostram os dados de operação em condições normais para os CSTRs em série, em torno dos pontos estacionários projetados para as variáveis controladas (C_{A2} , T_1 e T_2), manipuladas (C_{A0} , T_{j10} e T_{j20}).

O conjunto de dados experimentais é composto pelas variáveis:

- concentração de A no CSTR 2 (C_{A2});
- temperatura no CSTR 1 (T_1);
- temperatura no CSTR 2 (T_2);
- concentração de A no CSTR 1 (C_{A1});
- temperatura da jaqueta no CSTR 1 (T_{j1});

- temperatura da jaqueta no CSTR 2 (T_{j2});
- vazão de alimentação (F_0);
- temperatura do fluido na entrada jaqueta no CSTR 1 (T_{j10});
- temperatura do fluido na entrada jaqueta no CSTR 2 (T_{j20}).




Figura 4.49: Dados normais para C_{A2} e C_{A0} .

Utilizou-se também neste exemplo, a técnica da análise paralela, descrito na Seção 2.4.2 para determinar o número de dimensões a serem retiradas do modelo PCA, totalizando 3, sendo que este exemplo possui 9 variáveis medidas, então $a = 6$. A variância percentual cumulativa (CPV), calculada a partir da Equação (2.98), foi de 99,54%.

Através da Equação (3.33) a matriz da dados é construída com 2 atrasos ($g = 2$), sendo que a utilização da técnica DPCAm, faz com que a dimensão de \mathbf{X} aumente, por exemplo, para os dados de operação normal, são 9 variáveis medidas com 2 instantes de atraso, e com 1800 observações (1800 amostras) para cada variável, fazendo com que a dimensão de $\mathbf{X} \in \mathbb{R}^{1798 \times 27}$.

Para a detecção das falhas 1 e 2, foram utilizadas as estatísticas T^2 semelhante a Equação (3.27), porém, agora com g atrasos, como observado na Equação (4.25) do exemplo anterior, e que leva em consideração somente os maiores valores característico, e também a estatística Q através da Equação (3.31), que é o monitora-




Figura 4.50: Dados normais para T_1 e T_{j10} .




Figura 4.51: Dados normais para T_2 e T_{j20} .

mento das variáveis aleatórias, considerando os valores característicos descartados pela análise paralela. Ambas as técnicas estão descritas na Seção 3.5.1.

A Figura (4.52) mostra a estatística T^2 e Q aplicadas aos dados experimentais. Nota-se que as estatísticas encontram-se abaixo dos limites especificados para a indicação de falha, calculados pelas Equações (3.29) e (3.32), respectivamente. Definiu-se também a região de alarme, com um limite de 10% superior do calculado (T_α^2 , Q_α) pelas Equações (3.29) e (3.32). As Figuras (4.53) e (4.54) mostram as estatísticas T^2 e Q para as falhas 1 e 2, respectivamente. Notou-se como no exemplo anterior, que no instante em que foi simulado as falhas, (após 2 horas) os métodos conseguiram indicar a presença de falha, pois as estatísticas T^2 e Q ficaram bem superiores aos limites T_α^2 e Q_α , comprovando a eficiência das técnicas.




Figura 4.52: Estatísticas T^2 e Q para os dados de operação normal.




Figura 4.53: Estatísticas T^2 e Q para a Falha 1 no CSTR Não-isotérmico.




Figura 4.54: Estatísticas T^2 e Q para a Falha 2 no CSTR Não-isotérmico.

4.5 Metodologia para o monitoramento

Os casos estudados neste capítulo são bastante representativos do ponto de vista da indústria química, pois os mesmos envolveram processos reativos, de separação, envolvendo fenômenos de transporte e termodinâmica. Os casos escolhidos representam também o maior grau de dificuldade para a aplicação dos métodos para o monitoramento de sistemas controlados, justificando a escolha dos casos estudados.

Monitorar de forma geral os sistemas de controle na indústria química não é uma tarefa fácil. As ferramentas apresentadas neste trabalho, nos dá a capacidade de realizar esta tarefa.

De forma sistemática e contínua, a metodologia proposta consiste em supervisionar o índice de desempenho (η), comparando-o com um valor desejado e que seja satisfatório ao sistema monitorado. Se o índice de desempenho não for mais satisfatório, isso indica que há degradação no sistema de controle e alguma ação deve ser tomada. Como ainda não se sabe a causa da perda do desempenho, o objetivo então é conhecê-la, desta forma, pode-se utilizar as técnicas apresentadas neste trabalho para descobrir se a causa pode estar relacionada com presença de oscilações, emperramento de válvulas, falhas ou mudanças paramétricas no modelo da planta e que o controlador já ficou obsoleto.

Nas próximas seções, serão apresentados com mais detalhes esta metodologia.

4.5.1 Cálculo do índice de desempenho

Na Seção 4.1 deste capítulo foram estudados 3 casos: Coluna de destilação binária, CSTR isotérmico e tanque para o aquecimento de substâncias. Nos três casos, foram provocados uma mudança paramétrica no modelo a fim de simular uma degradação no sistema de controle.

Como foi observado nos três casos estudados, o índice de desempenho (η) caiu ao longo das mudanças paramétricas no modelo, indicando a degradação do sistema de controle. Como não se sabe a causa desta degradação, utiliza-se as ferramentas apresentadas no Capítulo 3 para identificar a causa do problema.

Aplicando a análise Karhunen-Loève e periodograma apresentada na Seção 3.3.1, nota-se que não há oscilações no processo, desta forma, passa-se adiante para a próxima ferramenta, aplicando o método de Yamashita, apresentado na Seção 3.4, para a identificação do emperramento de válvulas, e nota-se também que não há em-

emperramento em válvulas do processo. Aplica-se agora a ferramenta para detecção de falhas, utilizando a PCA e estatísticas T^2 e Q , apresentados nas Seções 2.4 e 3.5.1, notando-se também que não há o indicativo de falhas no sistema. Desta forma, pode-se perceber que a causa da degradação do sistema de controle pode estar relacionada à sintonia ou estrutura de controle inadequada ao processo corrente, assim, a próxima ação, seria realizar uma nova sintonia e em segundo plano, projetar uma nova estrutura de controle.

4.5.2 Detecção de oscilações

Na Seção 4.2 deste capítulo foram estudados 2 casos: Sinais sintéticos com o objetivo de apenas demonstrar a aplicabilidade da técnica de detecção de oscilações e o caso dos reatores em série.

Seguindo a mesma metodologia, para o caso dos reatores em série, em um determinado instante de operação o índice de desempenho que era satisfatório cai para $\eta = 0,019$, bem distante do valor desejado ($\eta \simeq 1$).

Aplicando a análise Karhunen-Loève e periodograma apresentada na Seção 3.3.1, nota-se que há presença de oscilações no processo, e uma das causas de oscilações é o emperramento de válvulas, desta forma, passa-se adiante para a próxima ferramenta, aplicando o método de Yamashita, apresentado na Seção 3.4, para a identificação do emperramento de válvulas, e nota-se que não há emperramento em válvulas do processo. Aplica-se agora a ferramenta para detecção de falhas, utilizando a PCA e estatísticas T^2 e Q , apresentados nas Seções 2.4 e 3.5.1, notando-se também que não há o indicativo de falhas no sistema. Desta forma, pode-se perceber que a causa da degradação do sistema de controle está relacionada à presença de oscilações, e que não se relaciona com o emperramento de válvulas, assim, deve-se verificar a sintonia dos controladores, que estando em situação adequada, pode-se projetar um filtro para atenuar as oscilações indesejadas.

4.5.3 Detecção do emperramento de válvulas

Na Seção 4.3 deste capítulo foi estudado o caso da coluna de destilação de alta pureza.

Seguindo a mesma metodologia, em um determinado instante de operação o índice de desempenho que era satisfatório cai para $\eta = 0,38$, não correspondendo

ao valor desejado ($\eta \simeq 1$).

Aplicando a análise Karhunen-Loève e periodograma apresentada na Seção 3.3.1, nota-se que há presença e oscilações no processo, e novamente, uma das causas de oscilações é o emperramento de válvulas, desta forma, passa-se adiante para a próxima ferramenta, aplicando o método de Yamashita, apresentado na Seção 3.4, para a identificação do emperramento de válvulas, e nota-se que há emperramento e uma válvulas do processo, explicando a presença de oscilações. Aplica-se agora a ferramenta para detecção de falhas, utilizando a PCA e estatísticas T^2 e Q , apresentados nas Seções 2.4 e 3.5.1, notando-se que não há o indicativo de falhas no sistema. Desta forma, pode-se perceber que a causa da degradação do sistema de controle está relacionada com o emperramento da válvula, assim, deve-se realizar a manutenção da válvula, ou em caso extremo, efetuar a troca do elemento final de controle.

4.5.4 Detecção de falhas: perturbações e sensores

Na Seção 4.4 deste capítulo foram estudados 2 casos: CSTR não-isotérmico e o mesmo caso dos reatores em série apresentado na Seção 4.2.

Em ambos os casos, forma provocados aos sistemas, dois tipos de falhas: falha 1, considerada uma perturbação de carga e falha 2, considerada uma falha em um sensor.

Seguindo a mesma metodologia, em um determinado instante de operação, no caso do CSTR não-isotérmico, o índice de desempenho que era satisfatório cai para $\eta = 0,0017$ para a falha 1 e $\eta = 4,8 \times 10^{-6}$ para a falha 2, bem distante do valor desejado ($\eta \simeq 1$). O mesmo resultado se repete para o caso dos reatores em série, o índice de desempenho que era satisfatório cai para $\eta = 0,56$ para a falha 1 e $\eta = 5,8 \times 10^{-6}$ para a falha 2.

Aplicando a análise Karhunen-Loève e periodograma apresentada na Seção 3.3.1, nota-se que não há oscilações no processo, desta forma, passa-se adiante para a próxima ferramenta, aplicando o método de Yamashita, apresentado na Seção 3.4, para a identificação do emperramento de válvulas, e nota-se também que não há emperramento em válvulas do processo. Aplica-se agora a ferramenta para detecção de falhas, utilizando a PCA e estatísticas T^2 e Q , apresentados nas Seções 2.4 e 3.5.1, notando-se que não o indicativo de falhas no sistema para ambos os casos. Desta forma, pode-se perceber que a causa da degradação do sistema de controle pode estar relacionado presença de falhas no sistema, assim, métodos de diagnóstico

e localização das falhas devem ser empregados para a realização de manutenção ou troca de equipamentos que possam estar causando a degradação.

Desta forma, com a metodologia proposta neste trabalho, pode-se então monitorar sistemas de controle na indústria química.

CAPÍTULO 5

Conclusões e Sugestões

5.1 Conclusões

5.1.1 Cálculo do índice de desempenho

Apesar da grande utilização do controle de variância mínima (MVC), ele também apresenta pontos negativos, os quais foram abordados no Exemplo 4.1.2, da Seção 4.1 do Capítulo 3 desta Tese. Desta forma, a técnica GIM é considerada como alternativa ao uso do MVC, como referência na determinação do índice de desempenho.

O índice de desempenho fornece a ideia do quanto o controle corrente do sistema está distante do melhor controle idealizado com mesma estrutura. Devido as características do comportamento de referência, que independe da estrutura de controle utilizada, pode-se avaliar controladores de diversos tipos e sob várias situações.

Quanto mais o índice de desempenho de um sistema de controle, η , se aproxima de 1 (um), tem-se que o controle corrente é uma boa escolha para o sistema e está tendo comportamento aproximadamente equivalente àquele do sistema de referência. Duas situações podem acontecer para que isso seja verdadeiro: (i) o processo em análise não possui fatores intrínsecos que possam ser extraídos pela técnica de projeto do comportamento de referência adotado. (ii) o controle adotado

para o processo opera próximo a capacidade máxima atingível para um controlador *feedback* naquele processo.

Quando o índice de interação situa-se conforme $0 < \eta < 1$, então isto indica que o sistema tem degradação de desempenho, mas pode ser sintonizado de forma a apresentar desempenho melhorado, e se não suficiente, outras estruturas de controle devem ser consideradas. É importante se salientar que, nem todas as estruturas de controle podem eficientemente responder a essa deficiência e então, o projetista deve colocar um parâmetro, considerado como aceitável, que baseia-se nas condições nominais de projeto para o sistema.

Quando o controlador possui desempenho superior ao do modelo de referência, $\eta > 1$, então, isto indica que o sistema de referência foi pobremente projetado, devendo-se então, recorrer a novas técnicas para estabelecer a referência. Isso pode acontecer, quando se utiliza-se uma fatoração que prioriza determinadas saídas que não são as desejadas para o processo.

Como observado na Seção 4.1, pode-se concluir que a metodologia GIM utilizada para o cálculo do índice de desempenho é válida, pois, tanto no ponto de vista físico, no qual se trata de uma referência realizável, quanto do ponto de vista teórico, que ao realizar a fatoração, extrai-se possíveis invariantes, tornando o sistema mais fácil de ser controlado, e então servindo como referência para o cálculo do índice de desempenho. Somado a isso, a técnica pode ser aplicada a qualquer algoritmo de controle, pois o comportamento de referência é característica unicamente do processo e da escolha de fatoração adotada no projeto. Assim, independente da estrutura de controle, a metodologia GIM pode ser aplicada para qualquer realidade industrial presente ou futura.

Considerando-se a necessidade do modelo da planta, conclui-se também, que é um ponto negativo da metodologia GIM.

A aplicação da metodologia GIM em modelos da planta de fase não-mínima, gera modelos de referência idênticos ao modelo do processo, sendo uma característica do método.

No Exemplo 4.1.3, após a normalização dos índices, apenas o comportamento do índice RVI não obedeceu à similaridade que houve entre os demais, devido ao fato de o mesmo levar em consideração a variabilidade da saída do sistema em malha aberta, entretanto, dentro do ponto de vista teórico, todas as técnicas apresentadas neste trabalho dão a ideia de degradação do sistema de controle ao longo do tempo, e satisfaz a necessidade de monitorar continuamente sistemas de controle.

É possível, inclusive, se utilizar a mesma metodologia GIM para se isolar malhas que não estejam funcionando adequadamente, bastando para isso, se ordenar a saída em análise de forma a se observar com máxima importância. A falta de desempenho nessa variável, desacoplada dos invariantes, é indicativo de problema naquela parte do processo, ou resultante de falha de equipamentos, projeto ou mesmo de sintonia.

5.1.2 Detecção de oscilações

Neste trabalho, mostrou-se a adequabilidade da técnica aplicada para a detecção de oscilações, a casos em que não existam transições operacionais no processo. Do contrário, novas técnicas de localização das oscilações devem ser estudadas.

Os resultados obtidos foram satisfatórios e conseguiu-se detectar a presença de oscilação nos sinais de saída dos casos estudados, bem como a localização das mesmas, sendo assim, ficando comprovada a eficiência da técnica, ao aplicar-se em sistemas de grandes dimensões e que não possuam transições operacionais.

A metodologia é bastante simples e eficiente. Pode ser aplicada na indústria para os sistemas de monitoramento automático de processo, que pode levar a informações muito importantes para avaliação de problemas de sintonia de controladores, problemas de agarramento (emperramento de válvulas) ou mesmo detecção de perturbações oscilatórias no processo.

5.1.3 Detecção do emperramento de válvulas

Foi utilizado o Método de Yamashita para a detecção do emperramento de válvulas, porque ficou comprovado que este é o mais seguro e de fácil implementação, apesar de requerer informações da posição da válvula (JELALI; HUANG, 2010).

Ficou também comprovado que o método é muito sensível à presença de ruídos, pois, na avaliação da taxa de sucesso do método, 78,4% dos emperramentos foram detectados quando estes existiam, 21,6% dos emperramentos não foram detectados quando estes existiam, 0% dos emperramentos foram detectados quando estes não existiam e 100% dos emperramentos não foram detectados quando estes não existiam. Os resultados obtidos podem ser explicados pelo acréscimo de ruídos aleatórios nos dados analisados.

5.1.4 Detecção de falhas: perturbações e sensores

Os exemplos apresentados na Seção 4.4 mostraram com clareza a eficiência nos métodos estudados neste trabalho para a indicação de falhas.

As estatísticas T^2 e Q são as ferramentas mais utilizadas para o monitoramento de plantas, com o objetivo de detectar falhas. Uniu-se também neste trabalho, a utilização da Análise dos Componentes Principais (PCA), com o objetivo de mostrar a técnica para reduzir as dimensões de modelos, devido à grande informação de dados operacionais oriundos de processos industriais. O número de componentes principais foi obtido através da análise paralela, e que teve sua aplicação comprovada nos exemplos estudados.

5.1.5 Contribuições

São considerados fatores de contribuição deste trabalho:

- a extensão do trabalho de Souza (2007) no cálculo do índice de desempenho, que anteriormente o projeto do sistema de referência era realizado em malha aberta, e posteriormente o método foi estendido ao projeto do sistema de referência em malha fechada. Sendo comprovada sua eficiência, o método proposto, através da fatoração de modelos lineares, foi comparado com os métodos mais utilizados na literatura;
- com o objetivo de tornar a localização automática de oscilações em plantas químicas, foi realizada uma análise estatística da variabilidade dos sinais de saída da planta, comparando-se a média da variância de cada variável medida, com o ponto médio entre a máxima e a mínima variância de cada variável medida. Esta análise, substitui a necessidade do conhecimento específico da planta proposto inicialmente por Odgaard e Wickerhauser (2007);
- criar um gerenciador de desempenho que contenha em seu banco de dados as técnicas mais simples e seguras encontradas na literatura para a detecção de oscilações, emperramento de válvulas, falhas e presença de oscilações na indústria química.

5.1.6 Publicações

Ao longo deste trabalho, foram realizadas as seguintes publicações:

SOUZA, D. L.; OLIVEIRA-LOPES, L. C. Limites de desempenho de sistemas controlados baseados em dados de operação entrada/saída. In: COBEQ-2008. Recife, PE, 2008.

SOUZA, D. L.; OLIVEIRA-LOPES, L. C. Análise do desempenho de sistemas de controle baseada em dados de operação em malha fechada. In: SNCA. Salvador, BA, 2009.

SOUZA, D. L.; OLIVEIRA-LOPES, L. C. Detecção de oscilações em sistemas de controle. In: COBEQ-2010. Foz do Iguaçu, PR, 2010.

SOUZA, D. L.; OLIVEIRA-LOPES, L. C. A novel controller performance index using a local process model factorization. Journal of Dynamic Systems, Measurement and Control, 2011 (Submetido).

SOUZA, D. L.; OLIVEIRA-LOPES, L. C. Detection of valve stiction in process control loops using a yamashita modified method. In: CHEMPOR. Lisboa, Portugal, 2011a.

SOUZA, D. L.; ALMEIDA, G. M.; OLIVEIRA-LOPES, L. C. Methodology for fault detection in chemical processes control. In: CHISA. Praga, República Tcheca, 2011b (submetido).

5.2 Sugestões

Para dar continuidade ao estudo e aplicação realizados neste trabalho, segue algumas sugestões para trabalhos futuros:

- desenvolver um índice de desempenho de sistemas de controle que incorpore a robustez na seleção do comportamento de referência;
- investigar a aplicação de métodos de detecção do estado estacionário;
- investigar a aplicação de métodos de detecção de oscilações em plantas com transições operacionais;
- desenvolver uma única ferramenta que seja capaz de realizar o monitoramento *online* e que incorpore os métodos apresentados neste trabalho;

- desenvolver estratégias para a avaliação da capacidade de controle e de estruturas de controle multivariáveis incorporando incertezas do modelo e avaliar o efeito do erro do modelo no projeto do comportamento de sistemas de referência.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALKAYA, A.; EKER, I. Variance sensitive adaptive threshold-based pca method for fault detection with experimental application. *ISA Transactions*, v. 50, p. 287–302, 2011.
- BENDER, M. *Auswahl, Implementierung Und Test Von Algorithmen Zur Bewertung Der Güte Von Reglern*. Tese (Doutorado) — Bfi/University Of Cologne, Germany, 2003.
- BEQUETTE, B. W. *Process Dynamics - Modeling, Analysis and Simulation*. New Jersey: Prentice Hall, 1998. (Prentice Hall International Series).
- BEZERGIANNI, S.; GEORGAKIS, C. Controller performance assessment based on minimum and open-loop output variance. *Chem. Eng. Practice*, v. 8, p. 791–797, 2000.
- BJÖRKLUND, S. *A Survey And Comparison Of Time Delay Estimation Methods In Linear Systems*. Tese (Doutorado) — Lund Institute Of Technology, Sweden, 2003.
- CHIANG, L. H.; RUSSEL, E. L.; BRAATZ, R. D. *Fault Detection And Diagnosis In Industrial Systems*. Book: Springer, 2001.
- CHITRALEKHA, S.; SHAH, S.; PRAKASH, J. Detection and quantification of valve stiction by the method of unknown input estimation. *Journal of Process Control*, 2010.
- CHOUDHURY, M.; THORNHILL, N.; SHAH, S. Modelling valve stiction. *Control Engineering Practice*, 2004.

- CHOUDHURY, M.; THORNHILL, N.; SHAH, S. Modelling valve stiction. *Control Engineering Practice*, v. 13, p. 641–658, 2005.
- CHOUNDHURY, M. A. A. S.; SHAH, S. L.; THORNHILL, N. F. Detection and diagnosis of system nonlinearities using higher order statistics. *Automatica*, v. 40, p. 1719–1728, 2004.
- CHU, C. C. On discrete innerouter and spectral factorizations. In: IN AMERICAN CONTROL CONFERENCE. USA, 1988.
- CONNER, J. S.; SEBORG, D. E. Assessing the need fo process re-identification. *Ind. Eng. Chem. Res.*, v. 44, p. 2767–2775, 2005.
- DESBOROUGH, L.; HARRIS, T. Performance assessment measures for univariate feedback control. *Can. J. Chem. Eng.*, v. 70, p. 1186–1197, 1992.
- DESBOROUGH, L.; HARRIS, T. Performance assessment measures for univariate feedforward/feedback control. *Canadian Journal Of Chemical Engineering*, v. 71, p. 605–616, 1993.
- DESBOROUGH, L.; MILLER, R. Increasing customer value of industrial control performance monitoring-honeywell’s experience. In: AICHE. Symposium Series, 2002.
- DEVRIES, W.; WU, S. Evaluation of process control effectiveness and diagnosis of variation in paper basis weight via multivariate time series analysis. *IEEE Trans. Auto. Cont.*, v. 23, p. 702–708, 1978.
- DING, S. et al. On the application of pca technique to fault diagnosis. *TSINGHUA SCIENCE AND TECHNOLOGY*, v. 15, p. 138–144, 2010.
- DITTMAR, R.; BEBAR, M.; REINIG, G. Control loop performance monitoring: Motivation, methoden, anwendungswünsche. *Automatisierungstechnische Praxis*, v. 45, p. 94–103, 2003.
- DUMONT, G. A.; KAMMER, L.; ALLISON, B. J.; ETTALEB, L.; ROCHE, A. Control performance monitoring: New developments and practical issues. In: PROCEEDINGS OF THE IFAC WORLD CONGRESS. Barcelona, Spain, 2002.
- ETTALEB, L. *Control Loop Performance Assessment And Oscillation Detection*. Tese (Doutorado) — University Of British Columbia, Canada, 1999.

- FORSMAN, K.; STATIN, A. A new criterion for detecting oscillations in control loops. In: IN PROCEEDINGS OF THE EUROPEAN CONTROL CONFERENCE. Karlsruhe, Germany, 1999.
- GRIMBLE, M. J. Controller performance benchmarking and tuning using generalised minimum variance control. *Automatica*, v. 38, p. 2111–2119, 2002.
- HAARSMA, G.; NIKOLAOU, M. Multivariate controller performance monitoring: Lessons from an application to snack food process. URL: <http://www.chee.uh.edu/faculty/nikolaou/fryermonitoring.pdf>, Último acesso em 15.04.2006, 2003.
- HÄGGLUND, T. A control-loop performance monitor. *Control Engineering Practice*, v. 3, p. 1543–1551, 1995.
- HARRIS, T. Assessment of closed loop performance. *Canadian Journal Of Chemical Engineering*, v. 67, p. 856–861, 1989.
- HARRIS, T.; BOURDREAU, F.; MACGREGOR, J. Performance assessment for multivariate feedback controllers. *Automatica*, v. 32, p. 1505–1518, 1996.
- HARRIS, T.; SEPPALA, C. T. Recent developments in performance monitoring and assessment techniques. Tucson, USA, 2001.
- HARRIS, T.; SEPPALA, C. T.; DESBOROUGH, L. D. A review of performance monitoring and assessment techniques for univariate and multivariate control systems. *Journal Of Process Control*, v. 9, p. 1–17, 1999.
- HE, Q.; WANG, J.; POTTMANN, M.; QIN, S. A curve fitting method for detecting valve stiction in oscillating control loops. *Ind. Eng. Chem. Res.*, v. 46, p. 4549–4560, 2007.
- HOO, K. A.; PIOVOSO, M. J.; SCHNELLE, P. D.; ROWAN, D. A. Process and controller performance monitoring: Overview with industrial applications. *International Journal Of Adaptive Control And Signal Processing*, v. 17, p. 635–662, 2003.
- HORCH, A. A simple method for detection of stiction in control valves. *Control Engineering Practice*, v. 7, p. 1221–1231, 1999.
- HORCH, A. *Condition Monitoring Of Control Loops*. Tese (Doutorado) — Royal Institute Of Technology, Stockholm, Sweden, 2000.

- HUANG, B. A pragmatic approach towards assessment of control loop performance. *International Journal Of Adaptive Control And Signal Processing*, v. 17, p. 489–608, 2003.
- HUANG, B.; SHAH, S.; FUJII, H. The unitary interactor matrix and its estimation from closed-loop data. *J. Process Control*, v. 7, p. 195–207, 1997a.
- HUANG, B.; SHAH, S.; KWOK, E. Good, bad, or optimal: Performance assessment of multivariable processes. *Journal of Mathematical Analysis and Applications*, v. 33, p. 1175–1183, 1997b.
- HUANG, B.; SHAH, S. L. Practical issues in multivariable feedback control performance assessment. In: PROCEEDINGS OF THE IFAC ADCHEM. Banff, Canada, 1997.
- HUANG, B.; SHAH, S. L. Performance assessment of control loops. *Chem. Eng. Res. Des.*, Berlin: Springer, 1999.
- HUANG, H. P.; WU, M. C. Monitoring and fault detection for dynamic systems using dynamic pca on filtered data. *Process Systems Engineering*, B. Chen and A.W. Westerberg, p. Published by Elsevier Science B.V., 2003.
- INGIMUNDARSON, A. *Dead-Time Compensation And Performance Monitoring In Process Control*. Tese (Doutorado) — PhD Thesis, Lund Institute Of Technology, Sweden, 2003.
- ISAKSSON, M. *A Comparison Of Some Approaches To Time-Delay Estimation*. Tese (Doutorado) — Royal Institute Of Technology, Stockholm, Sweden, 1997.
- JACKSON, J. *Quality Control Methods For Several Related Variables*. Book: Technometrics, 1959.
- JACKSON, J. *A User's Guide To Principal Components*. Book: Wiley, 1991.
- JACKSON, J. E.; MUDHOLKAR, G. S. Control procedures for residuals associated with principal component analysis. *Technometrics*, v. 21, p. 341–349, 1979.
- JELALI, M. An overview of control performance assessment technology and industrial applications. *Control Engineering Practice*, v. 14, p. 441–466, 2006.
- JELALI, M. Estimation of valve stiction in control loops using separable least-squares and global search algorithms. *Journal Process Control*, v. 18, p. 632–642, 2008.

-
- JELALI, M.; HUANG, B. *Detection and diagnosis of stiction in control loops*. First. New York, USA: AIC - Advances in Industrial Control, 2010.
- JIANG, H.; CHOUDHURY, M.; SHAH, S. Detection and diagnosis of plant-wide oscillations from industrial data using the spectral envelope method. *Journal of Process Control*, v. 17, p. 143–155, 2007.
- JIANG, H.; PATWARDHAN, R.; SHAH, S. Root cause diagnosis of plant-wide oscillations using the concept of adjacency matrix. *Journal of Process Control*, 2009.
- JULIEN, R. H.; FOLEY, M. W.; CLUETT, W. R. Performance assessment using a model predictive control benchmark. v. 14, p. 441–456, 2004.
- KANO, M.; MARUTA, H.; KUGEMOTO, H.; SHIMIZU, K. Practical model and detection algorithm for valve stiction. In: PROC IFAC DYCOPS. Cambridge, USA., 2004.
- KARRA, S.; KARIM, M. Alternative model structure with simplistic noise model to identify linear time invariant systems subjected to non-stationary disturbances. *Journal Process Control*, 2009.
- KO, B.-S.; EDGAR, T. F. Performance assessment of multivariable feedback control systems. *Automatica*, v. 37, p. 899–905, 2001b.
- KOZUB, D.; GARCIA, C. Monitoring and diagnosis of automated controllers in the chemical process industry. In: AICHE ANNUAL MEETING. St. Louis, Mo, 1993.
- KOZUB, D. J. Controller performance monitoring and diagnosis: Experiences and challenges. In: PROCEEDINGS OF THE CHEMICAL PROCESS CONTROL CONFERENCE. Lake Tahoe, USA (Pp. 83-96), 1996.
- KOZUB, D. J. Controller performance monitoring and challenges. In: CPC V PROCEEDINGS. Pp. 83-96, 1997.
- KU, W.; STORER, R.; GEORGAKIS, C. *Disturbance Detection And Isolation By Dynamic Principal Component Analysis*. Book: Chemometrics And Intelligent Laboratory Systems, 1995.
- LI, X.; WANG, J.; HUANG, B.; LU, S. The dct-based oscillation detection method for a single time series. *Journal of Process Control*, 2010.

- LIU, X.; JUTAN, A.; S., R. Almost disturbance decoupling of mimo nonlinear systems and application to chemical processes. *Automatica*, v. 40, p. 465–471, 2004.
- LSERMANN, R. Supervision, fault-detection and fault-diagnosis methods - an introduction. *Control Eng. Practice*, v. 5, p. 639–652, 1997.
- MARUYAMA, N. Uma breve introdução aos sistemas de controle. Notas de Aula, <http://www.poli.usp.br/d/pmr2360/Download>. Último acesso em Junho de 2007.
- MAURATH, P. Predictive controller design by principal component analysis. *Eng. Chem. Res.*, v. 27, p. 1258–1264, 1988.
- MCMILLAN, G. Modeling and control. <http://www.modelingandcontrol.com>, 2009. Último acesso em 01 de abril de 2010.
- MCNABB, C.; QIN, S. Projection based mimo control performance monitoring: I-covariance monitoring in state space. *J. Proc. Cont.*, v. 13, p. 739–757, 2003.
- MCNABB, C.; QIN, S. Projection based mimo control performance monitoring: Ii-measured disturbances and setpoint changes. *J. Proc. Cont.*, v. 15, p. 89–102, 2005.
- MISRA, M.; YUE, H. H.; QIN, S. J.; LING, C. Multivariate process monitoring and fault diagnosis by multi-scale pca. *Computers and Chemical Engineering*, v. 26, p. 1281–1293, 2002.
- MITCHELL, W.; SHOOK, D. E.; SHAH, S. L. A picture worth a thousand control loops: An innovative way of visualizing controller performance data. In: INVITED PLENARY PRESENTATION, CONTROL SYSTEMS. Quebec City, 2004.
- MORARI, M.; ZAFIRIOU, E. Robust process control. *Prentice Hall*, 1989.
- ODGAARD, P. F.; WICKERHAUSER, M. V. Karhunen-loève (pca) based detection of multiple oscillations in multiple measurement signals from large-scale process plants. <http://www.math.wustl.edu>, 2007. Último acesso em 01 de abril de 2010.
- OLIVEIRA-LOPES, L. C. *Reference System Nonlinear Model Predictive Control*. Tese (Doutorado) — Lehigh University, USA, 2000.
- ORDYS, A.; CLEGG, A.; XIA, H.; UDUEHI, D. Controller benchmarking: From single loops to plant-wide economic assessment. URL: <http://www.isc-ltd.com>, 2005.

- ORDYS, A. W.; UDUEHI, D.; JOHNSON, M. A. *Process Control Performance Assessment: From Theory to Implementation*. First. London: Springer, 2007. (Advances in Industrial Control, First).
- OWEN, J.; READ, D.; BLEKKENHORST, H.; ROCHE, A. A. A mill prototype for automatic monitoring of control loop performance. In: IN PROCEEDINGS OF THE CONTROL SYSTEMS. Halifax, Canada (Pp. 171-178), 1996.
- PENG, Y.; KINNAERT, M. Explicit solution to the singular lq regulation problem. *IEEE Trans AC*, v. 37, p. 633–636, 1992.
- PIOVOSO, M. J.; KOSANOVICH, K. Monitoring process performance in real time. In: PROCEEDINGS OF THE AMERICAN CONTROL CONFERENCE, IEEE, P. 2359-2363. Piscataway, NJ, 1992.
- PIOVOSO, M. J.; KOSANOVICH, K. Applications of multivariate statistical methods to process monitoring and controller design. *International Journal Of Control*, v. 59, p. 743–765, 1994.
- QIN, S. J. Control performance monitoring-a review and assessment. *Computers and Chemical Engineering*, v. 23, p. 173–186, 1998.
- REIS, L. L. G. *Controle Tolerante com Reconfiguração Estrutural Acoplado a Sistemas de Diagnóstico de Falhas*. Dissertação (Mestrado) — Universidade Federal de Uberlândia-UFU, Faculdade de Engenharia Química-FEQUI, 2008.
- ROGOZISKI, M.; PAPLINSKI, A.; GIBBARD, M. An algorithm for calculation of a nilpotent interactor matrix for linear multivariable systems. *IEEE Trans. Autom. Control*, v. 32, p. 234–237, 1987.
- ROSSI, M.; SCALI, C. A comparison of techniques for automatic detection of stiction: simulation and application to industrial data. *Journal Process Control*, v. 1, p. 505–514, 2005.
- SALSBURY, T.; SINGHAL, A. A new approach for arma pole estimation using higher-order crossings. In: PROC. AM CONTROL CONFERENCE. Portland, USA., 2005.
- SAMY, I.; POSTLETHWAITE, I.; GU, D. W. Survey and application of sensor fault detection and isolation schemes. *Control Eng. Practice*, v. 19, p. 658–674, 2011.
- SCALI, C.; GHELARDONI, C. An improved qualitative shape analysis technique for automatic detection of valve stiction in flow control loops. *Control Engineering Practice*, 2008.

- SHAH, S. L.; PATWARDHAN, R.; HUANG, B. Multivariate controller performance analysis: Methods, applications and challenges. In: IN PROCEEDINGS OF THE CHEMICAL PROCESS CONTROL CONFERENCE. Tucson, Usa (Pp. 187-219), 2001.
- SISTU, P. B.; BEQUETTE, B. W. Model predictive control of processes with input multiplicities. *Chemical Engineering Science*, v. 50, p. 921–936, 1995.
- SOUZA, D. L. *Análise do Desempenho de Sistemas de Controle*. Dissertação (Mestrado) — Universidade Federal de Uberlândia-UFU, Faculdade de Engenharia Química-FEQUI, 2007.
- SOUZA, D. L.; OLIVEIRA-LOPES, L. C. Limites de desempenho de sistemas controlados baseados em dados de operação entrada/saída. In: COBEQ-2008. Recife, PE, 2008.
- SOUZA, D. L.; OLIVEIRA-LOPES, L. C. Análise do desempenho de sistemas de controle baseada em dados de operação em malha fechada. In: SNCA. Salvador, BA, 2009.
- SOUZA, D. L.; OLIVEIRA-LOPES, L. C. Detecção de oscilações em sistemas de controle. In: COBEQ-2010. Foz do Iguaçu, PR, 2010.
- SOUZA, D. L.; OLIVEIRA-LOPES, L. C. A novel controller performance index using a local process model factorization. *Journal of Dynamic Systems, Measurement and Control*, 2011.
- SOUZA, D. L.; OLIVEIRA-LOPES, L. C. Detection of valve stiction in process control loops using a yamashita modified method. In: CHEMPOR. Lisboa, Portugal, 2011a.
- STOGESTAD, S.; MORARI, M. *The dominant time constant for distillation columns*. Book: Comp. Chem. Eng., 1, p.607, 1987.
- TANGIRALA, A.; SHAH, S.; THORNHILL, N. Pscmap: A new tool for plant-wide oscillation detection. *Journal of Process Control*, v. 15, p. 931–941, 2005.
- THAM, M. Minimum variance and generalized minimum variance control algorithms. In: NEWCASTLE UPON TYNE. Ne1 7ru, UK, 1999.
- THORNHILL, N. *Process Control Performance Assessment*. Book: Springer, 2007.
- THORNHILL, N.; HUANG, B.; ZHANG, H. Detection of multiple oscillations in control loops. *Journal of Process Control*, v. 13, p. 91–100, 2003.

- THORNHILL, N. F.; HUANG, B.; SHAH, S. L. Controller performance assessment in set point tracking and regulatory control. *International Journal Of Adaptive Control And Signal Processing*, v. 17, p. 709–727, 2003a.
- THORNHILL, N. F.; OETTINGER, M.; FEDENCZUK, M. S. Refinery-wide control loop performance assessment. *Journal Of Process Control*, v. 9, p. 109–124, 1999.
- TSILIGIANNIS, C. A.; SVORONOS, S. A. Dynamic interactors in multivariable process control i. the general time delay case. *Chemical Engineering Science*, v. 43, p. 339–347, 1988.
- TSILIGIANNIS, C. A.; SVORONOS, S. A. Dynamic interactors in multivariable process control ii. time delays and zeroes outside the unit circle. *Chemical Engineering Science*, v. 44, p. 2041–2047, 1989.
- VARGA, A. Computation of innerouter factorizations of rational matrices. *IEEE Transactions on Automatic Control*, v. 43, p. 684–688, 1998.
- VAUGHT, R.; TIPPET, J. Control performance monitoring: Shaman or saviour - a candid look at what such a system can truly do. *Pulp and Paper Canada*, v. 102, p. 26–29, 2001.
- WISE, B.; GALLAGHER, N. The process chemometrics approach to process monitoring and fault-detection. *Journal Process Control*, v. 6, p. 329–348, 1996.
- WISE, B.; RICKER, N.; VELTKAMP, D. Upset and sensor failure detection in multivariate processes. In: AICHE ANNUAL MEETING. San Francisco, CA., 1989.
- XIA, H.; MAJECKI, P.; ORDYS, A.; GRIMBLE, M. E. Performance assessment of MIMO systems based on I/O delay information. *Journal of Process Control*, v. 16, p. 373–383, 2006.
- YAMASHITA, Y. An automatic method for detection of valve stiction in process control loops. *Control Engineering Practice*, 2006.
- YANG, X. B.; JIN, X. Q.; DU, Z. M.; ZHU, Y. H. A novel model-based fault detection method for temperature sensor using fractal correlation dimension. *Building and Environment*, v. 46, p. 970–979, 2011.
- YUA, W.; WILSON, D. I.; YOUNG, B. R. Control performance assessment for nonlinear systems. *Journal of Process Control*, v. 20, p. 1235–1242, 2010.

- YUAN, Q.; LENNOX, B. Control performance assessment for multivariable systems based on a modified relative variance technique. *Journal of Process Control*, v. 19, p. 489–497, 2009.
- ZHANG, Z.; FREUDENBERG, J. S. Discrete-time loop transfer recovery for systems with nonminimum phase zeros and time delays. *Automatica*, v. 29, p. 351–363, 1993.
- ZHIMIN, D.; XINQIAO, J.; LIZHOU, W. Fault detection and diagnosis based on improved pca with jaa method in vav systems. *Building and Environment*, v. 42, p. 3221–3232, 2007.
- ZUMOFFEN, D.; BASUALDO, M. From large chemical plant data to fault diagnosis integrated to decentralized fault tolerant control: pulp mill process application. *Industrial & Engineering Chemistry Research*, v. 47, p. 1201–1220, 2007.

Apêndice A

Algoritmo para o Cálculo da Matriz de Interação Unitária

Este Apêndice contém os algoritmos propostos por Rogoziski et al. (1987) e Peng e Kinnaert (1992) para o cálculo da matriz de interação unitária.

DEFINIÇÃO A.1: Uma matriz polinomial $n \times n$ $U(q)$ é chamada de matriz de linha trocada (*row shift polynomial matrix* - r.s.p.m.) de ordem k_i , onde

$$U(q) = U_0q + U_1 = \begin{bmatrix} 0 & I_r \\ qI_{k_i} & 0 \end{bmatrix}$$

Com U_0 e U_1 , definidas como:

$$U = \begin{bmatrix} U_0 \\ U_1 \end{bmatrix} = \begin{bmatrix} 0_r \\ I_n \\ 0_{k_i} \end{bmatrix}, \quad n = r + k_i$$

na qual U_0 e U_1 possuem dimensões $n \times n$, I_n é uma matriz identidade $n \times n$ e 0_r é uma matriz de zeros com r -linha.

Como o sistema pode ser escrito na forma RMF (*right matrix fraction*), descrito como:

$$T(q^{-1}) = N(q)R^{-1}(q)$$

com

$$N(q) = N_0q^p + N_1q^{p-1} + \dots + N_p \quad (5.1)$$

Podendo ser representado pela matriz de seus coeficientes:

$$\Lambda = \begin{bmatrix} N_0 \\ \vdots \\ N_p \end{bmatrix}$$

A matriz de interação unitária $D(q)$ pode ser obtida através da fatoração da Equação (5.1) de acordo com o seguinte teorema:

TEOREMA A.1: (ROGOZISKI et al., 1987) Para a matriz de funções de transferência $T(q)$, existe uma matriz de interação unitária com fatores finitos (t) de acordo com:

$$D(q) = S^{(t)}(q)S^{(t-1)}(q) + \dots + S^{(1)}(q) \quad (5.2)$$

com

$$S^{(i)}(q) = U^{(i)}(q)Q^{(i)} \quad (5.3)$$

com $U^{(i)}(q)$ matriz *r.s.p.m.* de ordem k_i , e $Q^{(i)}$ matriz não singular de ordem $n \times n$.

Desta forma, o algoritmo para o cálculo da matriz de interação unitária é descrito como se segue:

Inicia-se o algoritmo com os valores: $i = 0$, $N^{(0)}(q) = N(q)$, $\Lambda(0) = \Lambda$ e $D(0) = I_n$. Considere a i -ésima interação a matriz de interação unitária $D(q)$.

ETAPA 1:

Se $r_i = \text{rank}(N^{(i-1)}) = \min(n, m)$ o algoritmo termina e a matriz de interação unitária $D(q) = D^{(i-1)}(q)$, então $t = i - 1$;

Se $r_i < \min(n, m)$, então se deve fatorar $N_0^{(i-1)}$ utilizando a fatoração QR de acordo com:

$$N_0^{(i-1)} = (Q^{(i)})^{-1} \begin{bmatrix} 0_i \\ N_{0D}^{(i)} \end{bmatrix}, \text{ ou seja, } Q^{(i)} N_0^{(i-1)} = \begin{bmatrix} 0_i \\ N_{0D}^{(i)} \end{bmatrix} \quad (5.4)$$

com $Q^{(i)}$ uma matriz real unitária (ortogonal) $n \times n$, $k_i = n - r_i$ e 0_i uma matriz de zeros com k_i -linhas.

ETAPA 2:

Após a fatoração QR de $N_0^{(i-1)}$ deve-se pré-multiplicar $N^{(i-1)}(q)$ pela matriz $Q^{(i)}$ da seguinte forma:

$$\overline{N}(q) = Q^{(i)} N^{(i-1)}(q) \quad (5.5)$$

no qual os coeficientes de \overline{N} são iguais ao segundo termo da Equação (5.4).

ETAPA 3:

Efetue a multiplicação: \overline{N} pela matriz r.s.p.m. de ordem k_i de acordo com:

$$N^{(i)}(q) = U^{(i)}(q) \overline{N}(q) \quad (5.6)$$

Esta multiplicação atualiza os coeficientes de $\Lambda^{(i)}$.

Logo em seguida, calcule a matriz de interação unitária parcial da seguinte forma:

$$D^{(i)}(q) = S^{(i)}(q) D^{(i-1)}(q) \quad (5.7)$$

Desta forma, a i -ésima interação é dada pela combinação das Equações (5.3) e (5.7), resultando em:

$$N^{(i)}(q) = U^{(i)}(q) Q^{(i)} N^{(i-1)}(q) = S^{(i)}(q) N^{(i-1)}(q) = D^{(i)}(q) N(q)$$

com $S^{(i)}(q)$ e $D^{(i)}(q)$ são definidos pelas Equações ((5.3) e (5.7).

A interação final é dada por ($t = i - 1$):

$$N^{(t)}(q) = D(q) N(q) \quad (5.8)$$

com $D(q) = D^{(t)}(q)$ a matriz de interação unitária.

Apêndice B

Algoritmo para o Cálculo da Matriz de Interação Generalizada

Este Apêndice contém o algoritmo proposto por Tsiligiannis e Svoronos (1989) para o cálculo da matriz de interação generalizada.

Sistemas sem pólos em $z = -1$:

Dada uma matriz de função de transferência estritamente própria e não singular $G(z)$ onde existe um único inteiro $k_i, i = 1, 2, \dots, L$ no qual:

$\lim_{z \rightarrow \infty} z^{k_i} G_i(z) = \tau_i$; $G_i(z) = i$ -ésima linha de $G(z)$, e ambos são finitos e não nulos.

Define-se a primeira linha $\xi(z)_1$ de $\xi(z)$ por: $\xi(z)_1 = (z^{k_1}, 0, \dots, 0)$ então:

$$\lim_{z \rightarrow \infty} \xi(z)_1 G(z) = \tau_i = \xi_1$$

Se τ_2 é linearmente independente para $\tau_1 = \xi_1$, então tem-se $\xi(z)_2 = (0, z^{k_2}, \dots, 0)$ então;

$$\lim_{z \rightarrow \infty} \xi(z)_2 G(z) = \tau_2$$

Se τ_2 e $\xi(z)_1$ são linearmente dependentes entre si, então tem-se $\tau_2 = \alpha_1^1 \xi_1$ e

pode-se escrever:

$\xi^1(z)_2 = z^{k_2^1} [(0, z^{k_2^1}, 0, \dots, 0) - \alpha_1^1 \xi(z)_1]$, em que k_2^1 é o único inteiro para o qual:

$\lim_{z \rightarrow \infty} \xi(z)^1 G(z) = \xi_2^1$, ambos finitos e não nulos.

Se ξ_2^1 é linearmente independente de ξ_1 , então se pode obter a segunda linha da matriz:

$$\xi(z)_2 = \xi^1(z)_2$$

Se não, tem-se: $\xi_2^1 = \alpha_1^2 \xi_1$ e então, $\xi^2(z)_2 = z^{k_2^2} [\xi^1(z)_2 - \alpha_1^2 \xi(z)_1]$, em que k_2^2 é o único inteiro para o qual $\lim_{z \rightarrow \infty} \xi^2(z)_2 G(z) = \xi_2^2$, ambos finitos e não nulos.

Se ξ_2^2 é linearmente independente de ξ_1 então pode-se obter a segunda linha da matriz:

$$\xi(z)_2 = \xi^2(z)_2$$

Se não, devem-se repetir os passos acima até que se encontre a independência entre as linhas da matriz.

Sistemas com pólos em $z = -1$:

ETAPA 1:

Dada uma matriz de função de transferência estritamente própria e não singular $G(z)$, no qual, através deste sistema deve-se obter os zeros que sejam finitos e em módulo, maiores que 1 (um), e os zeros infinitos dados por σ_i e σ_j , respectivamente (TSILIGIANNIS; SVORONOS, 1989), com i e $j = 1, 2, \dots, n$.

ETAPA 2:

Com os zeros σ_i e σ_j , faz-se a substituição no sistema em z para p ou q conforme as equações:

Para p : $z = \frac{1+\sigma p}{p+\sigma}$

Para r : $z = \frac{\sigma r}{r+\sigma-1}$

Assim, pode-se obter $\xi_i^p(z)$ ou $\xi_i^r(z)$ para um zero finito e repetir a *ETAPA 2* até completar o número de zeros finitos.

ETAPA 3:

Extrair as informações de zeros finitos do sistema, dado por: $K_i^w = \xi_{G\sigma i}^w(z)G(z)$, onde $w = p$ ou r e $i = 1, 2, \dots, n$.

Utilizar novamente o algoritmo para o cálculo de $\xi_j^w(z)$, repetindo esta etapa até o número de zeros no infinito.

ETAPA 4:

Efetua-se o cálculo da matriz de função de transferência já abordada anteriormente, da seguinte forma:

$$\xi^w(z) = \xi_M^w(z)\xi_{M-1}^w(z)\dots\xi_2^w(z)\xi_1^w(z)$$

com $M = n$.