

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA QUÍMICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA

**Planejamento de Perturbações para a
Identificação de Modelos Dinâmicos**

DISSERTAÇÃO DE MESTRADO

Vinicius Cunha Machado

Porto Alegre

2004

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA QUÍMICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA

Planejamento de Perturbações para a Identificação de Modelos Dinâmicos

Vinicius Cunha Machado

Dissertação de Mestrado apresentada como
requisito parcial para obtenção do título de
Mestre em Engenharia

Área de concentração: Controle de Processos

Orientador:
Prof. Dr. Jorge Otávio Trierweiler

Co-orientador:
Prof. Dr. Argimiro Resende Secchi

Porto Alegre

2004

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA QUÍMICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA

A Comissão Examinadora, abaixo assinada, aprova a Dissertação *Planejamento de Perturbações para a Identificação de Modelos Dinâmicos*, elaborada por Vinicius Cunha Machado, como requisito parcial para obtenção do Grau de Mestre em Engenharia.

Comissão Examinadora:

Prof. Dr. Darci Odloak

Eng. Herbert Campos G. Teixeira

Prof. Dr. Luís Gustavo Soares Longhi

Prof. Dr. Nilo Sérgio Medeiros Cardozo

Resumo

A identificação de modelos é determinante no sucesso das modernas técnicas de controle avançado de processos. Um modelo para o sistema pode ser obtido através de modelagem rigorosa, baseada em equações governantes do sistema ou através da modelagem empírica e estimação de parâmetros. Embora mais rápida e fácil, a modelagem empírica necessita de alguns testes de identificação nos quais as variáveis manipuladas são variadas de modo que resultem em variações nas variáveis controladas.

Os testes de identificação podem apresentar custos muito elevados tendo em vista que o sistema pode sair de seu ponto normal de operação, gerando produtos com folga de especificação. Este fato ocorre porque usualmente as perturbações aplicadas nas variáveis manipuladas nas indústrias de processos são independentes umas das outras, aumentando a duração do teste de identificação. Desta forma, neste trabalho foi desenvolvida uma nova metodologia de projeto de perturbações simultâneas para a identificação de modelos dinâmicos baseada na direcionalidade do sistema, com o objetivo de fornecer dados mais ricos para se capturar corretamente o comportamento multivariável do sistema e manter o processo no ponto de operação normal. As perturbações são projetadas conforme as características de um modelo simplificado do processo, ou pré-modelo. Este modelo inicial é obtido essencialmente de dados históricos de planta, selecionados através de uma sistemática análise de correlação desenvolvida neste trabalho.

A metodologia proposta é composta de duas partes: a primeira parte diz respeito à análise dos dados históricos de planta para obtenção de informações preliminares as quais são utilizadas no planejamento de perturbações, tais como amplitude do ruído de medida, correlação entre as variáveis de processo, constante de tempo do sistema e matriz de ganhos. E a segunda parte consiste no cálculo da amplitude das perturbações baseado nos resultados da primeira etapa do planejamento. Para sistemas mal-condicionados verificou-se que as perturbações planejadas pela metodologia removem menos a planta de seu ponto de operação gerando resultados mais consistentes em relação às perturbações tradicionais. Já para sistemas bem-condicionados, os resultados são semelhantes.

A metodologia foi aplicada em uma unidade piloto experimental e numa unidade de destilação da PETROBRAS, cujos resultados apontam pouca remoção dos sistemas do ponto de operação e modelos consistentes. A validação dos modelos também foi contemplada na dissertação, uma vez que foi proposto um novo critério de validação que considera a derivada dos dados de planta e a do modelo e não apenas os dados de planta e os dados da simulação das saídas do modelo.

Abstract

Generally, a model can be obtained through rigorous modeling based on the first principles or by empiric modeling and parameter estimation using plant data. In most cases, it is very difficult to create an accurate first-principles model, due to the complexity of the process and the lack of information. On the other side, the empirical modeling, although easier to obtain than the rigorous modeling, demands an intensive identification test, where all manipulated variables must be excited to produce some effects in the controlled variables. The big deal in these tests is the change of the process from its normal operating point, increasing costs and being time-consuming. For fixing this problem, in this work was developed a new tool for signal design to identify dynamic models based on the directionality of the simplified model of the system. This simplified model is obtained from a rigorous procedure based on correlation analysis developed in this work.

The proposed methodology is structured in two parts. First part extract a lot of system information from historical plant data such as noise amplitude, what variables are correlated, time constant and gain matrix. Second part comprehends on the calculation properly of the signal to be applied in the system. An identification set of signals to identify dynamic models of a distillation unit of the PETROBRAS was projected by the proposed methodology and the results are presented in this work. The methodology was also applied in a real laboratory plant. Model validation also was considered in this work because it was proposed a new model validation criterion based on the derivative of the plant data and the derivative of the model output and not only based on the plant data and the model output such as the conventional criteria.

Agradecimentos

A minha fé no trabalho e na superação dos meus limites, despertara após inúmeras conversas com meu orientador, Jorge Otávio Trierweiler, o qual tenho como segundo pai e infalível amigo e com o meu co-orientador Argimiro Resende Secchi, sempre pronto para auxiliar na caminhada. Não posso esquecer das inúmeras palavras de apoio da Equipe Trisolutions, composta pelos amigos Maurício Simões Posser, Luciano André Farina, Ricardo Guilherme Duraisk, Simone Marcon e Leandro Porto Lusa. Agradeço a todos pela força que me dão e que me deram. Muito obrigado!

Sou eternamente grato aos meus queridos pais, Marco e Lizette, pelo empenho e dedicação em me darem a educação mais que suficiente para ser um excelente cidadão. A educação vem antes de qualquer ciência, embora algumas pessoas não se tenham dado conta disto. Ao meus irmãos, Rafael e Letícia, pela singela convivência e a minha querida esposa Ana Néry. Muito obrigado!

E aí gurizada da Várzea (para quem não sabe, Várzea é um mundo paralelo ao mundo real, criado pelo homem primitivo). A "gurizada" a que me refiro e profiro os meus agradecimentos são: Tchaca (André Muniz), Pinguço (Ariel Kempf), Kiosk (Marcelo Farenzena), Mórrom (Flávio Faccin), Samuca (Samuel Facchin), Visconde de Sabugosa (Josué Bohn), Cvrino (Edson Cordeiro do Vale), Peregra (Rafael Pelegrini), Farsante (Arlindo Rader), Fisch (Adriano Fisch), Fura (Tiago Finkler), Xampa (Márcio Pereira) e também às suas respectivas namoradas/noivas/esposas. Muito Obrigado!

Agradeço ao corpo de funcionários do DEQUI (Departamento de Engenharia Química), em especial ao Patrício, secretário da Pós-Graduação, ao Senhor José, Chefe da Oficina do DEQUI e as moças da limpeza Neuza e Sônia. Também não poderia esquecer da Dona Irma, secretária dos projetos CTPETRO-FINEP. Muito Obrigado! Obviamente não poderia esquecer de agradecer à PETROBRAS – Petróleo Brasileiro, em nome dos Engenheiros Herbert (CENPES), Almeida (PETROBRAS) e Filipe (Refinaria de Capuava, da PETROBRAS). O contato com estes profissionais contribuiu extremamente para o sucesso do trabalho. Muito Obrigado!

Notação e Símbolos

Veja:

| | | |
|--|--|-------------|
| s | Variável do conjunto dos números complexos | Seção 2.1 |
| $\mathbf{G}(s)$ | Matriz de transferência | Introdução |
| $\mathbf{A}(t)$, $\mathbf{B}(t)$, $\mathbf{C}(t)$, $\mathbf{D}(t)$ | Matrizes da representação de um sistema no espaço de estados. | Introdução |
| ω | Vetor de frequências | |
| ϕ_{ss} | Espectro da função autocorrelação do vetor de dados $s(t)$. | Seção 2.1 |
| $\mathbf{S}(s)$ | Função sensibilidade | Seção 2.1 |
| $\mathbf{T}(s)$ | Função complementar de sensibilidade | Seção 2.1 |
| $\mathbf{C}(s)$ | Função do controlador expressa no domínio complexo | Seção 2.1 |
| k | Inclinação da função do relé com saturação | Seção 2.4.2 |
| \bar{a} | Valor limite de saturação nas ações do relé com saturação | Seção 2.4.2 |
| ku | Ganho ultimativo do sistema | Seção 2.4.2 |
| x_j | Vetor de dados de planta da variável j | Seção 3.2.1 |
| Corr | Função correlação | Seção 3.2.1 |
| μ_y, μ_u | Média dos dados de saída e de entrada, respectivamente | Seção 3.2.1 |
| max(.) | Maior valor dentre os elementos de um vetor | Seção 3.2.1 |
| $\Delta u, \Delta y$ | Valores normalizados das entradas e das saídas dos dados de planta | Seção 3.2.1 |
| L_C | Valor de decisão para a escolha dos subintervalos | Seção 3.2.1 |

| | | |
|----------------------|---|---------------|
| | de dados com maior correlação entre entradas e saídas. | |
| σ_u, σ_y | Desvios padrão das entradas e das saídas no subintervalo de dados com distribuição mais próxima da distribuição Normal. | Seção 3.2.1 |
| y_{diff} | Vetor diferença entre os dados das variáveis controladas e a média da mesma variável dentro de um subintervalo de dados. | Seção 3.2.2.1 |
| \bar{y} | Média dos dados das variáveis controladas para o cálculo da variável y_{diff} | Seção 3.2.2.1 |
| p, x, μ, σ | Parâmetros da distribuição Normal | Seção 3.2.2.1 |
| Δy_j | Estimativa da amplitude do ruído de medida na variável controlada y_j | Seção 3.2.2.1 |
| σ_j | Desvio padrão da variável controlada j | Seção 3.2.2.1 |
| $\tau_{MÉDIO}$ | Constante de tempo representativa do sistema baseada na média geométrica das constantes de tempo das funções de transferência do pré-modelo | Seção 3.2.2.2 |
| τ_i | Constante de tempo i do vetor de constantes de tempo das funções de transferência do pré-modelo | Seção 3.2.2.2 |
| τ | Constante de tempo do sistema | Seção 3.2.2.2 |
| L, R | Matrizes de escalonamento do sistema | Seção 3.2.2.3 |
| $G_S(j\omega)$ | Pré-modelo escalonado e avaliado em $j\omega$ | Seção 3.2.2.3 |
| U, Σ, V^H | Matrizes da decomposição em valores singulares do pré-modelo $G_S(j\omega)$ | Seção 3.2.2.3 |
| V_i | Vetor coluna da matriz V^H na direção i . | Seção 3.2.2.3 |

| | | |
|----------------|---|---------------|
| Δu_i | Amplitude das perturbações na direção i . | Seção 3.2.2.3 |
| FE_i | Fator de expansão para o cálculo de Δu_i | Seção 3.2.2.3 |
| $e(t)$ | Vetor de erros entre a variável medida e a predição do modelo para cada unidade de amostragem | Seção 4.1 |
| θ | Vetor de parâmetros do modelo | Seção 4.2 |
| Z^N | Conjunto de dados de planta com N pontos | Seção 4.2 |
| $\dim(\theta)$ | Dimensão do vetor θ | Seção 4.2 |
| D | Critério da derivada | Seção 4.3 |
| ω_{GEO} | Inverso da constante de tempo baseada na média geométrica | Seção 4.3 |

Lista de Acrônimos

Veja:

| | | |
|--------------|--------------------------------------|-------------|
| AIC | Akaike's Information Criterion | Seção 4.2 |
| FIFO | First In First Out | |
| FIR | Finite Impulse Response | Apêndice |
| FODT | First Order with Dead Time | Seção 3.2.1 |
| FSR | Finite Step Response | |
| LTI | Linear Time Invariant | Introdução |
| MDL | Minimum Description Length | Seção 4.2 |
| MIMO | Multi-Input Multi-Output | Seção 2.8 |
| PIMS | Plant Information Management Systems | Seção 3.1 |
| PRBS | Pseudo Random Binary Signal | Seção 2.5 |
| RECAP | Refinaria de Capuava | Seção 6.1 |
| RGA | Relative Gain Array | Seção 3.4 |
| RGA0 | RGA estacionário | Seção 3.5 |
| SISO | Singular-Input Singular-Output | Seção 2.1 |
| SNR | Signal-to-Noise Ratio | Seção 3.1 |
| UOV | Unmodeled Output Variation | Seção 4.2 |

Sumário

| | |
|--|-----------|
| Introdução | 1 |
| 1.1 Estrutura da Dissertação..... | 5 |
| Perturbações Clássicas para Identificação..... | 6 |
| 2.1 Conceitos Básicos | 7 |
| 2.2 Exemplo Introdutório sobre Perturbações..... | 9 |
| 2.3 Perturbação Degrau..... | 10 |
| 2.4 Perturbação Relé | 11 |
| 2.5 Sinal PRBS..... | 15 |
| 2.6 Perturbações geradas pelo controlador..... | 17 |
| 2.7 Comparação entre os Diferentes Tipos de Perturbações..... | 19 |
| 2.8 Perturbações para o Caso Multivariável | 21 |
| Metodologia de Perturbações Multivariáveis Proposta | 22 |
| 3.1 Principais Compromissos e Objetivos | 23 |
| 3.2 Metodologia Proposta | 27 |
| 3.2.1 Geração de Pré-Modelo a partir do histórico de dados de planta | 27 |
| 3.2.2 Projeto Sistemático de Perturbações baseado no Pré-Modelo | 32 |
| 3.2.2.1 Determinação da Amplitude do Ruído de Medida..... | 33 |
| 3.2.2.2 Cálculo do Tempo de Perturbação | 36 |
| 3.2.2.3 Cálculo das Direções e da Amplitude das Perturbações | 37 |
| 3.3 Importância das Perturbações Ortogonais..... | 38 |
| 3.4 Decomposição das Perturbações em Blocos..... | 39 |
| 3.5 Exemplo ilustrativo | 39 |
| 3.5.1 Modelos para estrutura 142..... | 42 |
| 3.5.2 Modelos para estrutura 635..... | 46 |
| Técnicas de Validação de Modelos..... | 51 |
| 4.1 Critérios de Validação de Modelos..... | 51 |
| 4.2 Revisão da Literatura sobre os Critérios de Validação | 52 |
| 4.3 Novo Critério de Validação: O critério da derivada | 53 |
| 4.4 Aplicação prática do critério da derivada: Identificação da Planta de dois tanques com aquecimento | 55 |
| 4.5 Utilização do critério da derivada como função objetivo | 59 |
| Identificação de Modelos de uma Planta Piloto..... | 63 |
| 5.1 Planta Piloto de Cinco Tanques | 64 |
| 5.1.1. Descrição da Unidade | 64 |
| 5.2 Identificação Estruturada | 65 |
| 5.3 Identificação de Sistemas Mal-Condicionados | 68 |
| Aplicação da Metodologia de Perturbações Proposta em Planta Industrial | 77 |

| | |
|---|------------|
| 6.1 Planta Industrial | 78 |
| 6.2. Descrição da Unidade | 78 |
| 6.3. Planejamento de Perturbações e Identificação dos Modelos | 81 |
| Conclusões e Sugestões para Futuros Trabalhos | 89 |
| 7.1 Principais Conclusões | 89 |
| 7.2 Sugestões para Trabalhos Futuros..... | 90 |
| Técnicas de Identificação | 92 |
| A.1 Métodos Discretos | 94 |
| A.2. Métodos de Identificação em Espaço de Estados..... | 98 |
| A.3. Método dos Momentos de Poisson | 100 |
| A.4 Modos de Operação de Plantas Industriais..... | 104 |
| A.4.1 Modo Malha Aberta | 104 |
| A. 4.2 Modo Malha Fechada..... | 106 |
| A.4.2.1 Método Direto | 107 |
| A.4.2.2 Métodos indiretos..... | 107 |
| Referências Bibliográficas..... | 109 |

Lista de figuras

| | |
|--|----|
| Figura 1.1 : Principais etapas do problema de identificação. | 1 |
| em que ω é a frequência e R_s é a função (auto) covariância do sinal $s(t)$, definida pela Equação (2.2): | 7 |
| Figura 2.1 : Representação esquemática do sistema de dois tanques com aquecimento. | 9 |
| Figura 2.2 : Seqüência de degraus aplicada à potência de aquecimento da planta de dois tanques com aquecimento..... | 10 |
| Figura 2.3 : Periodograma do sinal degrau aplicado à planta de aquecimento e reciclo..... | 11 |
| Figura 2.4 : Representação esquemática de uma malha de controle com atuação de relé..... | 11 |
| Figura 2.5 : Representação da função da resposta do relé ideal. | 12 |
| Figura 2.6 : Dados do teste relé ideal aplicada a planta de dois tanques com aquecimento. | 12 |
| Figura 2.7 : Periodograma do sinal de excitação gerado por um relé ideal..... | 13 |
| Figura 2.8 : Representação da função da resposta do relé com saturação. | 13 |
| Figura 2.9 : Dados de teste de identificação com perturbações gerados a partir do relé com saturação na planta de dois tanques com aquecimento. | 14 |
| Figura 2.10 : Periodograma do sinal de excitação gerado por um relé com saturação..... | 15 |
| Figura 2.11 : Dados de teste de identificação com perturbações geradas através de sinal PRBS na planta de dois tanques com aquecimento. | 16 |
| Figura 2.12 : Periodograma do sinal de excitação do tipo PRBS..... | 17 |
| Figura 2.13 : Perturbações em malha fechada na planta de dois tanques com aquecimento. No gráfico superior: <i>setpoint</i> (linha cheia) e temperatura T_2 (linha tracejada). No gráfico intermediário: ação de controle calculada pelo controlador (linha cheia) e ação total de controle (linha tracejada). No gráfico inferior, tem-se a perturbação adicional aplicada ao <i>u-bias</i> do controlador. | 18 |
| Figura 2.14 : Periodograma do sinal de perturbação gerado pelo controlador PI do sistema de dois tanques com aquecimento..... | 19 |
| Figura 3.1 : Correlação entre as variáveis de entrada e de saída para um determinado subintervalo de dados usando a norma dos vetores $\Delta y(t)$ e $\Delta u(t)$ (gráfico à esquerda) e não usando a norma (gráfico à direita). | 30 |
| Figura 3.2 : Exemplo do uso do critério L_C de determinação dos melhores subintervalos de dados para a identificação. | 30 |
| Figura 3.3 : Dados das variáveis controladas da debutanizadora. | 31 |
| Figura 3.4 : Dados das variáveis manipuladas da debutanizadora. | 31 |
| Figura 3.5 : Comparação entre a distribuição normal e a distribuição obtida para os dados das variáveis desvio, para a caracterização da amplitude do ruído das saídas do sistema. | 34 |
| Figura 3.6 : Análise do ruído de dados de planta..... | 35 |
| Figura 3.7 : Fluxograma simplificado do processo de separação de ar LINDE. | 40 |
| Figura 3.8 : Dados gerados através da metodologia tradicional de projeto de perturbações para a identificação do modelo da estrutura 142. | 42 |

| | |
|---|----|
| Figura 3.9: Dados gerados através de sinais <i>PRBS</i> para a identificação do modelo da estrutura 142..... | 43 |
| Figura 3.10: Dados gerados através das perturbações baseadas nas principais direções do sistema. | 44 |
| Figura 3.11: Condicionamento mínimo dos modelos identificados e da planta real..... | 44 |
| Figura 3.12: Resposta a degrau unitário dos modelos identificados e da planta real. Planta (traço-ponto); Metodologia tradicional (traço longo-traço curto); <i>PRBS</i> (linha contínua), Direções (linha tracejada)..... | 45 |
| Figura 3.13: Dados gerados através da metodologia tradicional de projeto de perturbações para a identificação do modelo da estrutura 635. | 47 |
| Figura 3.14: Dados gerados através de sinais <i>PRBS</i> de projeto de perturbações para a identificação do modelo da estrutura 635..... | 47 |
| Figura 3.15: Dados gerados através das perturbações baseadas nas principais direções do sistema. | 48 |
| Figura 3.16: Condicionamento mínimo dos modelos identificados e da planta real..... | 48 |
| Figura 3.17: Resposta a degrau unitário dos modelos identificados e da planta real (635). Planta (pontilhado); Metodologia tradicional (tracejado); <i>PRBS</i> (traço-ponto), Direções (linha contínua)..... | 49 |
| Figura 4.1: Conjunto de dados experimentais com decréscimo da temperatura da água de alimentação T_0 (distúrbio), carga térmica Q (variável manipulada) e temperatura da água de descarga, T_2 | 55 |
| Figura 4.2: Conjuntos de dados usados na identificação dos modelos: (1) $\Delta T_2 = T_2(t) - T_2(0)$ (linha cheia) dados sem a compensação do efeito da temperatura de entrada e (2) $\Delta \Delta T = \Delta T(t) - \Delta T(0) = [T_2(t) - T_0(t)] - [T_2(0) - T_0(0)]$ (linha tracejada), dados com a compensação do efeito da temperatura de entrada. | 56 |
| Figura 4.3: Comparação entre os dados de planta sem o efeito das variações em T_0 (isto é $\Delta \Delta T$ da Figura 4.2) e os modelos identificados OE e BJ..... | 57 |
| Figura 4.4: Comparação entre os dados de planta com os efeitos das variações de T_0 (isto é, ΔT_2) e os modelos identificados OE e BJ. | 57 |
| Figura 4.5: Comparação entre a derivada dos dados de planta filtrados por <i>Idfilt</i> e a derivada dos modelos identificados OE e BJ. | 58 |
| Figura 4.6: Comparação com o conjunto de dados experimentais $\Delta \Delta T$: $G1$ identificado com OE, $G2$ identificado com o critério $S1$ e $G3$ com o $S2$ | 60 |
| Figura 4.7: Resposta a um degrau unitário de $G1$, $G2$ e $G3$ | 60 |
| Figura 4.8: Comparação entre os dados de planta (sem a compensação dos efeitos da temperatura da água de entrada na temperatura da água de descarga), modelo BJ ($G4$), critério $S1$ ($G5$) e o critério $S2$ ($G6$). | 61 |
| Figura 4.9: Resposta a degrau unitário dos modelos identificados $G4$, $G5$, $G6$ e $G1$ | 62 |
| Figura 5.1: Fluxograma simplificado e foto da unidade de cinco tanques. | 64 |
| Figura 5.2: Visualização da histerese no sistema provocada pelas válvulas de controle e curva de vazão destas válvulas..... | 65 |
| Figura 5.3: Simulação dos modelos estruturado e convencional em conjunto externo de validação, com o confronto com os dados de planta, para os quatro níveis dos tanques da planta piloto. Nos gráficos de $Y1$ a $Y4$ (níveis dos tanques), a linha cheia (-) representa os dados de validação enquanto que as linhas (--) e (-.) representam, respectivamente, o modelo estruturado e o não estruturado..... | 66 |

| | |
|--|-----|
| Figura 5.4: Comparação entre a resposta a um degrau unitário entre os modelos estruturado e o convencional do sistema composto por quatro níveis (tanques 1 a 4) e a posição de abertura das quatro válvulas do sistema (válvulas 1 a 4). G1 é o modelo estruturado (linha tracejada) e G2 é o modelo não estruturado (linha contínua). Por convenção, as linhas da matriz representam as saídas (níveis dos tanques de 1 a 4) e as colunas, as entradas do sistema (posição de abertura das válvulas de controle)..... | 67 |
| Figura 5.5: Representação simplificada do subsistema 3 tanques da planta de 5 tanques..... | 69 |
| Figura 5.6: Confronto entre os dados de planta do modelo G1 e a simulação deste modelo..... | 70 |
| Figura 5.7: Confronto entre os dados de planta do modelo G2 e a simulação deste modelo..... | 71 |
| Figura 5.8: Confronto entre os dados de validação (dados de planta) e a simulação dos modelos G1 (perturbações simultâneas) e G2 (perturbações isoladas). | 72 |
| Figura 5.9: Comparação entre as respostas a um degrau unitário dos modelos G1 (perturbações simultâneas) e G2 (perturbações isoladas). | 73 |
| Figura 5.10: Comparação entre os valores singulares máximos e mínimos dos modelos G1 (perturbações simultâneas) e G2 (perturbações isoladas)..... | 73 |
| Figura 5.11: Comparação entre os valores de condicionamento mínimo dos modelos G1 (perturbações simultâneas) e G2 (perturbações isoladas). | 74 |
| Figura 6.1: Fluxograma simplificado da unidade de destilação da RECAP..... | 79 |
| Figura 6.2: Diagrama das variáveis controladas e manipuladas constituintes dos blocos de planejamento de perturbações para a unidade de destilação..... | 81 |
| Figura 6.3: Perturbações planejadas para a identificação dos modelos da unidade de destilação..... | 83 |
| Figura 6.4: Resposta degrau do pré-modelo (G) das variáveis do bloco 2..... | 84 |
| Figura 6.5: Comparação entre a predição dos modelos obtidos para a saída 8 e os dados de planta desta variável (veja Tabela 6.2)..... | 86 |
| Figura A.1: Representação em diagrama de blocos da estrutura de modelos <i>FIR</i> | 96 |
| Figura A.2: Comparação entre o formato da distribuição de probabilidades de Poisson (gráfico superior) e a resposta a um impulso unitário de funções de transferência de primeira, segunda e terceira ordens. | 101 |
| Figura A.3: Representação do sistema em malha aberta. | 104 |
| Figura A.4: Confronto entre os dados de planta e modelos identificados entre a vazão de catalisador e a razão entre H_2/C_2 . (A, ponto) Dados de planta, (B, linha tracejada) <i>Box-Jenkins</i> , (C, linha contínua) Subespaço de Estado, (D, linha traço-ponto) <i>Poisson</i> | 105 |
| Figura A.5: Confronto entre os dados e planta e modelos identificados entre a vazão de catalisador e a vazão de etileno. Na figura, Dados de planta (ponto), <i>Box-Jenkins</i> (linha tracejada), Subespaço de Estado (linha contínua), <i>Poisson</i> (linha traço-ponto)..... | 106 |
| Figura A.6: Representação do sistema em malha fechada..... | 107 |

Lista de tabelas

| | |
|--|----|
| Tabela 2.1: Quadro comparativo entre os principais tipos de perturbação existentes. | 20 |
| Tabela 3.1: Dados gerados para a identificação do modelo de uma coluna de alta pureza operando em estrutura LV e em estrutura DV (gráficos inferiores). O condicionamento dos modelos identificados para o sistema nas estruturas LV e DV estão representados nos gráficos superiores, assim como o condicionamento mínimo do sistema em ambas as estruturas..... | 25 |
| Tabela 3.2: Valores do primeiro elemento dos vetores de correlação entre as normas das variáveis desvios normalizados das entradas e saídas do sistema debutanizador da RECAP. | 32 |
| Tabela 3.3: Amplitude do ruído de medida e valores da integral do erro absoluto entre a distribuição normal e a distribuição dos dados da Figura 3.4 para todos os subintervalos de dados analisados. | 36 |
| Tabela 3.4: Características dinâmicas das estruturas de controle 142 e 635 do processo de separação de ar LINDE. | 41 |
| Tabela 3.5: Resposta a degrau unitário dos modelos das estruturas de controle 142 e 635..... | 41 |
| Tabela 3.6: Variância dos dados de saída das variáveis controladas da estrutura 142 para os três testes de identificação. | 45 |
| Tabela 3.7: Zeros de transmissão dos modelos identificados para a estrutura 142 e da planta real. | 46 |
| Tabela 3.8: Variância dos dados de saída das variáveis controladas da estrutura 635 para os três testes de identificação. | 49 |
| Tabela 3.9: Zeros de transmissão dos modelos identificados para a estrutura 635 e os da planta real. | 50 |
| Tabela 4.1: Somatório dos erros de predição e da derivada do erros de predição quadráticos obtidos para os modelos OE e BJ identificados com os dados do conjunto ΔT_2 | 58 |
| Tabela 4.2: Coeficientes da Equação (4.5) obtidos a partir do conjunto de dados ΔAT | 59 |
| Tabela 4.3: Coeficientes obtidos a partir dos dados experimentais do conjunto ΔT_2 , das funções de G_4 , G_5 e G_6 | 61 |
| Tabela 5.1: Análise estatística dos dados de planta dos testes de identificação e validação apresentados no capítulo 5, na identificação do modelo do subsistema de 3 (três) tanques..... | 74 |
| Tabela 6.1: Variáveis manipuladas do sistema. | 80 |
| Tabela 6.2: Variáveis controladas do sistema. | 80 |
| Tabela 6.3: Amplitude de perturbações para as duas variáveis manipuladas do bloco 2..... | 85 |
| Tabela 6.4: Amplitude do ruído de medida das variáveis controladas da unidade de destilação, obtidas para a determinação da amplitude das perturbações dos testes da metodologia de perturbações baseada na direcionalidade do sistema.... | 85 |
| Tabela 6.5: Propriedades estatísticas básicas dos dados da unidade de destilação estudada após os testes de identificação com perturbações projetadas a partir da metodologia proposta. | 87 |

Capítulo 1

Introdução

A identificação de modelos lineares e invariantes no tempo é etapa determinante na implementação do sistema de controle de processos industriais, tanto na sintonia de controladores PID's (Proporcional – Integral – Derivativo) e CPM's (Controladores Preditivos Multivariáveis), quanto na determinação da melhor estrutura de controle para o sistema. Pode-se dizer que a identificação de modelos de processos dinâmicos resume-se em quatro etapas fundamentais, apresentadas através da Figura 1.1.

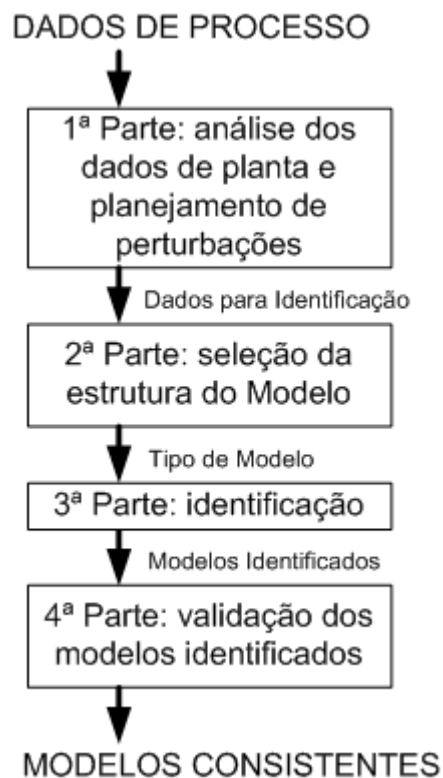


Figura 1.1 : Principais etapas do problema de identificação.

Das etapas apresentadas na Figura 1.1, em especial, esta dissertação apresentará contribuições no primeiro bloco e no quarto, tendo em vista que o trabalho focou o desenvolvimento de uma metodologia de perturbações para a identificação de modelos lineares, além de uma técnica de validação de modelos baseada nas derivadas dos dados das variáveis controladas. Embora alguns desenvolvimentos devam ser realizados na etapa de identificação, estes não fizeram parte do escopo deste trabalho, uma vez que muitos algoritmos e estratégias de identificação estão devidamente consolidadas.

A identificação de modelos dinâmicos a partir de dados de planta pode ser chamada também de modelagem empírica, uma vez que os modelos usados são empíricos e ajustados experimentalmente. Ainda existem os modelos teóricos ou rigorosos, os quais consideram as equações que governam o comportamento do sistema. No entanto, a modelagem rigorosa geralmente requer um tempo excessivo para a sua obtenção e estimação de seus parâmetros. Sob estes aspectos, a modelagem empírica tem sido utilizada usualmente por indústrias de processos.

A correta identificação dos modelos empíricos está intimamente ligada a uma série de fatores, tais como: o tipo de sinal aplicado à unidade, a seqüência de perturbações realizadas, a estratégia de identificação empregada, discreta ou contínua, malha aberta ou malha fechada, a relação sinal/ruído, a presença de distúrbios não medidos, o tempo despendido com a realização dos testes e o quanto o processo foi removido de seu ponto de operação. Estes dois últimos fatores são de extrema importância na identificação de modelos, substancialmente porque testes de identificação mais eficientes e eficazes reduzem drasticamente o custo da obtenção de modelos.

No sentido da redução de insumos e custos na tarefa de modelagem dinâmica de sistemas, faz-se cada vez mais necessário processar dados históricos de planta, de modo a se vasculhar dados ricos em informações dinâmicas do processo e aproveitar melhor estas informações armazenadas pelos sistemas comerciais PIMS (*Plant Information Management Systems*). Esta análise prévia dos dados de planta dificilmente está incorporada de forma automatizada em metodologias de projeto de perturbações encontradas na literatura. Desta forma, o presente trabalho procura contribuir justamente nesta lacuna da identificação de processos, introduzindo uma metodologia de planejamento de perturbações completa, a qual procura usar o máximo de informações já existente no sistema antes de novos testes de identificação serem realizados.

As principais metodologias de projeto de perturbações estabelecidas na literatura aplicam usualmente os sinais do tipo degrau ou step, PRBS (*Pseudo Random Binary Signal*), relé ideal e relé com saturação, e perturbações geradas pelo próprios controladores. Cada sinal apresenta aspectos peculiares, e excita o sistema de maneira diferente, podendo proporcionar diferentes modelos, conforme a riqueza da resposta do sistema frente a cada perturbação. Estas perturbações podem ser executadas em dois modos de operação: em malha aberta, caracterizada pela inexistência de controladores, em que as ações de controle são aplicadas de forma isolada e não automática e em malha fechada, na qual o controlador do processo permanece ativo ao longo dos testes de identificação.

A grande vantagem da estratégia de identificação em malha aberta consiste na facilidade de realização dos ensaios com aplicação dos sinais para obtenção dos dados, geralmente degrau/PRBS. O ponto negativo desta metodologia, amplamente utilizada nas indústrias de processo, é o elevado consumo de recursos e tempo, tendo em vista a remoção da planta de seu ponto de operação, além de que a presença de distúrbios não medidos afetam diretamente a qualidade dos modelos identificados. Por outro lado, pode-se empregar a estratégia de identificação em malha fechada. Há grande apelo por parte das indústrias, quanto ao estudo e aplicação desta estratégia de identificação, em função do teste de identificação ser em geral mais rápido em relação à identificação em malha aberta, removendo por pouco tempo a unidade do seu ponto de operação. Em certas malhas de controle, ocorre a impossibilidade de abri-las devido à instabilização, e por isso apenas a identificação em malha fechada é aconselhável.

Os modelos dinâmicos podem ser classificados, de maneira geral como:

- lineares e não-lineares
- paramétricos e não-paramétricos
- com parâmetros concentrados e com parâmetros distribuídos
- determinísticos e estocásticos ou uma mistura das duas características

Embora os modelos não lineares sejam os que melhor reproduzem a realidade dos processos, a grande maioria dos controladores ativos nas plantas industriais utilizam modelos lineares devido à facilidade de cálculo das ações de controle. Na prática, o que se faz é linearizar o modelo não-linear, quando este é disponível, e se opera em torno do ponto em que se linearizou. Diferentemente do modelo linear, o modelo não-linear é de natureza posicional, isto é, a mesma variação nas entradas em diferentes pontos de operação, pode produzir resultados significativamente distintos.

Em alguns cenários industriais, a não-linearidade é confundida com distúrbios não medidos, os quais são componentes estocásticos que precisam ser contemplados pelo modelo, assim como a distribuição estatística do ruído de medida. Modelos que procuram contemplar estes efeitos são ditos modelos estocásticos. Por outro lado, se o interesse da identificação é obter a relação entre a entrada e a saída, ignorando os distúrbios e o ruído, o modelo é chamado de modelo determinístico.

Outra característica importante do modelo é sua representação ou não através de parâmetros. Os modelos não-paramétricos procuram estabelecer uma relação entre a variável dependente e a independente, sendo esta última pertencente ao domínio do tempo ou da frequência. Os modelos não-paramétricos mais simples, empregando-se o domínio do tempo, são obtidos através da resposta ao impulso (FIR – *Finite Impulse Response*) e resposta ao degrau (FSR – *Finite Step Response*). No domínio da frequência, pode-se estimar uma função de

transferência através da razão entre a transformada de Fourier discreta do sinal de saída e a transformada de Fourier discreta do sinal de entrada.

A identificação de sistemas procura relacionar entradas e saídas através de correlações traduzidas matematicamente por modelos. Os modelos podem ser expressos tanto em forma de funções de transferência, no domínio discreto ou no domínio contínuo, e também sob a forma de espaço de estado. Os modelos tradicionalmente usados em controle de plantas industriais são modelos do tipo LTI (*Linear Time-Invariant*), ou seja, modelos lineares e com parâmetros invariantes no tempo.

Modelos LTI representam a classe de modelos mais interessante do ponto de vista industrial, não apenas pela praticidade, facilitando tratamentos matemáticos, mas também pela facilidade de obtenção com boa representação das dinâmicas do processo. Esta classe de modelos, apresentam respostas que independem do tempo absoluto e tem natureza não posicional, isto é, em qualquer ponto de operação do processo, variações nas entradas produzem os mesmos efeitos nas saídas. É chamado de linear porque sua resposta a várias entradas simultâneas é a soma das respostas frente as mesmas entradas individuais. Em outras palavras, é válido o princípio da superposição, em que $f(a+b) = f(a)+f(b)$. A representação deste tipo de sistema pode ser feita através de funções de transferência ou em espaço de estados, dadas respectivamente por:

$$y(s) = G(s) \cdot u(s) \quad (1.1)$$

$$\begin{aligned} \frac{dx}{dt} &= Ax(t) + Bu(t) \\ y(t) &= Cx(t) + Du(t) \end{aligned} \quad (1.2)$$

em que $G(s), y(s)$ e $u(s)$ representam, nesta ordem, a função de transferência que é o modelo do processo, a saída e a entrada do sistema. Na equação 1.2 as matrizes A, B, C e D compõem a representação do sistema em espaço de estados, sendo que $x(t)$ é o vetor dos estados, $u(t)$ é o vetor das variáveis manipuladas e $y(t)$ é o vetor das variáveis controladas. Cabe lembrar que os sistemas lineares apresentam apenas um ponto de equilíbrio e são estáveis se todos os autovalores da matriz A forem negativos. A resposta transiente, bem como o ganho de sistemas lineares são invariantes em relação ao ponto de operação.

Cabe ressaltar que neste trabalho a metodologia de perturbações desenvolvida é dirigida à identificação de sistemas lineares, tais quais mencionados anteriormente, e todos os modelos identificados são pertencentes a esta classe de modelos. É válido lembrar que sistemas não-lineares não podem ser descritos pelas equações 1.1 e 1.2.

1.1 Estrutura da Dissertação

Esta dissertação apresenta-se dividida em sete capítulos, conforme descritos a seguir: no Capítulo 2, são abordados os principais tipos de sinais aplicados em testes de identificação. Alguns conceitos importantes sobre as principais características que os sinais de excitação devem ter são também verificados. Já no Capítulo 3, é apresentada a metodologia de projeto de perturbações para a identificação de modelos dinâmicos desenvolvida neste trabalho, assim como algumas aplicações a sistemas simulados. Outra contribuição que se vislumbra nesta dissertação é a introdução de um novo critério de validação de modelos, baseado na derivada dos dados de planta e do modelo. Este novo critério é apresentado no Capítulo 4. Os capítulos 5 e 6 apresentam aplicações da metodologia de projeto de perturbações em sistemas piloto e numa unidade de destilação industrial. Finalizando, o Capítulo 7 traz as conclusões do estudo realizado e as sugestões/metapas para trabalhos futuros.

Capítulo 2

Perturbações Clássicas para Identificação

A identificação de sistemas implica em conhecer as relações entre as variáveis manipuladas do processo ou entradas e as variáveis controladas do processo ou saídas. O processo de identificação, dentro da modelagem empírica, pode iniciar com uma série de testes em que a unidade sofre algumas perturbações nas variáveis manipuladas. Estas perturbações produzem reações nas variáveis de saída do sistema, permitindo a geração de dados ricos em informações sobre a relação entre estas variáveis. Com estes dados pode-se estimar parâmetros de modelos que minimizam o somatório da diferença entre os dados das saídas da planta e os valores preditos pelo modelo. Minimizar esta diferença significa, a princípio, capturar o comportamento do sistema. No entanto, as alterações nas variáveis controladas podem ocasionar a remoção da planta de seu ponto de operação, gerando produtos com folga de especificação e elevando os custos do processo de identificação.

Os sinais de perturbação podem ser os mais variados possíveis e são caracterizados, de forma simplificada, por: seu espectro, excitação e intervalo de frequências importantes. Além da caracterização do sinal, algumas considerações práticas, as quais dependem da natureza de cada sistema, devem ser estudadas antes da aplicação de qualquer sinal de perturbação na identificação de modelos lineares, como por exemplo, a definição do conjunto de variáveis envolvidas, o intervalo de operação ou valor que cada variável pode assumir durante o período de testes, o tempo em que o sistema pode sair do ponto de operação em que está trabalhando e a amplitude das perturbações a serem realizadas. Neste sentido, faz-se necessário considerar estes fatores para reduzir os custos dos testes de identificação sem abrir mão da qualidade dos modelos identificados.

As perturbações para a identificação mais conhecidas e empregadas nos cenários acadêmico e industrial são:

- Perturbação degrau
- Perturbação relé

- Perturbação PRBS (*Pseudo Random Binary Signal*)
- Perturbações geradas pelo próprio controlador.

Este capítulo tem por objetivos apresentar as características gerais dos sinais de perturbação, bem como mostrar aspectos importantes das principais perturbações utilizadas na indústria para a identificação de modelos de processos. De modo a transformar o tema deste capítulo mais agradável e didático, um exemplo introdutório sobre perturbações será apresentado após a seção de conceitos básicos.

2.1 Conceitos Básicos

O espectro de frequências é a característica mais importante de um sinal sob o aspecto da identificação de sistemas, pelo fato de ser uma medida da energia do sinal. Por ser definido matematicamente como a transformada de *Fourier* da função covariância do sinal, representa o conteúdo de frequências do sinal. Em outras palavras, é possível decompor um sinal $s(t)$, em vários sinais com frequências distintas, em que o espectro é a soma das energias de cada um destes sinais

Algumas variáveis importantes na identificação de sistemas são dependentes do espectro do sinal de excitação e não de seu formato, como por exemplo, o *bias* (diferença numérica entre os parâmetros que caracterizam o modelo identificado e os parâmetros do verdadeiro modelo) e a *variância* (variância dos parâmetros estimados na identificação) [LJ99]. Entenda-se por verdadeiro modelo aquele modelo cujos parâmetros tornam a predição do modelo mais próxima dos dados de planta. O conceito de espectro, de um sinal $s(t)$, pode ser formalizado através da Equação (2.1):

$$\Phi_{ss}(\omega) = \sum_{\tau=-\infty}^{\infty} R_s(\tau) e^{-i\tau\omega} \quad (2.1)$$

em que ω é a frequência e R_s é a função (auto) covariância do sinal $s(t)$, definida pela Equação (2.2):

$$R_s(\tau) = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{t=1}^N s(t) \cdot s(t + \tau) \quad (2.2)$$

A variável τ é chamada de variável defasagem. A variável t representa o instante de amostragem. N é o número total de pontos considerados no cálculo. Na prática, o somatório da Equação (2.2) tem número finito de pontos. Além do espectro do sinal $s(t)$, pode-se definir o espectro cruzado entre dois sinais, através da Equação (2.3):

$$\Phi_{s\omega}(\omega) = \sum_{\tau=-\infty}^{\infty} R_{s\omega}(\tau) e^{-i\tau\omega} \quad (2.3)$$

em que R_{sw} é a função covariância cruzada entre os sinais $s(t)$ e $w(t+\tau)$. R_{sw} é definida pela Equação (2.4), a seguir:

$$R_{sw}(\tau) = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{t=1}^N s(t) \cdot w(t+\tau) \quad (2.4)$$

Estatisticamente, a função covariância e a função covariância cruzada podem ser observadas como sendo os valores esperados entre o produto dos sinais $s(t)$ por $s(t+\tau)$ e $s(t)$ por $w(t+\tau)$, respectivamente, de acordo com as equações (2.5) e (2.6).

$$R_s(\tau) = E\{s(t) \cdot s(t+\tau)\} \quad (2.5)$$

$$R_{sw}(\tau) = E\{s(t) \cdot w(t+\tau)\} \quad (2.6)$$

Naturalmente, se os sinais $s(t)$ e $w(t+\tau)$ não são correlacionados, R_{sw} assume o valor nulo. Além do espectro de frequências, a excitação é outra importante característica do sistema e está intimamente relacionada com a amplitude do espectro do sinal, seja para o sinal de excitação ou para o sinal de resposta do sistema. Quanto maior for a amplitude do espectro do sinal de excitação, num determinado intervalo de frequências, mais “rico” será o sinal de resposta da planta, $y(t)$, neste mesmo intervalo de frequências, ou seja, maior será o conteúdo de informações sobre a dinâmica do sistema, presente nos dados de $y(t)$. Verifica-se este efeito através da amplitude do espectro de $y(t)$. Em notação matemática, a amplitude do espectro de um sinal $s(t)$ é equivalente a:

$$A_a = |\Phi_{ss}(\omega)|^2 \quad (2.7)$$

Na literatura [Lj99], o gráfico que relaciona a excitação do sinal com o intervalo de frequências é chamado de periodograma. A princípio, um sinal de excitação para a identificação de modelos do processo visando o controle, deverá cobrir um grande intervalo de frequências, de modo que o comportamento dinâmico do processo seja quase totalmente conhecido. Entretanto, ao iniciar a tarefa de identificação, a primeira questão a ser levantada é: “Quais deverão ser as frequências do sinal de excitação?”. Na identificação de modelos para o controle do processo, é interessante se conhecer bem o sistema na chamada frequência de corte ou *crossover frequency*. Esta é a frequência em que as funções de sensibilidade $S(s)$ e sua complementar $T(s)$, apresentam a mesma magnitude e caracteriza o ponto em que o controlador trabalhará. A função $S(s)$ é igual a $1/[1+C(s)G(s)]$, onde $C(s)$ representa a equação do controlador e $G(s)$ é a função de transferência que representa o modelo do sistema. A função $T(s)$ compreende à resposta do sistema em malha fechada, isto é, relaciona o valor desejado da variável controlada e a própria variável controlada. Matematicamente, $T(s) = 1 - S(s)$.

Desta forma, sinais que excitem razoavelmente a zona de frequências que contenha a frequência de corte, maiores informações para um bom projeto de controladores trarão. Obviamente, se o objetivo da identificação é obter modelos que representem bem a parte estacionária, as excitações deverão ser concentradas na zona de baixas frequências. Mas, como normalmente os controladores atuam na zona de frequências intermediárias, basta identificar o sistema na zona da frequência de corte.

Dando continuidade ao trabalho, na seção seguinte, as perturbações típicas utilizadas no cenário industrial, seus respectivos espectros e suas principais características serão apresentadas e aplicadas num sistema SISO (*Singular Input, Singular Output*).

2.2 Exemplo Introdutório sobre Perturbações

Para visualizarmos as principais perturbações aplicadas em indústrias de processo e suas características, nesta seção é apresentado um sistema SISO. O sistema é composto por dois tanques, com volumes iguais a 0,87 litros, dispostos em série e com alimentação de água no primeiro tanque. Neste mesmo tanque existe um aquecedor, cuja potência fornecida será a variável manipulada. Deseja-se controlar a temperatura da água de descarga do segundo tanque. O principal distúrbio é a temperatura da água de alimentação. As temperaturas de interesse são duas, a saber: T_0 , temperatura da água de alimentação (alimentada no tanque 1) e T_2 , a qual é a temperatura da água na saída do tanque 2. A Figura 2.1 ilustra o sistema em que serão aplicados e apresentados os diferentes tipos de perturbação.




Figura 2.1: Representação esquemática do sistema de dois tanques com aquecimento.

O ponto de operação em que se pretende gerar os dados é caracterizado pela temperatura T_2 de 24,8°C, potência de aquecimento de 1000 Watts e vazão de alimentação de água, F , igual a $5,00 \cdot 10^{-5} \text{ m}^3/\text{s}$. As próximas seções deste capítulo mostram os diferentes tipos de perturbação, aplicados ao sistema de dois tanques com aquecimento. É importante ressaltar que as perturbações apresentadas a seguir foram realizadas no modelo fenomenológico da unidade de dois tanques com aquecimento, implementado em MATLAB/Simulink, embora no capítulo 4 serão apresentados dados reais desta unidade.

2.3 Perturbação Degrau

A perturbação degrau ou step, é caracterizada pela mudança abrupta no valor da variável manipulada, a qual pode assumir dois valores distintos, $u1$ e $u2$. Geralmente, nas indústrias de processo, a perturbação degrau é feita no mínimo, duas vezes, em sentidos opostos, para minimizar a variabilidade da variável controlada durante o teste de identificação. Este tipo de perturbação pode remover o sistema do ponto de operação. A Figura 2.2 apresenta uma típica seqüência de degraus dentro do cenário industrial.




Figura 2.2: Seqüência de degraus aplicada à potência de aquecimento da planta de dois tanques com aquecimento.

A perturbação degrau promove a excitação, principalmente, das características estacionárias do sistema, isto é, o intervalo de baixas frequências. É, sem sombra de dúvidas, o tipo de sinal de excitação mais utilizado no meio industrial, em testes para a identificação de modelos, por ser de fácil execução e identificação. A Figura 2.3 apresenta o periodograma do sinal de excitação do tipo degrau (Figura 2.2) aplicado na planta de dois tanques com aquecimento. É importante ressaltar que todos os periodogramas apresentados nestes trabalho foram confeccionados a partir das subrotinas do *Signal Processing Toolbox* do MATLAB [SIGPRO].

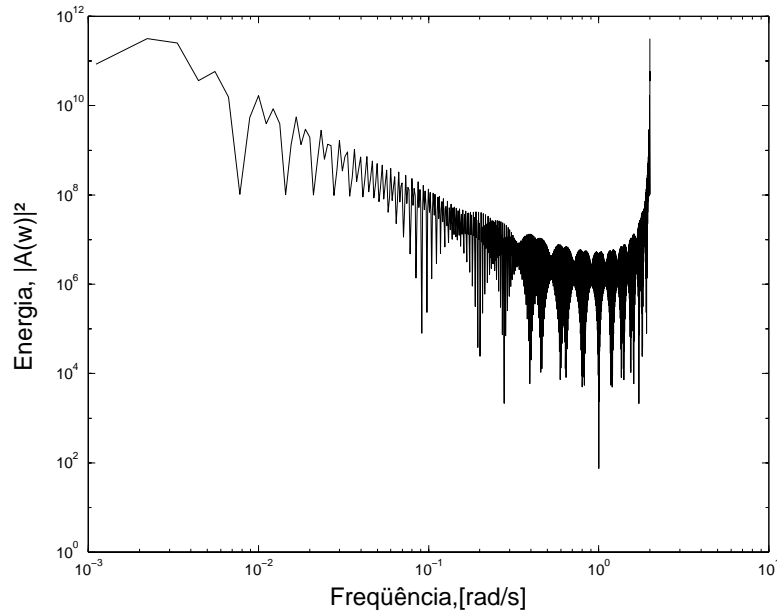


Figura 2.3: Periodograma do sinal degrau aplicado à planta de aquecimento e reciclo.

Pelos dados da Figura 2.3, observa-se que o sinal do tipo degrau excita fortemente a região de baixas frequências. À medida que a frequência aumenta, a excitação diminui.

2.4 Perturbação Relé

Originalmente, os sinais produzidos por relés foram utilizados no autoajuste de controladores PID's [Yu98]. Basicamente, existem dois tipos de relés: relé ideal e relé com saturação. Outros tipos de relés fundamentam-se nestes dois tipos básicos e apresentam melhorias para processos com ruído de medida e distúrbios na carga. Os relés atuam em malha *feedback*, tendo como entrada o erro entre o *setpoint* da variável controlada e o valor medido da variável controlada. Como resposta, os relés produzem ações de controle específicas, de acordo com a implementação do relé. A 2.4 mostra, de forma esquemática, uma malha de controle na qual o relé está inserido.




Figura 2.4: Representação esquemática de uma malha de controle com atuação de relé.

É importante ressaltar que as oscilações provocadas automaticamente pelos relés devem-se ao fato do sistema ter a ordem do denominador no máximo 3 unidades maior que o numerador ou ser de fase não-mínima, isto é, apresentar ou tempo morto ou resposta inversa. Caso contrário, o relé não produz as mudanças de níveis (nível alto ou nível baixo) [Yu98]. As perturbações geradas com relés na planta de dois tanques com aquecimento, apresentadas a

seguir, só foram realizadas devido à adição de um tempo morto na medida de temperatura do fluido da corrente de descarga do segundo tanque. O tempo morto, em termos de diagrama de blocos apresentado na Figura 2.4, está contido dentro do modelo da planta, $G(s)$.

2.4.1 Relé Ideal

O relé ideal provoca perturbações em apenas dois níveis da variável manipulada, um inferior e outro superior. A mudança de um nível para outro depende do sinal do erro. A brusca mudança de níveis da variável manipulada causa oscilações na resposta do sistema, em torno do valor de setpoint. A Figura 2.5 ilustra a representação da função da resposta do relé ideal.




Figura 2.5: Representação da função da resposta do relé ideal.

Pode-se observar através da função apresentada pela Figura 2.5 que as possíveis ações tomadas pelo relé ideal são duas: uma com valor positivo e outra com valor negativo, ambas com a mesma intensidade. Uma ou outra ação será tomada em função do sinal do erro da variável controlada. Para ilustrar um ensaio de identificação com teste relé ideal, a Figura 2.6 apresenta dados típicos deste tipo de perturbação quando aplicado ao sistema de dois tanques com aquecimento.




Figura 2.6: Dados do teste relé ideal aplicada a planta de dois tanques com aquecimento.

Na Figura 2.6, pode-se observar que as perturbações geradas pelo relé ideal não removem em demasia o sistema de seu ponto de operação, isto é, a média dos valores da resposta do sistema assume, aproximadamente, o valor do ponto de operação. Uma das características deste tipo de sinal é a promoção de uma grande excitação em uma faixa específica de frequências, como ilustra a Figura 2.7.




Figura 2.7: Periodograma do sinal de excitação gerado por um relé ideal.

Observa-se, pelos dados da Figura 2.7, que entre as frequências 10^{-2} e 10^{-1} rad/s, existe grande excitação, a qual é superior à excitação promovida pela perturbação do tipo degrau, conforme apresentou a Figura 2.3.

2.4.2 Relé com Saturação

O relé com saturação difere do relé ideal por permitir ações de controle intermediárias, relacionadas ao valor do erro da variável controlada. Entre as ações de controle máxima, \bar{a} , e mínima permitidas, $-\bar{a}$, a resposta do relé é o próprio erro multiplicado por um fator proporcional à diferença entre os limites máximo e mínimo. Acima ou abaixo dos limites, a resposta do relé vale os próprios limites máximo e mínimo, respectivamente. A inclinação da reta entre os dois limites é chamada de k . A Figura 2.8 ilustra a representação da função da resposta do relé com saturação.




Figura 2.8: Representação da função da resposta do relé com saturação.

A Figura 2.9 mostra os sinais típicos gerado em teste relé com saturação.




Figura 2.9: Dados de teste de identificação com perturbações gerados a partir do relé com saturação na planta de dois tanques com aquecimento.

Da mesma forma que o relé ideal, o relé com saturação remove muito pouco o sistema de seu ponto de operação, por ser um sinal com média praticamente nula. Observa-se que o relé com saturação é uma generalização do sinal produzido por um relé ideal. Dependendo do valor da inclinação da equação do relé com saturação, cuja representação gráfica encontra-se na Figura 2.8, o sinal produzido pelo relé com saturação pode ser idêntico ao sinal do relé ideal (k tendendo a infinito). Justamente, a escolha do valor de k é um dos pontos limitantes deste tipo de sinal, uma vez que para valores baixos de k (menores que o ganho ultimate do sistema - ku -), o sistema não instabiliza, obviamente, não gerando oscilações permanentes. Na literatura [Yu98], uma das formas de se obter o valor de k é realizar um teste com relé ideal e se obter uma estimativa do valor de ku . A inclinação k , do teste com relé com saturação vale 1,4 vezes o valor da estimativa de ku obtida através do teste com relé ideal. Similarmente ao relé ideal, o espectro do sinal produzido por relés com saturação excitam fortemente o sistema apenas em uma estreita faixa de frequências, de acordo com o gráfico mostrado através da Figura 2.10.

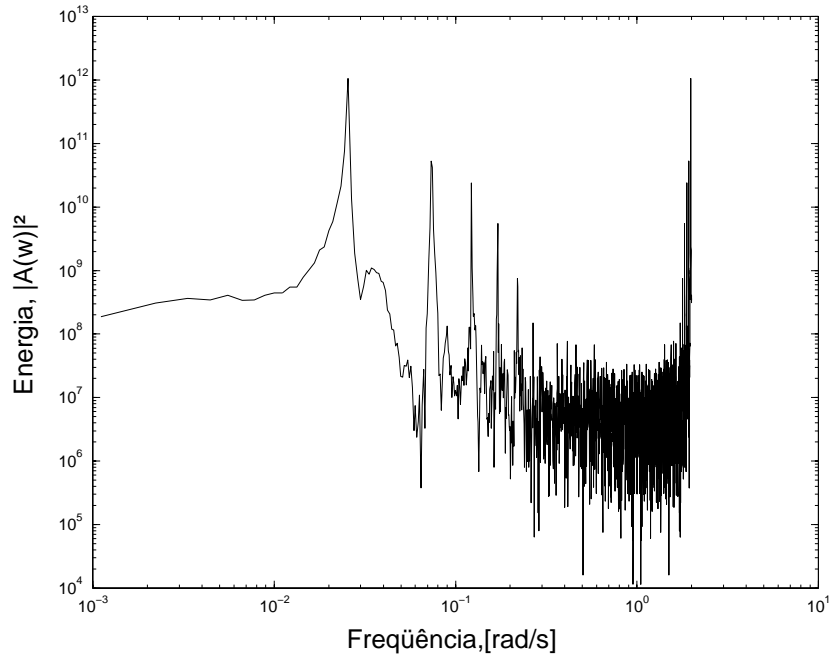


Figura 2.10: Periodograma do sinal de excitação gerado por um relé com saturação.

2.5 Sinal PRBS

O sinal PRBS (*Pseudo Random Binary Signal*) é, juntamente com a perturbação do tipo degrau, o sinal mais conhecido e empregado no cenário industrial. As ações da variável manipulada, assim como no relé ideal, podem assumir apenas dois valores (nível alto e nível baixo), entretanto, permanece períodos distintos em cada valor, aleatoriamente. De forma diferente em relação ao degrau, o tempo de permanência do sinal em cada nível apresenta um limite mínimo e um limite máximo os quais são matematicamente determinados.

A grande vantagem do sinal PRBS é sua capacidade de excitar com muita intensidade, uma grande faixa de frequências. Para isto, devem ser calculados o período máximo e o mínimo em que o sinal deve ficar num determinado valor. De acordo com a literatura [Luy92, capítulos 6 e 7], o período mínimo é calculado através da Equação (2.8).

$$T_{CL} = \frac{2,8 \cdot \left(\tau_{DOM} + \frac{\tau_D}{2} \right)}{\alpha} \quad (2.8)$$

onde τ_{DOM} é a constante de tempo dominante ou característica do sistema e τ_D é uma aproximação do valor do tempo morto do processo. A variável α é a relação entre a velocidade do sistema em malha aberta e em malha fechada, dada pela Equação (2.9).

$$\alpha = \frac{\tau_{OL}}{\tau_{CL}} \quad (2.9)$$

onde τ_{OL} é a constante de tempo do sistema em malha aberta e τ_{CL} é a constante de tempo do sistema em malha fechada. O período máximo em que o valor da variável manipulada pode permanecer constante é um múltiplo do período mínimo. Este múltiplo é o valor de N , o qual é calculado pela Equação (2.10).

$$N = \frac{2 \cdot \pi \cdot \alpha \cdot \beta}{2,8} \quad (2.10)$$

onde β indica o quanto deve ser excitada a zona de baixas frequências. $\beta = 3$ está relacionado a excitar as frequências correspondentes até 95% do tempo de assentamento do sistema. Para $\beta = 4$, em torno de 98% do tempo de assentamento e para $\beta = 5$, 99%. A Figura 2.11, apresenta os sinais típicos de teste de identificação com perturbação tipo PRBS.




Figura 2.11: Dados de teste de identificação com perturbações geradas através de sinal PRBS na planta de dois tanques com aquecimento.

O sinal PRBS tem a capacidade de excitar uma longa faixa de frequências com elevada excitação. Esta característica torna o sinal PRBS uma perturbação muito útil na identificação, por enriquecer as informações do sinal de resposta da planta, ao menos para sistemas monovariáveis [Luy92], [Lj99]. Este fato pode ser observado através da Figura 2.12.




Figura 2.12: Periodograma do sinal de excitação do tipo PRBS.

2.6 Perturbações geradas pelo controlador

Os sinais das perturbações degrau, relé e PRBS são feitas sem a presença de um controlador. Em malha fechada, isto é, na presença de um controlador, é possível projetar testes de identificação em que o controlador produza, de acordo com seu ajuste e características do sistema, perturbações que não sigam nenhum padrão como aqueles apresentados anteriormente.

Em malha fechada, existem dois pontos em que as perturbações podem ser realizadas, de modo que o controlador aplique ações na planta para identificação: no *setpoint* e no *u-bias* (ação de controle base) do controlador [LJ99]. As perturbações no *setpoint* e no *u-bias* podem ser quaisquer uma das apresentadas nos itens anteriores. Estas perturbações provocam erro na variável controlada e, por consequência, o controlador atua no sistema, gerando perturbações que efetivamente serão aplicadas na planta. A Figura 2.13 mostra os dados da planta de dois tanques com aquecimento após perturbações do tipo degrau no *u-bias* do controlador.




Figura 2.13: Perturbações em malha fechada na planta de dois tanques com aquecimento. No gráfico superior: *setpoint* (linha cheia) e temperatura T_2 (linha tracejada). No gráfico intermediário: ação de controle calculada pelo controlador (linha cheia) e ação total de controle (linha tracejada). No gráfico inferior, tem-se a perturbação adicional aplicada ao u -bias do controlador.

A grande vantagem da realização das perturbações em malha fechada é a presença do controlador. De acordo com seu ajuste, é possível rapidamente, rejeitar os efeitos provocados pelas perturbações da variável manipulada na variável controlada, diminuindo o tempo de execução do teste de perturbações. No entanto, a presença do controlador correlaciona a variável controlada com a ação de controle a ser tomada. Este efeito é extremamente indesejado, uma vez que esta correlação dificulta o processo de geração do modelo, o qual poderá ser identificado como o inverso do modelo do controlador em vez da planta. A excitação provocada pelo sinal gerado pelo próprio controlador é dependente do ajuste do controlador. Para a sintonia empregada para o sistema de aquecimento com dois tanques, o espectro da ação de controle pode ser vislumbrado pelo periodograma da Figura 2.14.




Figura 2.14: Periodograma do sinal de perturbação gerado pelo controlador PI do sistema de dois tanques com aquecimento.

2.7 Comparação entre os Diferentes Tipos de Perturbações

Para a identificação de sistemas, como já fora observado anteriormente, é necessário buscar dados ricos em informações a respeito do comportamento do processo. Estes dados podem ser obtidos do próprio histórico de dados de planta, em que procedimentos operacionais produziram perturbações no sistema e também, obviamente, através de dados providos dos testes planejados de identificação.

Caso seja necessário o planejamento e a execução de testes de identificação, qual o tipo de perturbação que se deve utilizar? É necessário abrir a malha de controle para a realização das perturbações? Sabe-se que as perturbações do tipo degrau são as mais encontradas e aplicadas no cenário industrial, pela facilidade de implementação e identificação. Entretanto, a amplitude do degrau é definida, na atualidade, através de experiências práticas com a identificação de plantas industriais. O grande inconveniente é a remoção da unidade de seu ponto de operação estável, que dependendo do sistema, pode ser relativamente alto.

As perturbações do tipo relé, tanto o relé ideal quanto o relé com saturação, são boas alternativas para a identificação automática, assim como são usados para o autoajuste de controladores PID's. Entretanto, os limites máximo e mínimo também devem ser fornecidos para o algoritmo de geração das perturbações, recaindo na mesma limitação do projeto de sinais do tipo degrau.

Uma das alternativas disponíveis para projeto de sinais são os sinais PRBS, como foi visto na subseção 2.5. No entanto, até que ponto é necessário excitar muitas frequências diferentes do sistema, se na prática, para o controle do processo é necessário respeitar um compromisso entre identificação da dinâmica rápida e do estado estacionário? Este tipo de sinal pode trazer

um tempo de perturbação elevado, desnecessário muitas vezes. Somado-se a este fato, a energia das perturbações deve ser também definido de modo experimental.

Quanto à questão da identificação em malha fechada, o grande problema é a correlação entre os distúrbios não-medidos e as ações de controle, provocada pela presença do controlador. Caso o sistema não apresente historicamente grandes distúrbios, a identificação em malha fechada apresenta-se, de forma imediata, como solução simples da identificação do sistema. Contudo, novamente surge a necessidade de se calcular a amplitude das perturbações, seja nos setpoints, seja na ação de controle de referência. A Tabela 2.1 agrupa os fundamentos para a escolha do padrão de perturbação a ser adotado visando a identificação de modelos dinâmicos.

Tabela 2.1: Quadro comparativo entre os principais tipos de perturbação existentes.

| Atributos | Tipo de Perturbação | | | |
|---|--|------------------------------------|---|--|
| | Modo Malha Aberta | | | Modo Malha Fechada |
| | Degrau | Relé | PRBS | |
| Duração do teste | Longo | Curto | Longo | Curto |
| Facilidade de Execução | Simples, porém deve-se antes abrir a malha de controle | Simples | Simples, mas tedioso se não for automatizado. | Simples |
| Deslocamento do ponto de operação da planta | Alto, em alguns casos. | Mínimo | Médio. | Baixo, mas usualmente superior ao deslocamento provocado pelo ensaio relé. |
| Cálculo das Amplitudes | Heurístico | Heurístico | Heurístico | Heurístico |
| Sensibilidade a distúrbios não medidos | Alto | Alto | Intermediário | Alto (presença do controlador correlaciona u e y). |
| Sensibilidade a ruídos de medida | Baixa | Alta | Baixa | Baixa |
| Frequências Excitadas | Baixas | Na faixa de atuação do controlador | Todas, ou a grande maioria delas | Depende da sintonia do controlador. |
| Uso em sistemas MIMO? | Sim | Não | Raramente | Pouco Explorada |

2.8 Perturbações para o Caso Multivariável

As perturbações apresentadas até o momento são direcionadas para o caso em que o sistema apresente apenas uma variável de entrada e uma variável de saída (caso SISO). O que se observa na literatura é a ampla utilização de testes com sinais do tipo degrau e sinais pseudo-aleatórios, principalmente em malha aberta.

Para o caso multivariável (MIMO), a variedade de tipos de sinais fica reduzida, devido ao aumento da dificuldade de implementação e execução dos testes, principalmente quando se refere aos testes relés. Entretanto, pode-se observar a utilização da identificação em malha fechada com o uso de sinais binários randômicos [Zhu02]. Na prática, os testes degrau são os mais aplicados industrialmente e de forma independente para cada variável manipulada. No entanto, este procedimento não é aconselhável para sistemas com forte acoplamento, uma vez que o acoplamento faz com que o sistema seja removido do ponto de operação normal. Além disto, as perturbações produzidas por esta técnica desconsideram os efeitos da direcionalidade do sistema, fato que no próximo capítulo, será minuciosamente abordado e uma nova metodologia de perturbações capaz de levar em conta a direcionalidade do sistema e calcular automaticamente as amplitudes dos sinais de perturbação, será apresentada. No Capítulo 3 ainda, para ilustrar as potencialidades da nova metodologia, serão estudados alguns sistemas simulados com a presença e ausência de acoplamento.

Capítulo 3

Metodologia de Perturbações Multivariáveis Proposta

No capítulo anterior foi apresentado os principais tipos de sinais de excitação. Aliando-se este conteúdo ao conteúdo do apêndice, o qual foca os algoritmos de identificação correntemente utilizados, pode-se estabelecer uma base teórica para o desenvolvimento de uma nova metodologia de realização dos testes de identificação.

De maneira geral, existem grandes desafios no processo de identificação de modelos em muitas indústrias de processo a serem superados, excluindo todos os demais fatores limitantes do desempenho do controle do processo (tempo morto, falhas de instrumentos, erros de projeto, etc), gerados por múltiplas causas, dentre as quais destacam-se: distúrbios externos não medidos nas variáveis de saída, estruturas de modelos incompatíveis com as características do processo, utilização de algoritmos de identificação limitados, mal condicionamento e direcionalidade do sistema, realização de testes de identificação cujos dados apresentam poucas informações a respeito do comportamento multivariável do sistema.

Com o objetivo de melhorar o processo de identificação e, basicamente, gerar dados que venham a maximizar as informações dinâmicas obtidas do processo, minimizando o tempo de retirada do processo de seu ponto de operação, foi proposta uma nova metodologia de projeto de perturbações a ser apresentada no capítulo que aqui se inicia.

3.1 Principais Compromissos e Objetivos

Os sistemas multivariáveis representam quase a totalidade dos processos industriais existentes. A principal característica destes sistemas é a interação entre seus diversos canais. Somada a este fato, cada vez mais as plantas industriais estão integradas mássica e energeticamente, fruto da necessidade da redução de custos. Em decorrência destes fatores, as perturbações em sistemas multivariáveis devem ser bem planejadas, de modo que o resultado final seja a geração de dados ricos para a etapa de identificação a um custo reduzido.

Usualmente, as unidades industriais operam em condições praticamente estacionárias (ponto de operação economicamente viável). Este fato faz com que a grande maioria das ações de controle aplicadas à planta para a rejeição de distúrbios, principalmente, não contenham energia suficiente para a excitação do sistema e, por consequência, os dados apresentam baixa relação sinal/ruído (*SNR - Signal to Noise Ratio*), a qual é dada por:

$$SNR(\omega) = \frac{|\phi_{uu}(\omega)|}{|\phi_{ee}(\omega)|} \quad (3.1)$$

onde $|\phi_{uu}(\omega)|$ e $|\phi_{ee}(\omega)|$ são, respectivamente, os espectros dos sinais da(s) variável(eis) manipulada(s) e do ruído da(s) variável (eis) de saída avaliados na frequência ω . Na prática, esta relação determina quantas vezes a energia o sinal de excitação é maior que a energia do sinal de ruído da variável controlada. Em outras palavras, perturbações de amplitude elevada trarão valores elevados de SNR e o ruído de medida terá efeito desprezável em relação à resposta do sistema, mas removerão a planta do ponto de operação. Caso isto aconteça, como consequência, o sistema passará a produzir produtos fora de especificação. No entanto, os dados gerados são ricos em informações sobre o comportamento dinâmico do processo. Além disto, o sistema apresentará, conforme sua natureza, um determinado tempo para retornar ao estado estacionário no qual estava operando no momento anterior às perturbações de excitação aplicadas ao processo para a identificação, resultando em ampliação dos custos. Ressalta-se ainda que os testes de identificação necessitam de alocação de recursos humanos qualificados para projetar e aplicar as seqüências de perturbações, bem como identificar e analisar os modelos obtidos, o que geram custos pertinentes ao processo de identificação. É interessante observar que cada sistema linear, neste trabalho expresso basicamente através de funções de transferência, apresenta valores e vetores característicos para cada frequência (domínio complexo). Determinados sistemas são ditos mal condicionados por terem a razão entre o maior e o menor valor característico muito elevada, o que dificulta a inversão de matrizes e, por consequência, o projeto do controlador. Em termos práticos, o mal condicionamento torna o sistema sensível a pequenas variações nos dados de entrada, que neste trabalho são as direções das perturbações a serem aplicadas. Entenda-se por direções das perturbações (direções de entrada), o vetor composto pelos valores das variáveis manipuladas do sistema. Desta forma, o mal condicionamento leva o sistema a responder de forma muito diferente (duas ou mais variáveis controladas) a direções de entrada semelhantes. A este efeito de variação das respostas do sistema ao longo da frequência dá-se o nome de "direcionalidade do sistema". Cabe salientar que além do condicionamento do sistema, existe também o condicionamento mínimo, que matematicamente é o menor valor de condicionamento do

sistema para o melhor escalonamento possível do sistema. Entenda-se por escalonamento do sistema o procedimento de obtenção de matrizes para a equivalência de unidades de medida das variáveis de entrada e de saída do sistema [TRI97]. Para sistemas multivariáveis, como observado no Capítulo 2, tradicionalmente, as perturbações são do tipo degrau, nas quais as variáveis manipuladas são alteradas de forma não simultânea. Este procedimento adotado e simplificado de se obter uma seqüência de perturbações, permite melhor visualizar os efeitos de cada variável manipulada nas variáveis controladas. No entanto, devido ao mal condicionamento dos sistemas, em determinados casos, para que os valores de SNR sejam adequados para a obtenção de modelos representativos do sistema, é necessário realizar perturbações com amplitudes muito elevadas, o que torna a simples seqüência de degraus inviável, por ampliar o tempo em que o sistema permanece fora de seu ponto de operação. Logo, faz-se necessário perturbar o processo de acordo com as principais direções do sistema, mesmo que estas direções exijam variações simultâneas nas variáveis manipuladas. Quando esta situação ocorre, pode-se dizer que as variáveis manipuladas combinam-se de tal maneira que o sistema é excitado sem ser retirado por muito tempo de seu ponto de operação.

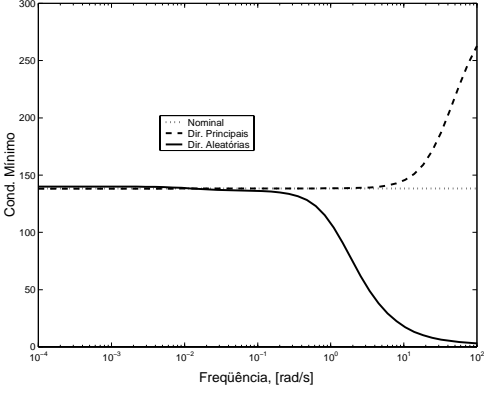
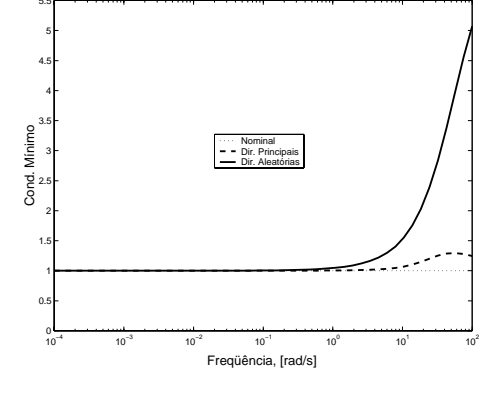
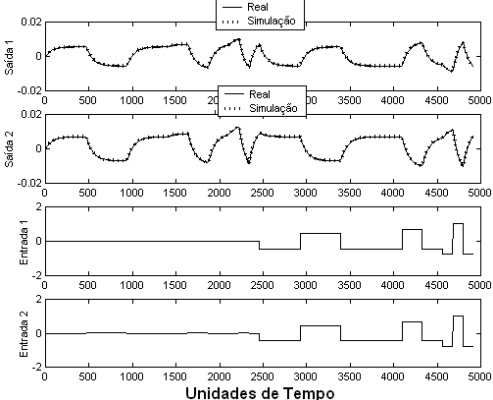
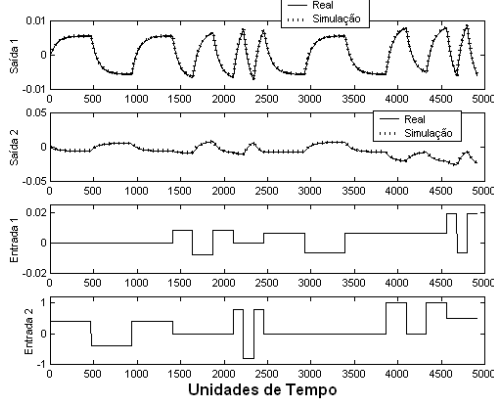
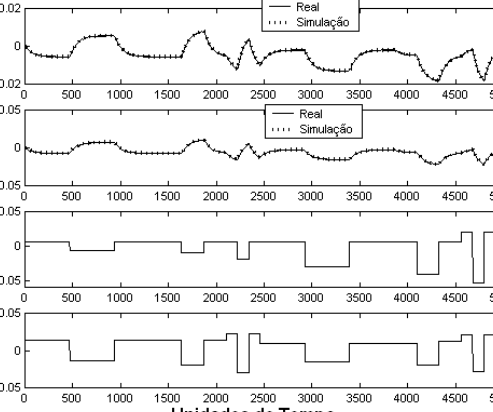
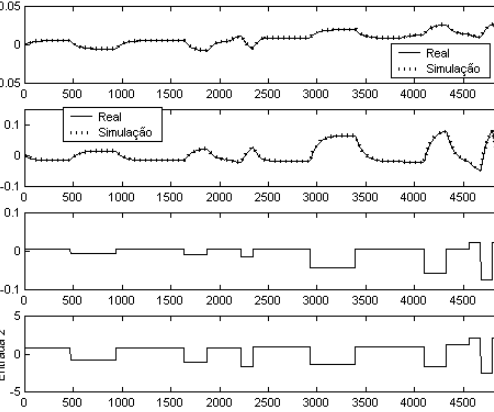
É interessante considerar no projeto de perturbações multivariáveis os efeitos da direcionalidade do sistema e do acoplamento entre os diversos canais da matriz de modelos dinâmicos do sistema. É recomendável perturbar o sistema num determinado número de direções distintas, para que, devido a presença de possíveis zeros de transmissão, os efeitos das perturbações não sejam anulados entre si. Sugere-se que este número seja no máximo igual ao número de entradas do sistema, para que o tempo de duração do teste de identificação não seja tão extenso. Este valor é suficiente para que se possa identificar modelos de sistemas multivariáveis representativos. Para cada freqüência no domínio complexo, existe uma direção das variáveis de entrada que fornecerá o maior ganho multivariável do sistema e outra direção das variáveis de entrada que provocará o menor ganho do sistema. Para estas direções de máximo e de mínimo ganho, define-se o termo “principais direções do sistema”. Para ilustrar a importância da direcionalidade do sistema na identificação do processo, considere os testes de identificação em uma coluna de destilação de alta pureza introduzida por Skogestad em 1988 [WW99], nas configurações LV e DV para controle de composições de topo e de fundo, onde L, V e D são as taxas de refluxo, vaporização e destilado, respectivamente. A operação deste sistema na estrutura de controle LV gera um sistema mal-condicionado (condicionamento mínimo igual a 138,5 em todo o intervalo de freqüências), reduzindo o desempenho do controlador, e, obviamente, dificultando a identificação do processo. Já a estrutura de controle DV torna o sistema razoavelmente bem condicionado (condicionamento mínimo igual a 1, em todo o intervalo de freqüências). Visando ilustrar a importância da direcionalidade, foram gerados dados, para o sistema operando tanto na estrutura DV, quanto na estrutura LV, considerando-se e não se considerando as principais direções do ganho multivariável do sistema. O modelo original do processos, para cada estrutura de controle, é representado por,

$$G_{LV}(s) = \frac{e^{-s}}{75s + 1} \begin{bmatrix} 0,878 & -0,864 \\ 1,082 & -1,096 \end{bmatrix} \quad (3.2)$$

$$G_{DV}(s) = \frac{e^{-s}}{75s + 1} \begin{bmatrix} -0,878 & 0,014 \\ -1,082 & -0,014 \end{bmatrix} \quad (3.3)$$

Tanto os dados dos testes de identificação quanto o condicionamento do sistema e dos modelos identificados estão apresentados na Tabela 3.1, para ambas as estruturas de controle.

Tabela 3.1: Dados gerados para a identificação do modelo de uma coluna de alta pureza operando em estrutura LV e em estrutura DV (gráficos inferiores). O condicionamento dos modelos identificados para o sistema nas estruturas LV e DV estão representados nos gráficos superiores, assim como o condicionamento mínimo do sistema em ambas as estruturas.

| Estrutura LV | Estrutura DV |
|--|---|
| <p style="text-align: center;">Condicionamento Mínimo</p>  | <p style="text-align: center;">Condicionamento Mínimo</p>  |
| <p style="text-align: center;">Perturbações nas principais direções</p>  | <p style="text-align: center;">Perturbações nas principais direções</p>  |
| <p style="text-align: center;">Perturbações em direções aleatórias</p>  | <p style="text-align: center;">Perturbações em direções aleatórias</p>  |

Conforme os gráficos da Tabela 3.1, pode-se observar que perturbações aplicadas em direções apropriadas produzem dados mais ricos para a identificação, em relação à aplicação de perturbações em direções quaisquer tal como usualmente ocorre em situações práticas (veja os gráficos dos condicionamentos mínimos). Esta necessidade de se perturbar nas principais direções do sistema é mais evidente quando o sistema é mal condicionado, da mesma forma que o modelo da estrutura LV da coluna de destilação de alta pureza, anteriormente apresentada. A grande direcionalidade da estrutura LV revela uma tendência dos canais de sua matriz de transferência a anularem os efeitos das perturbações multivariáveis entre si, diminuindo a relação sinal-ruído. E este é o principal motivo para a direcionalidade ser considerada no planejamento de perturbações. Em contraposição, sistemas com modelos bem condicionados, a exemplo da estrutura de controle do tipo DV da coluna de alta pureza, a importância da direcionalidade não é tão grande, e o projeto das perturbações pode ser simplificado, isto é, as direções das perturbações podem ser escolhidas aleatoriamente. Sem sombra de dúvidas, as perturbações mais simples ocorrem nas direções da matriz identidade, ou seja, cada variável manipulada é alterada de uma só vez. Esta simples seqüência é adotada pela maioria das indústrias de processos, embora alguns sistemas apresentem problemas de mal condicionamento. Sendo assim, é comum haver, em algumas unidades destas indústrias, dificuldades na identificação dos modelos, uma vez que optaram por realizar perturbações demasiadamente simplificadas.

Outro fato que, usualmente, pode ser observado em algumas indústrias de processos é a subutilização das informações depositadas nos sistemas *PIMS* (*Plant Information Management Systems*). Embora muitas informações contidas nestes sistemas não contenham informações dinâmicas do processo, existem trechos de dados muito ricos, geralmente apresentando variações significativas nas entradas do sistema para possíveis rejeições de distúrbios. Este fato não acontece por acaso: a cada instante de amostragem estão sendo gerados milhares de novos dados. Para o engenheiro de controle, a tarefa de pesquisar no histórico de dados os melhores trechos para a obtenção de modelos não é uma tarefa simples. Em alguns casos, este rastreamento promove grande economia nos testes de identificação, tendo em vista que um menor número de variáveis manipuladas deverão ser alteradas nos testes caso se tenha conseguido obter modelos para as demais entradas do sistema. Neste sentido, é interessante que se desenvolva uma ferramenta de análise dos dados de histórico que venha a fornecer os melhores intervalos para a identificação de modelos, sem a necessidade de novos testes ou com testes de reduzida duração. Pode-se fazer uma analogia entre o histórico dos dados de planta e uma grande mina de pedras preciosas. A mina deve ser trabalhada e lapidada de modo que se vislumbrem a riqueza que existe escondida dentro das rochas brutas.

Neste sentido, uma técnica de geração de dados ricos em informações para a identificação do modelo do sistema deve cumprir o compromisso de realizar perturbações rápidas e eficazes, removendo pouco o sistema do ponto normal de operação, considerando o comportamento multivariável do processo e gerando dados com boa relação sinal ruído. Além disto, a técnica de geração de dados ricos não pode menosprezar as informações contidas nos históricos dos sistemas *PIMS*, se um dos objetivos primordiais no meio industrial é a redução dos custos em todas as etapas do gerenciamento do processo. Este compromisso é o objetivo e a motivação

para o desenvolvimento de uma metodologia de projeto de perturbações para a identificação de modelos, a ser descrita a partir da subseção 3.2.

3.2 Metodologia Proposta

A metodologia para o projeto sistemático de perturbações para a identificação desenvolvida neste trabalho é composta, em sua essência, por duas etapas, citadas a seguir:

1º) análise do comportamento atual da unidade, registrado em dados históricos de processo, de modo a se gerar um pré-modelo do sistema.

2º) geração de perturbações baseadas no pré-modelo do sistema

A primeira etapa da metodologia inclui a obtenção de características relevantes, como por exemplo, a amplitude dos ruídos de medida, os valores máximos e mínimos que tanto as variáveis controladas quanto as manipuladas podem assumir. Ainda nesta etapa é feita uma análise da correlação entre as variáveis manipuladas e controladas, em vários trechos dos conjuntos de dados, de modo que o engenheiro de controle possa concentrar seus esforços em dados que realmente contenham informações sobre o comportamento dinâmico do processo. Feito isto, parte-se para a geração de um modelo prévio do sistema, ou pré-modelo, com os dados selecionados na análise de correlação. Desta forma, o pré-modelo sintetiza, as informações guardadas nos dados históricos. Em vista disto, este modelo prévio pode apresentar grandes incertezas, apesar da análise de correlação ser relativamente rigorosa.

Baseado no pré-modelo, inicia-se a segunda etapa do projeto de perturbações proposto: a etapa de cálculo da amplitude das perturbações e tempo de excitação que os sinais deverão conter. Estes cálculos são obtidos através do estudo da direcionalidade do sistema e da constante de tempo do pré-modelo. O resultado final são perturbações que capturem a direcionalidade do sistema e que pouco removem a planta do ponto de operação. Um maior detalhamento à respeito das duas etapas da metodologia será apresentado nas subseções seguintes.

3.2.1 Geração de Pré-Modelo a partir do histórico de dados de planta

O comportamento dinâmico de uma boa parte dos processos industriais pode ser aproximado satisfatoriamente por sistemas de primeira ordem com tempo morto (*FODT – First Order with Dead Time*). Tendo esta afirmação como base, através dos dados de planta e de informações experimentais, é possível construir um modelo *FODT*. Este tipo de modelo é razoavelmente fácil de ser identificado, e contém as principais informações do processo para o planejamento de perturbações (constante de tempo, ganho e tempo morto), além de ter a capacidade de representar uma variedade de processos industriais.

Esta etapa é crucial na qualidade das perturbações geradas e, obviamente, caso o pré-modelo seja suficientemente consistente para assumir a condição de modelo para a planta industrial, a necessidade de realização dos testes de identificação passa a ser mínima. No entanto, surge a questão: como obter um pré-modelo, se justamente é um modelo que se quer obter? A resposta está fundamentada numa triagem inicial realizada nos dados históricos da planta. Inicialmente, faz-se necessário organizar os dados que os engenheiros de controle já possuem, antes de realizar qualquer teste de identificação. Esta organização permitirá afirmar quais são os dados que contêm mais informações a respeito do comportamento dinâmico do sistema e quais os dados que podem ser descartados.

A organização dos dados históricos de planta sugerida pela metodologia aqui proposta, é baseada na análise de covariância entre as normas Euclidianas dos vetores de entrada e saída do sistema. Por que utilizar a norma quadrada? A norma Euclidiana ou norma quadrada está relacionada com a energia do sinal. Portanto, ao se aplicar a definição de covariância entre as normas dos vetores de entrada e de saída, poder-se-á determinar quais são as variáveis de entrada que mais afetam as saídas em um determinado conjunto de dados.

A norma Euclidiana de um vetor é dada por,

$$Norma2 = \sqrt{\sum_{j=1}^N x_j^2} \quad (3.4)$$

em que N é o número total de pontos do vetor x , e j é o índice de posição de cada elemento no vetor x . A medida que os dados são analisados de acordo com uma janela de tempo pré-estabelecida, é calculada a norma do vetor x correspondente. Observe que x não são os dados brutos do processo, e sim uma diferença entre os dados e a média aritmética dos mesmos. Para dados de plantas industriais, julgou-se coerente utilizar-se uma janela de dados de 10 (dez) minutos. Cabe salientar que o valor de dez minutos depende da dinâmica do sistema. Utilizou-se este neste trabalho porque a grande maioria dos processos apresentam constantes de tempo nesta ordem de grandeza. Para cada deslocamento de uma unidade de tempo de amostragem, o primeiro dado do vetor x é descartado e é inserido um novo dado na última posição deste vetor, similarmente ao sistema *FIFO* (*First in First Out*). Note que ao final da varredura, cada variável controlada e cada variável manipulada analisada terão um vetor de normas associado, composto dos valores das normas obtidas para cada janela móvel que se estabeleceu ao longo da varredura dos dados.

Com as normas calculadas, parte-se para a análise de correlação entre as normas das manipuladas e as normas das controladas. Nesta etapa, os vetores de normas gerados através do uso da Equação (3.4) analisados são divididos em alguns subconjuntos, com no mínimo 200 pontos cada um, de modo a garantir a qualidade da análise. A correlação entre dois vetores é dada, então, por,

$$Corr(k) = \frac{1}{N} \sum_{t=1}^N u(t) \cdot y(t+k) \quad (3.5)$$

onde N é o número de pontos do vetor $u(t)$, t é o índice de posição dos valores do vetor $u(t)$ e k é o índice que determina a defasagem do vetor $y(t)$ relação ao vetor $u(t)$. Observe que o vetor $y(t)$ deve conter um número maior de pontos que o vetor $u(t)$, tendo em vista que perturbações nas variáveis manipuladas afetam apenas os valores posteriores das saídas. Após uma perturbação, haverá um determinado tempo em que a energia do sinal de excitação transfere-se para o sinal de saída. Desta forma, a correlação entre os sinais de entrada e de saída, ou em relação às suas normas, tende a diminuir à medida que a defasagem entre ambos sinais aumenta. Por isso, pode-se afirmar que os primeiros valores do vetor de correlação entre $u(t)$ e $y(t)$ são os mais importantes, representando a maior transferência de energia das entradas para as saídas. Em suma, o algoritmo de busca dos melhores intervalos realiza as seguintes operações:

- 1) Cálculo da média aritmética de cada entrada (μ_u) e saída (μ_y) do conjunto bruto de dados.

$$\mu_y = \frac{\sum_1^N y(t)}{N} \quad \text{e} \quad \mu_u = \frac{\sum_1^N u(t)}{N}$$

- 2) Determinação das variáveis desvio, ou seja, a diferença entre os dados brutos e a média calculada no passo anterior. Este procedimento é feito tanto para as variáveis manipuladas quanto para as variáveis controladas. É importante ressaltar que a variável desvio ainda é dividida pelo maior desvio para cada variável, de modo que os valores das variáveis desvio fiquem normalizadas entre -1 e 1 .

$$\Delta y(t) = \frac{y(t) - \mu_y}{\max(y(t) - \mu_y)} \quad \text{e} \quad \Delta u(t) = \frac{u(t) - \mu_u}{\max(u(t) - \mu_u)}$$

- 3) Obtenção do vetor de normas para cada uma das variáveis desvio envolvidas calculadas, a partir do uso da Equação (3.4).
- 4) Cálculo dos vetores de correlação entre as variáveis manipuladas e controladas para cada um dos subintervalos de 10 (dez) minutos, determinados pela Equação (3.5).
- 5) Para cada subintervalo, o primeiro valor de cada vetor de correlação é considerado como mais importante. Se estes valores são maiores que a unidade, os subintervalos são selecionados para fazer parte do conjunto de dados mais propícios à identificação. Observe que em alguns subconjuntos nem todas as variáveis apresentar-se-ão correlacionadas, embora fisicamente estejam. Naturalmente, nestes conjuntos, os valores de correlação serão menores que a unidade. Em relação à escolha do valor de decisão ser igual 1, pode-se afirmar que este valor deriva dos valores de correlações obtidas entre dados de entrada e saída de uma coluna de destilação da PETROBRAS. Como foi observado, correlações maiores que a unidade entre as manipuladas e controladas produziram modelos de qualidade relativamente alta.

É possível verificar a correlação entre os vetores $\Delta y(t)$ e $\Delta u(t)$ sem o cálculo das normas. No entanto, foi observado que a correlação entre as variáveis de entrada e de saída realizada sem o uso da norma apresenta-se menos suavizada em relação à correlação com o uso das normas. Este fato pode ser evidenciado na Figura 3.1:




Figura 3.1: Correlação entre as variáveis de entrada e de saída para um determinado subintervalo de dados usando a norma dos vetores $\Delta y(t)$ e $\Delta u(t)$ (gráfico à esquerda) e não usando a norma (gráfico à direita).

A grande vantagem de não se usar a norma dos vetores $\Delta y(t)$ e $\Delta u(t)$ consiste na fácil determinação de um critério de decisão se as variáveis de entrada e saída estão correlacionadas, chamado neste trabalho de L_c , calculado como $L_c = 2,6 \sqrt{\sigma_u \cdot \sigma_y}$. L_c é uma estimativa da covariância do produto das amplitudes do ruído das entradas e das saídas. Se o maior valor de correlação entre as variáveis de entrada e de saída num determinado intervalo for superior ao valor de L_c , pode-se dizer que as variáveis analisadas estão correlacionadas. As variáveis σ_u e σ_y são os desvios padrão das variáveis de entrada e de saída no subintervalo cuja a distribuição dados mais se aproxima da distribuição normal, caracterizando o ruído destas variáveis. A determinação de σ_u e σ_y será apresentada na subseção 3.2.2.1. Como exemplo da utilização do critério L_c sem o uso da norma das entradas e das saídas, pode-se observar os dados da Figura 3.2.




Figura 3.2: Exemplo do uso do critério L_c de determinação dos melhores subintervalos de dados para a identificação.

De acordo com os dados dos gráficos da Figura 3.2, todos os subintervalos estão aptos a comporem o conjunto de dados de identificação, exceto os subintervalos 3, 4 e 10, uma vez que a correlação entre a entrada e a saída não foi superior ao valor de L_C .

Com os conjuntos de dados mais “ricos” para a identificação, apenas estudando o histórico dos dados de operação, o qual é vasto em muitas indústrias de processo, é possível determinar-se um pré-modelo de qualidade razoável. O algoritmo de busca das melhores regiões do histórico de dados para identificação do pré-modelo foi testado em dados históricos de uma coluna debutanizadora, da RECAP (PETROBRAS – Mauá, São Paulo), usando como valor de decisão para a escolha dos subintervalos o valor 1 (um). A princípio, foram analisados visualmente (inspeção visual) mais de 15 (quinze) conjuntos de dados de modo a se determinar os melhores intervalos para a identificação, além de se indicar quais são as variáveis mais propícias envolvidas em cada conjunto. Como a quantidade de dados é relativamente grande, neste trabalho será mostrado a aplicação do algoritmo em apenas um dos conjuntos de dados. Os dados brutos a serem analisados e apresentados neste trabalho estão concentrados nos gráficos da Figura 3.3 e da Figura 3.4.

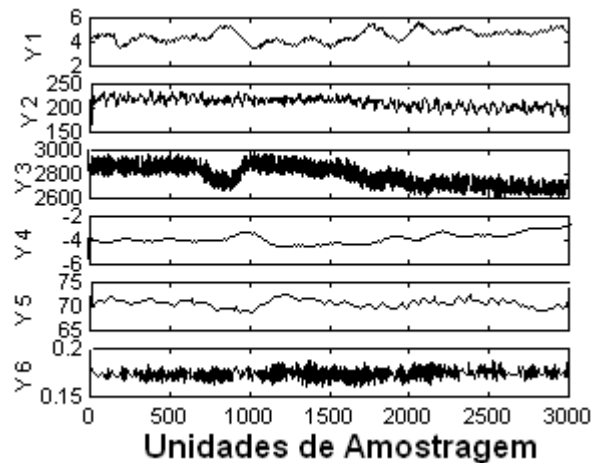


Figura 3.3: Dados das variáveis controladas da debutanizadora.

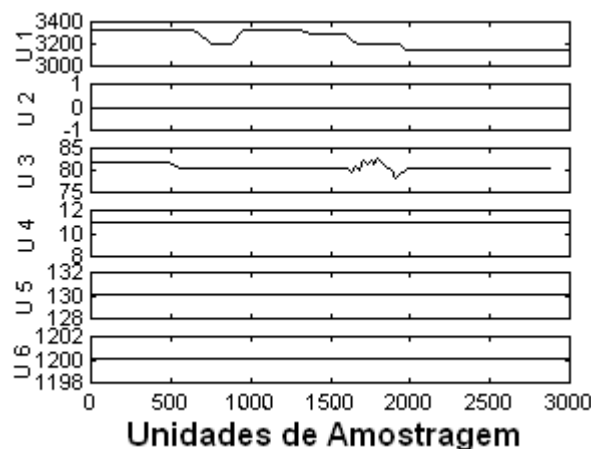


Figura 3.4: Dados das variáveis manipuladas da debutanizadora.

É visível, através dos dados da Figura 3.4 que apenas as variáveis $U1$ e $U3$ influenciam as saídas do sistema no conjunto de dados escolhido, mostradas nas Figura 3.3. Vale lembrar que as abscissas dos gráficos das Figuras 3.3 e 3.4 representam as unidades de amostragem, explícita apenas no último gráfico de cada uma das duas figuras. Através da sistemática de determinação dos melhores subconjuntos de dados, os valores das correlações entre as normas de todas as entradas e de todas as saídas é apresentada pela Tabela 3.2.

Tabela 3.2: Valores do primeiro elemento dos vetores de correlação entre as normas das variáveis desvios normalizados das entradas e saídas do sistema debutanizador da RECAP.

| S/E | U1 | U2 | U3 | U4 | U5 | U6 |
|-----|------|------|-------|------|------|------|
| Y1 | 1,61 | 0,00 | 5,41 | 0,00 | 0,00 | 0,00 |
| Y2 | 2,45 | 0,00 | 8,26 | 0,00 | 0,00 | 0,00 |
| Y3 | 1,97 | 0,00 | 6,65 | 0,00 | 0,00 | 0,00 |
| Y4 | 4,83 | 0,00 | 16,26 | 0,00 | 0,00 | 0,00 |
| Y5 | 1,31 | 0,00 | 4,43 | 0,00 | 0,00 | 0,00 |
| Y6 | 2,78 | 0,00 | 9,37 | 0,00 | 0,00 | 0,00 |

É importante ressaltar que cada subintervalo apresenta uma tabela com os valores das correlações (ponto inicial, com $k = 0$) tal qual a Tabela 3.2. Como as correlações entre as saídas e as entradas $U1$ e $U3$ são maiores que 1 (um), pode-se dizer que estas duas variáveis manipuladas influenciam as saídas e o subintervalo que contém as primeiras perturbações é candidato a fazer parte do conjunto de dados para a identificação do pré-modelo. Esta mesma análise é feita para os demais subconjuntos de dados, de modo que ao final desta etapa se tenham dados do histórico sendo aproveitados de uma maneira mais nobre. Então, o pré-modelo é obtido através destes dados selecionados através de algoritmos de identificação, discretos ou contínuos, conforme mostram os apêndices desta dissertação.

3.2.2 Projeto Sistemático de Perturbações baseado no Pré-Modelo

O pré-modelo concentra uma série de informações a respeito do comportamento dinâmico do sistema, fundamentado, basicamente, a partir dos dados históricos de planta. Além de representar o sistema através de ganhos estáticos e constantes de tempo, os quais estão

relacionados com a amplitude das perturbações e com o tempo de duração das mesmas, o pré-modelo revela a principal característica dos sistemas multivariáveis: a direcionalidade. Somado às informações do pré-modelo, é de extrema importância caracterizar o ruído de medida e de processo das variáveis controladas do sistema tendo em vista que as perturbações devem superar a amplitude do ruído das saídas, no mínimo. A determinação do tempo e da amplitude de cada perturbação serão descritos e analisados mais adiante, ainda neste capítulo.

3.2.2.1 Determinação da Amplitude do Ruído de Medida

O efeito das perturbações planejadas nas variáveis de saída devem superar o efeito dos ruídos das variáveis controladas (ou variáveis de saída). O ruído ou variações nas variáveis de saída podem ser provenientes de dois tipos de fatores:

A) Fatores não-sistemáticos (ou probabilísticos, ou estocásticos): ruídos de medida, ruídos de processo e distúrbios na carga.

B) Fatores sistemáticos (ou determinísticos): variações nas entradas do sistema para corrigir desvios de setpoint, de trajetória de referência ou de faixa de operação.

Desta forma, a correta determinação da amplitude do ruído das variáveis de saída deverá ser realizada em conjuntos de dados sem a variação ou com variação mínima das variáveis manipuladas ou entradas do sistema. A metodologia de análise da amplitude do ruído nas variáveis de saída consiste nos seguintes procedimentos:

1. Divisão do conjunto de dados em subintervalos.
2. Para cada variável, em cada subintervalo, é calculado o valor médio (\bar{y}).
3. Para cada variável, em cada subintervalo, é criada a variável diferença, *ydiff*, dada por,

$$ydiff = y - \bar{y} \quad (3.6)$$

onde y são os valores das variáveis de saída e \bar{y} é a média destes valores. Para a determinação da amplitude das variáveis de saída, pode-se utilizar o fato de que os ruídos de medida apresentam geralmente distribuição normal de probabilidade. Esta distribuição é expressa pela Equação (3.7),

$$p = f(x | \mu, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} e^{\left(\frac{-(x-\mu)^2}{2\sigma^2}\right)} \quad (3.7)$$

onde μ é a média do vetor de dados x , σ é o desvio padrão.

Assumindo então esta distribuição para a variável y_{diff} , o subintervalo cujos dados apresentar distribuição de probabilidades mais próxima da distribuição normal, será o intervalo escolhido para o cálculo da amplitude do ruído das variáveis de entrada e, especialmente para o cálculo da amplitude do ruído das variáveis de saída. Esta verificação é feita através da comparação entre as probabilidades dos valores da variável y_{diff} com aquelas calculadas através da Equação (3.7). Para cada subintervalo é gerado um gráfico tal qual apresentado na Figura 3.5.

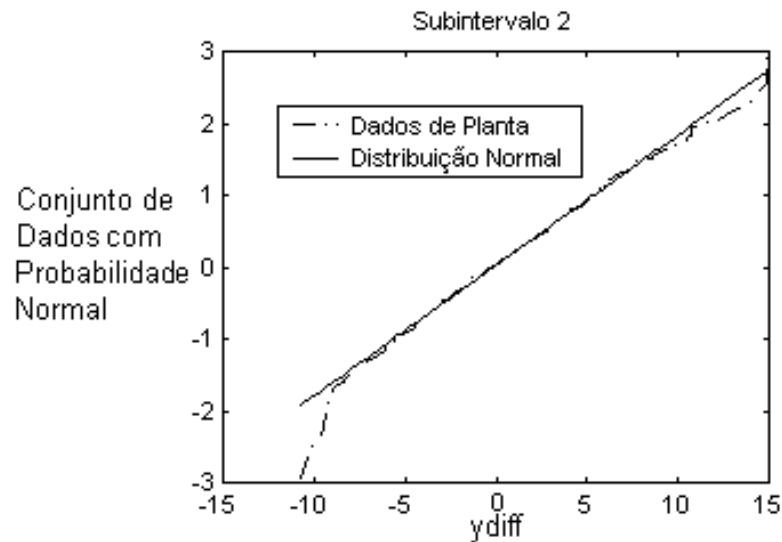


Figura 3.5: Comparação entre a distribuição normal e a distribuição obtida para os dados das variáveis desvio, para a caracterização da amplitude do ruído das saídas do sistema.

A integral da diferença absoluta entre a curva da distribuição normal e a distribuição dos valores da variável y_{diff} foi o critério utilizado para selecionar o intervalo que mais se aproximou da distribuição normal. Obviamente, na presença de distúrbios externos não medidos, a distribuição de probabilidades da variável y_{diff} se afastará da distribuição normal.

Prosseguindo, obtém-se no subintervalo escolhido, ou seja, naquele em que a integral entre a distribuição normal e a distribuição de probabilidade da variável y_{diff} apresentou o menor valor entre todos os subintervalos, que,

$$\Delta y_j = 2,6\sigma_j \quad (3.8)$$

em que, Δy_j é a amplitude do ruído da variável de saída j , e σ_j é o desvio padrão dos dados da variável diferença correspondente a variável de saída j . Com 2,6 desvios padrão, aproximadamente 95% das medidas apresentam ruído com amplitude inferior ao dado pela Equação (3.8). A Figura 3.6 mostra dados de planta industrial cuja amplitude do ruído foi analisada, a título de exemplo.

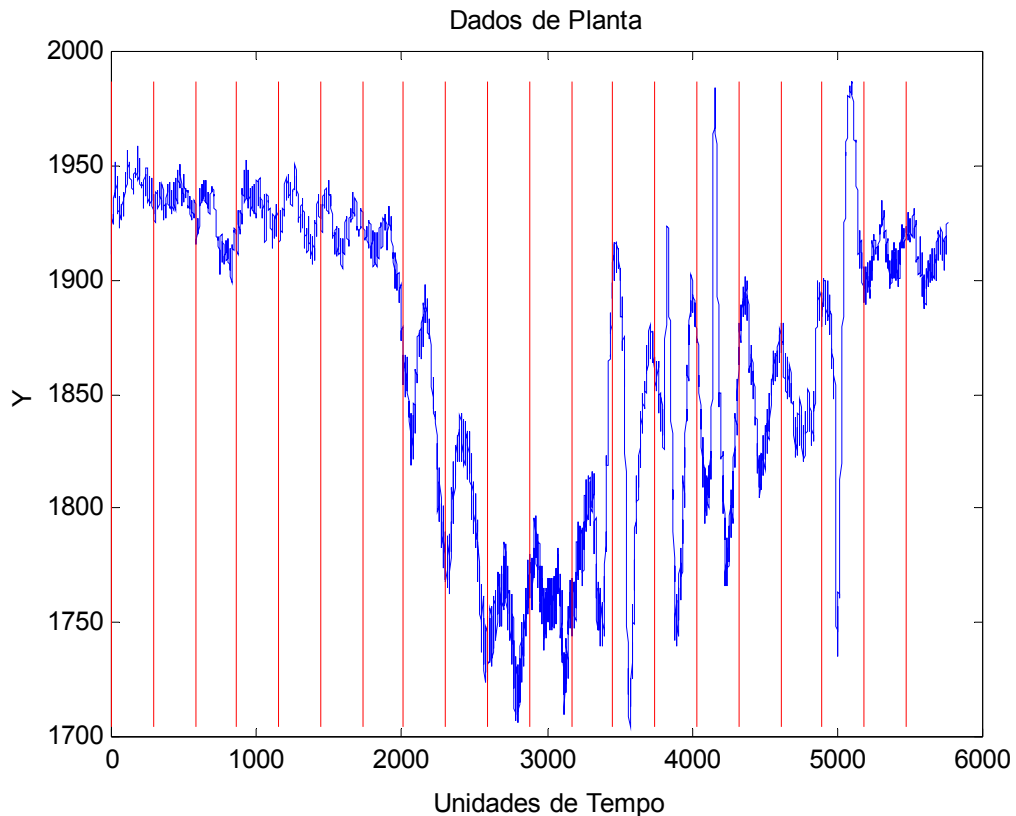


Figura 3.6: Análise do ruído de dados de planta.

De todos os subintervalos de dados mostrados na Figura 3.4, foi determinado qual deles mais se aproximou da distribuição normal. O algoritmo implementado indica que os dados do segundo subintervalo apresentam distribuição mais próxima da normal e a amplitude do ruído é de 13,83 unidades. Por inspeção visual, pode-se concluir que realmente, o segundo intervalo pode ser tomado como parâmetro na determinação da amplitude do ruído de medida. Obviamente, dados de planta também estão corrompidos com efeitos de perturbações nas variáveis manipuladas e distúrbios não medidos, que podem tornar mais imprecisa a determinação da amplitude do ruído de medida das variáveis de saída. A Tabela 3.3 mostra a amplitude do ruído de medida para todos os intervalos mostrados na Figura 3.6, obtidos através da Equação (3.8), além do critério da integral utilizado para a seleção do intervalo mais adequado para a determinação da amplitude do ruído nas variáveis de saída.

Tabela 3.3: Amplitude do ruído de medida e valores da integral do erro absoluto entre a distribuição normal e a distribuição dos dados da Figura 3.4 para todos os subintervalos de dados analisados.

| Intervalo N° | Amplitude | Integral | Intervalo N° | Amplitude | Integral |
|--------------|--------------|----------|--------------|-----------|----------|
| 1 | 21,94 | 12,40 | 11 | 43,32 | 18,54 |
| 2 | 13,83 | 2,56 | 12 | 100,59 | 80,75 |
| 3 | 30,47 | 13,13 | 13 | 155,62 | 43,69 |
| 4 | 20,95 | 4,31 | 14 | 126,67 | 38,10 |
| 5 | 25,94 | 7,54 | 15 | 130,82 | 145,00 |
| 6 | 21,73 | 8,05 | 16 | 65,36 | 16,17 |
| 7 | 40,76 | 91,72 | 17 | 54,13 | 16,40 |
| 8 | 83,36 | 26,89 | 18 | 166,32 | 71,76 |
| 9 | 83,17 | 20,58 | 19 | 24,48 | 5,27 |
| 10 | 45,17 | 10,71 | 20 | 24,81 | 7,82 |

3.2.2.2 Cálculo do Tempo de Perturbação

Para a determinação das frequências de atuação dos sinais planejados, faz-se necessário obter a constante de tempo representativa do sistema, de modo que tanto os canais rápidos quanto os canais lentos sejam excitados. Uma forma de calcular a constante de tempo representativa do sistema é calcular a média geométrica entre as constantes de tempo de todos os canais da matriz de transferência. A média geométrica é a mais apropriada para ponderar grandezas muito díspares, em relação a média aritmética e a média harmônica. A Equação (3.9) apresenta o cálculo da média geométrica.

$$\tau_{Médio} = \sqrt[N]{\prod_{i=1}^N \tau_i} \quad (3.9)$$

em que N é o número de constantes de tempo presentes no sistema e τ_i é a constante de tempo, para cada canal. A média geométrica é interessante por ter seu valor pouco influenciado por constantes de tempo muito elevada em poucos canais ou muito baixas. Desta forma, mesmo

havendo canais com altas constantes de tempo, a constante global do sistema tende para o valor médio da maioria das constantes de tempo dos diversos canais. Ao contrário, a média aritmética tende aos valores extremos, mesmo que apenas um dos canais possua este extremo. Na literatura pode-se observar que a constante de tempo do sistema é a constante de tempo com valor mais elevado. Entretanto, é necessário ter uma visão crítica com relação a esta escolha, porque se apenas poucos canais apresentam elevada constante de tempo, o teste de identificação ficará sobremaneira longo, podendo remover o sistema do ponto de operação.

Da teoria de controle [Luy92], é sabido que a o intervalo de frequências mais importante, em se tratando de funções de transferências de primeira ordem com tempo morto está centrado na frequência equivalente a $1/\tau$, em que τ é a constante de tempo do sistema. O intervalo em si cobre a faixa de um decado (meio decado à esquerda da frequência central e meio decado à direita da frequência central). No caso multivariável, a frequência central equivale a $1/\tau_{Médio}$ e o intervalo de frequências está entre $0,5/\tau_{Médio}$ e $5/\tau_{Médio}$. Na prática, frequências menores que $0,5/\tau_{Médio}$ e maiores que $5/\tau_{Médio}$ não trazem maiores informações a respeito do processo. Portanto, as frequências das perturbações planejadas deverão ser $0,5/\tau_{Médio}$, $1/\tau_{Médio}$ e $5/\tau_{Médio}$. Entretanto, estes valores podem ser variados. O tempo de permanência de cada sinal num determinado patamar é calculado através da Equação (3.10),

$$Tempo_excitação = \frac{2\pi}{\omega} \quad (3.10)$$

em que ω é o vetor com as frequências de excitação sugeridos acima. A Equação (3.10) advém do período que um sinal senoidal com frequência ω teria se fosse utilizado para excitação. Entretanto, devido a facilidade de execução de testes degrau em seqüência em plantas industriais, empregou-se, na metodologia proposta, o sinal do tipo degrau.

3.2.2.3 Cálculo das Direções e da Amplitude das Perturbações

Em um sistema multivariável, as unidades de medida das variáveis de entrada e de saída geralmente são muito distintas. Para calcular a correta amplitude das perturbações nas variáveis manipuladas, é necessário escalonar o sistema de forma ótima. Em termos práticos, faz-se necessário determinar as matrizes peso L (*left*) e R (*right*) que podem ser vistas como fatores de conversão de unidades, ou seja, $G(j\omega) = L \cdot G_s(j\omega) \cdot R$, onde G_s é o sistema escalonado. Nesta etapa é realizada a decomposição em valores singulares do sistema escalonado, em cada frequência de excitação, de modo a se obter as principais direções do sistema:

$$G_s(j\omega) = U \Sigma V^H \quad (3.11)$$

em que V^H contém os vetores das direções de entrada (vetores coluna) que apontam para o valor singular da correspondente coluna da matriz diagonal Σ (esta matriz contém os valores

singulares do sistema na diagonal principal em ordem decrescente, da esquerda para a direita). O primeiro vetor coluna da matriz V^H (matriz com as direções de entrada) é a direção de maior ganho que o sistema apresenta e o último vetor coluna (da esquerda para a direita) é a direção de menor ganho do sistema. A matriz U corresponde aos vetores das direções de saída. Após a decomposição da matriz $G_s(j\omega)$ em valores singulares, sabe-se, então, as principais direções nas quais o sistema deverá ser excitado, para cada frequência de interesse. A amplitude das perturbações é calculado através da seguinte equação:

$$\Delta u_i = FE_i \cdot R \cdot V_i \quad (3.12)$$

em que Δu_i é o vetor na direção i de amplitudes das variáveis manipuladas a ser aplicado no sistema, FE_i é o fator de expansão, para garantir que a variável menos sensível seja excitada, R é a matriz de escalonamento das entradas e V_i é o vetor coluna da matriz V^H , correspondente à direção i que se está calculando as perturbações. O fator de expansão é calculado pela Equação (3.13).

$$FE_i = \max \left(\frac{L^{-1} \cdot \Delta y_j}{|G_s(j\omega) \cdot V_i|} \right) \quad (3.13)$$

em que Δy_j são as amplitudes do ruído das variáveis de saída obtidas através da Equação (3.8).

É importante observar que para cada frequência, haverá uma amplitude de perturbação, assim como para cada direção. É importante ressaltar que se o vetor Δu_i for complexo, o sentido é mantido através do sinal da parte real e a intensidade é determinada pelo módulo do número complexo.

A grande vantagem desta metodologia reside na confluência de informações advindas dos dados de planta (pré-modelo), o qual permite avaliar em que direções é realmente necessário excitar o sistema, além de indicar qual a amplitude da perturbação mais adequada. Somado a isto, é feito um escalonamento do sistema, no sentido de garantir que a variável menos sensível seja excitada.

3.3 Importância das Perturbações Ortogonais

As perturbações projetadas pelas etapas anteriores da metodologia em proposição são obrigatoriamente ortogonais, devido ao algoritmo de decomposição em valores singulares da matriz $G_s(j\omega)$. Esta característica da perturbação gerada pela metodologia é de fundamental importância para a geração de dados repletos de informações do processo, pelo simples fato de que a cada perturbação, por elas serem ortogonais, novas informações sobre o comportamento do processo são obtidas. O espaço de possíveis direções para aplicação das perturbações é melhor explorado ao se projetar perturbações em direções ortogonais. No entanto, existe uma condição mais forte e básica que a ortogonalidade: a dependência linear.

Em última análise, as direções de perturbação devem ser linearmente independentes, de modo que os novos dados gerados não contenham informações repetidas. Caso essa repetição aconteça, os algoritmos de identificação usualmente encontrados na literatura [LJ99] poderão gerar diferentes modelos que se ajustam aos dados de planta mas nem todos representam adequadamente o sistema.

3.4 Decomposição das Perturbações em Blocos

As perturbações projetadas pelas etapas anteriores podem ser agrupadas em blocos de variáveis manipuladas, dependendo das características dinâmicas do pré-modelo. O engenheiro de controle pode optar por projetar as perturbações para todas as variáveis manipuladas ou apenas para aquelas em que o algoritmo sugere. Este agrupamento depende de quão influente são as variáveis manipuladas no sistema. Esta relação de influência está baseada no RGA (*Relative Gain Array*) [BR66]. As variáveis mais influentes são agrupadas em um bloco e as menos em outro. Em termos práticos, esta decomposição facilita a aplicação do teste em sistemas com um grande número de variáveis manipuladas, sem contar que os efeitos das perturbações das variáveis que menos influenciam não ficam mascarados pelos efeitos das variáveis mais influentes, como aconteceria se o teste de identificação exigisse perturbações em todas as variáveis manipuladas simultaneamente.

A decomposição sugerida não faz sentido para sistemas em que todas as variáveis manipuladas afetam de forma diferente as variáveis controladas, isto é, para sistemas totalmente desacoplados, não importando a seqüência e nem quais variáveis manipuladas estão sendo alteradas simultaneamente. No entanto, como esta situação é incomum na prática, a decomposição em blocos de perturbações deverá sempre estar em mente pelo engenheiro de controle ao projetar testes de identificação.

3.5 Exemplo ilustrativo

Esta subseção é destinada a apresentar a aplicação da metodologia tradicional e a metodologia de projeto de perturbações multivariável para a identificação, em um modelo de um processo de separação de ar [TE00]. Este sistema foi escolhido por apresentar diferentes possibilidades de estruturas de controle da unidade, cada qual com grau de acoplamento e comportamentos dinâmicos distintos. Estas características refletem-se no grau de controlabilidade do sistema.

A unidade promove a separação entre o nitrogênio e oxigênio na coluna principal, composta por uma zona de alta pressão (fundo) e outra de baixa pressão (topo). A corrente de fundo segue para outra coluna (torre 2) com o objetivo de aumentar a eficiência de separação entre os dois compostos. Nesta segunda coluna, a quantidade de nitrogênio é muito superior à quantidade de oxigênio, se compararmos com a fração existente na atmosfera. Enquanto isto, a corrente de topo da coluna segue para outra coluna (torre 1), da mesma forma que a corrente

de fundo. Entretanto, maior é a fração de oxigênio. É importante ressaltar que as três colunas do sistema estão integradas mássica e energeticamente, o que provoca acoplamento dos canais da matriz de transferência, além do possível surgimento de uma "competição interna entre os canais", traduzida para a terminologia de controle de processos como *zero de transmissão*. A Figura 3.7 mostra uma visão geral do sistema LINDE.

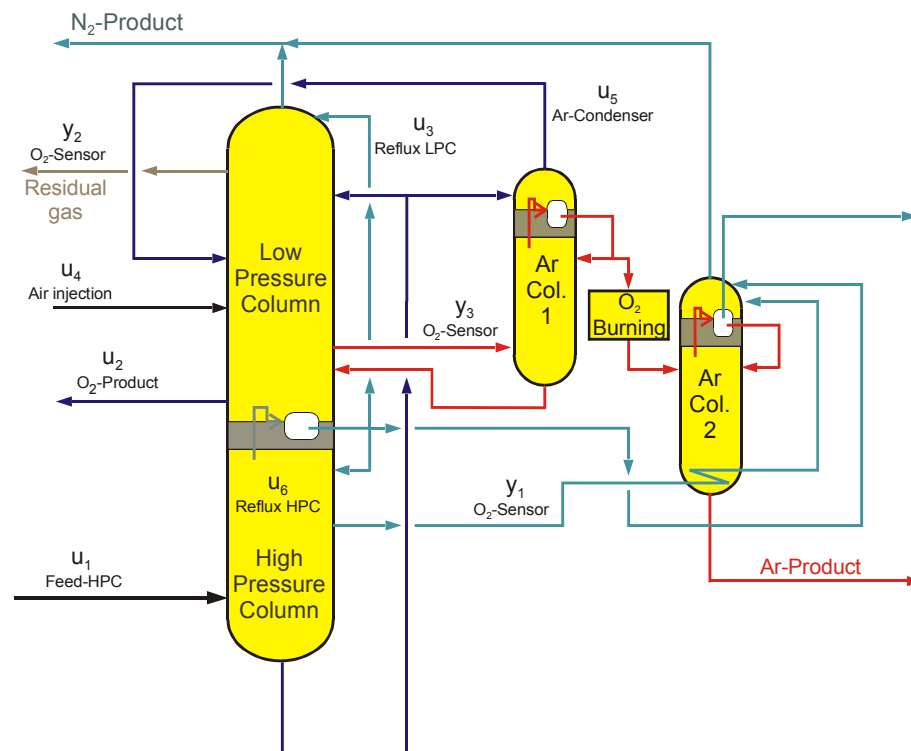
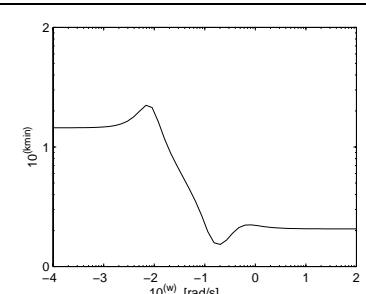
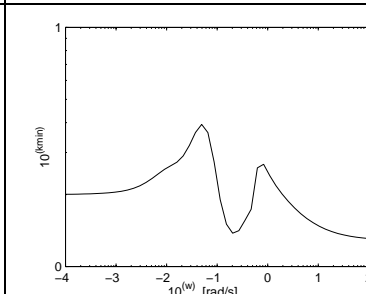


Figura 3.7: Fluxograma simplificado do processo de separação de ar LINDE.

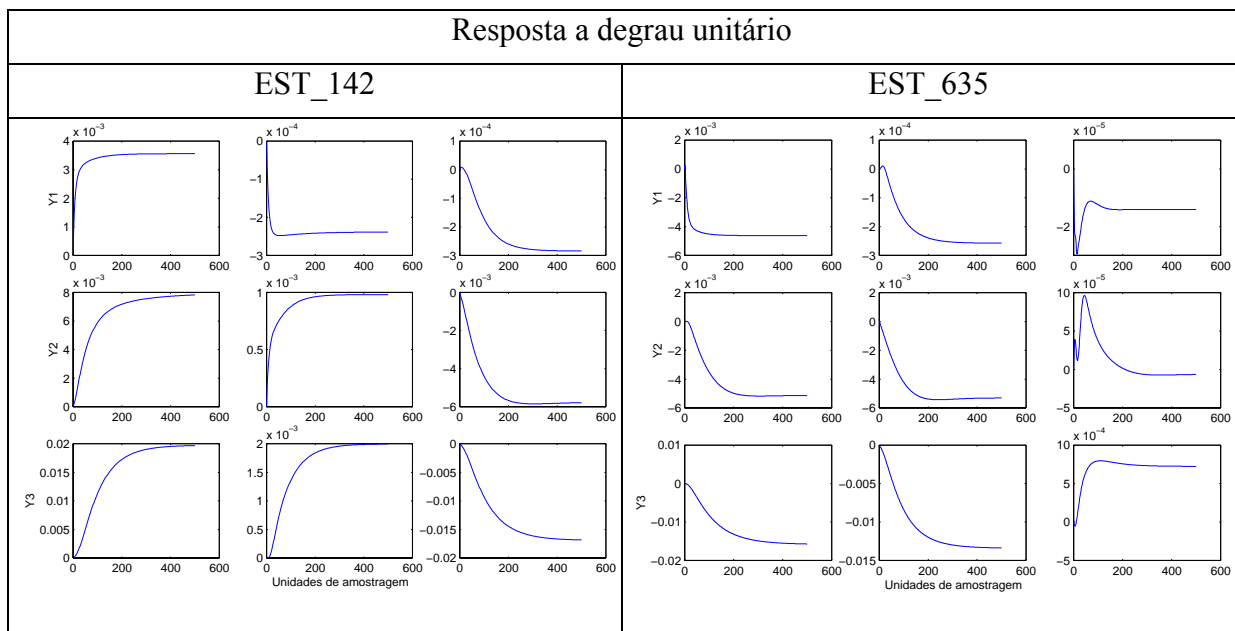
Nesta unidade, três variáveis são controladas: fração de oxigênio da corrente de fundo da primeira torre que se destina à torre 2 (Y_1), fração de oxigênio da corrente de topo da coluna principal (Y_2) e fração de oxigênio da corrente de topo que alimenta a torre 1, partindo da zona de baixa pressão da coluna principal (Y_3). Para realizar o controle das variáveis acima, seis variáveis manipuladas podem ser usadas, de U_1 a U_6 , conforme fluxograma da Figura 3.7. Algumas das principais estruturas de controle desta unidade são: estrutura 142 e estrutura 635. Esta nomenclatura está vinculada com os índices das variáveis manipuladas usadas para controlar as saídas 1, 2 e 3, respectivamente. Logo, a estrutura 142, por exemplo, usa a variável manipulada 1 para controlar a saída Y_1 , a manipulada 4 para a saída Y_2 e a manipulada 2 para a saída Y_3 . Como dito anteriormente, cada estrutura de controle apresenta características dinâmicas distintas. A Tabela 3.4 apresenta as principais características dinâmicas para comparação com os modelos a serem identificados, para as duas estruturas escolhidas.

Tabela 3.4: Características dinâmicas das estruturas de controle 142 e 635 do processo de separação de ar LINDE.

| Item | EST_142 | EST_635 |
|-----------------------------|---|---|
| Zeros no Semi-Plano Direito | — | 0,6561 e 0,1081 |
| RGA0 | $\begin{bmatrix} 0,821 & 0,223 & 0,045 \\ 1,658 & 2,431 & 3,089 \\ 1,480 & 1,654 & 4,134 \end{bmatrix}$ | $\begin{bmatrix} 1,044 & 0,056 & 0,012 \\ 0,110 & 1,088 & 0,022 \\ 0,066 & 0,031 & 0,965 \end{bmatrix}$ |
| Condicionamento Mínimo |  |  |

A resposta ao degrau unitário das matrizes de transferência correspondentes às duas estruturas de controle são apresentadas na Tabela 3.5.

Tabela 3.5: Resposta a degrau unitário dos modelos das estruturas de controle 142 e 635.



Os dados contidos nas Tabelas 3.4 e 3.5 servirão como comparação das características dinâmicas dos modelos identificados a partir de dados gerados pela metodologia proposta por este trabalho e pelas metodologias degrau (metodologia tradicional) e *PRBS* multivariáveis.

Além disto, podem ser observadas diferenças significativas entre o comportamento dinâmico destas duas estruturas. Enquanto a estrutura 142 apresenta condicionamento mínimo elevado e forte acoplamento entre os canais a baixas frequências, a estrutura 635 possui condicionamento mínimo baixo em todo o intervalo de frequências, apresentando um acoplamento baixo entre os canais do sistema. Como neste exemplo trata-se da identificação de modelos para um sistema simulado, as perturbações a serem planejadas pela metodologia proposta neste trabalho partirá já da etapa de cálculo das perturbações propriamente dita. O pré-modelo utilizado, para ambas as estruturas, é uma aproximação de primeira ordem com tempo morto do modelo original, que foi apresentado pelos dados das Tabelas 3.4 e 3.5.

3.5.1 Modelos para estrutura 142

Os dados gerados através da seqüência independente de degraus, para a identificação do modelo do estrutura 142 estão mostrados na Figura 3.8. Os valores mostrados no eixo y do gráfico superior deve ser multiplicado por 10^{-11} . Para o gráfico inferior, o fator de multiplicação é igual a 10^{-8} . Estes fatores não estão explícitos nos gráficos porque as figuras foram exportadas do software MATLAB[®] através de subrotinas que maximizavam o tamanho do texto e eliminavam as potências da base 10, desafortunadamente.




Figura 3.8: Dados gerados através da metodologia tradicional de projeto de perturbações para a identificação do modelo da estrutura 142.

Deve-se salientar que a amplitude das perturbações da metodologia tradicional foi calculada da mesma forma que a amplitude das perturbações da metodologia proposta, usando a matriz identidade como matriz de direções. A Figura 3.9 contém os dados das perturbações geradas

através de sinais *PRBS* para a identificação do modelo da estrutura 142. Da mesma forma que na Figura 3.8, os valores do eixo y devem ser multiplicados por 10^{-11} e os valores do eixo x do gráfico inferior por 10^{-8} . Estes fatores devem ser considerados em todos os demais gráficos apresentados na identificação dos modelos das estruturas 142 e 635 do sistema LINDE.




Figura 3.9: Dados gerados através de sinais *PRBS* para a identificação do modelo da estrutura 142.

Observa-se na Figura 3.9 que os sinais *PRBS* são aplicados em inúmeras direções distintas, provocando uma dependência linear entre as próprias direções de perturbação, aliada à repetição de informações dinâmicas refletidas nas saídas do sistema. O último conjunto de dados refere-se às perturbações geradas através da metodologia de perturbações baseada na direcionalidade do sistema. Cabe lembrar que estas direções estão baseadas num pré-modelo obtido através de uma aproximação de primeira ordem com tempo morto do modelo real da unidade. A matriz de direções utilizada no projeto das perturbações é mostrada a seguir, para a estrutura 142.

$$V_{142} = \begin{bmatrix} 0,4460 & 0,7760 & 0,4460 \\ 0,4693 - 0,3047i & 0,5908 - 0,1575i & 0,5587 + 0,0308i \\ -0,6921 + 0,0952i & -0,0089 + 0,1546i & 0,6766 + 0,1738i \end{bmatrix}$$

Os dados das perturbações geradas com a matriz V_{142} estão apresentados na Figura 3.10.




Figura 3.10: Dados gerados através das perturbações baseadas nas principais direções do sistema.

Para cada conjunto de dados apresentados através das Figuras 3.8, 3.9 e 3.10 foi obtido um modelo em espaço de estado, conforme os canais da estrutura 142. O algoritmo de identificação utilizado foi o algoritmo SUBID [OM96], o qual está descrito no apêndice A. Vale lembrar que o índice das matrizes de Hankel para as três identificações foi a mesma, além da escolha da ordem do modelo, de modo que a comparação entre os modelos gerados fosse possível. Conforme descrito anteriormente, a qualidade dos modelos multivariáveis gerados podem ser comparados através do condicionamento mínimo ao longo de um determinado intervalo de frequências. É válido recordar que o modelo original é conhecido (Planta), e pode-se, desta forma, ter a exata noção de quanto os modelos identificados divergem da verdadeira dinâmica do sistema. Desta forma, a Figura 3.11 mostra o condicionamento mínimo dos modelos identificados e da planta, para a estrutura 142.




Figura 3.11: Condicionamento mínimo dos modelos identificados e da planta real.

A Figura 3.11 indica que todas as metodologias produziram dados ricos para a identificação, uma vez que o condicionamento mínimo dos modelos identificados e o modelo considerado como planta são praticamente idênticos em todo o intervalo de frequências. Da mesma forma que o gráfico do condicionamento mínimo, é interessante comparar o gráfico das respostas degrau dos modelos identificados e do modelo tido como planta real. Esta comparação é feita através dos gráficos da Figura 3.12.




Figura 3.12: Resposta a degrau unitário dos modelos identificados e da planta real. Planta (traço-ponto); Metodologia tradicional (traço longo-traço curto); PRBS (linha contínua), Direções (linha tracejada).

Entretanto, a metodologia baseada nas principais direções do sistema leva a grande vantagem, ante as demais, da pequena remoção da planta do ponto de operação, refletida através da variância das variáveis de saída nos dados de cada teste. Estes valores estão concentrados na Tabela 3.6.

Tabela 3.6: Variância dos dados de saída das variáveis controladas da estrutura 142 para os três testes de identificação.

| Metodologia de Perturbações | Y1 ($\times 10^{-21}$) | Y2($\times 10^{-21}$) | Y3($\times 10^{-21}$) |
|-----------------------------|--------------------------|-------------------------|-------------------------|
| Degrau | 0,011 | 0,101 | 0,442 |
| <i>PRBS</i> | 112 | 448 | 2875 |
| Baseada nas direções | 0,006 | 0,118 | 0,285 |

Claramente pode-se observar que tanto a metodologia tradicional quanto a metodologia de perturbações baseada nas direções do sistema removeram o sistema do ponto de operação muito menos que o teste PRBS. A metodologia de perturbações baseada na direcionalidade do sistema remove praticamente metade o sistema do ponto de operação em relação à metodologia tradicional, para as variáveis Y1 e Y3. Para a variável Y2, a variação provocada pelas perturbações de ambas as metodologias foi similar. Outro ponto importante para comparação entre os diversos modelos identificados e a planta real é a localização dos zeros de transmissão, que podem ser observados na Tabela 3.7.

Tabela 3.7: Zeros de transmissão dos modelos identificados para a estrutura 142 e da planta real.

| Metodologia de Perturbações | zeros de transmissão (ou zeros no semi-plano direito) |
|-----------------------------|---|
| Planta Real | Não apresenta |
| Degrau | Não apresentou |
| <i>PRBS</i> | $7,6481 \cdot 10^7$ e $6,8903 \cdot 10^7$ |
| Baseada nas direções | Não apresentou |

Novamente, é possível concluir que os modelos gerados pela metodologia de perturbações baseada na direcionalidade do sistema e pela metodologia tradicional de perturbações conseguiram capturar melhor as características multivariáveis do sistema em relação ao planejamento *PRBS*.

3.5.2 Modelos para estrutura 635

Embora o modelo que representa originalmente a estrutura de controle 635 seja bem condicionado ao longo de todo o intervalo de frequências importantes para o controle do processo, diferentemente da estrutura 142, esta estrutura apresenta zeros de transmissão, isto é, uma competição entre as diversas funções de transferência da matriz do modelo. Da mesma forma que foi analisado o estudo dos efeitos das perturbações planejadas por diferentes técnicas para a estrutura 142, faz-se agora para a estrutura 635. Os dados das perturbações planejadas geradas pela simples seqüência de degraus, PRBS e baseado nas principais direções do sistema, estão apresentados através das figuras 3.13, 3.14 e 3.15, respectivamente.




Figura 3.13: Dados gerados através da metodologia tradicional de projeto de perturbações para a identificação do modelo da estrutura 635.




Figura 3.14: Dados gerados através de sinais PRBS de projeto de perturbações para a identificação do modelo da estrutura 635.




Figura 3.15: Dados gerados através das perturbações baseadas nas principais direções do sistema.

A matriz de direções utilizada para a geração das perturbações da Figura 3.15 é igual a:

$$V_{635} = \begin{bmatrix} -0,6547 & 0,3779 & -0,6547 \\ -0,5746 + 0,2122i & -0,0579 - 0,4963i & 0,6080 + 0,0742i \\ -0,2802 - 0,3431i & -0,2696 + 0,7313i & 0,4359 - 0,0790i \end{bmatrix}$$

O condicionamento mínimo dos modelos identificados e o da planta real estão comparados no gráfico da Figura 3.16.




Figura 3.16: Condicionamento mínimo dos modelos identificados e da planta real.

Na Figura 3.16, a curva de condicionamento mínimo da planta real e a do modelo gerado pela metodologia tradicional de projeto de perturbações estão sobrepostas. Por fim, a Figura 3.17 apresenta a comparação no domínio do tempo para os três modelos identificados para a estrutura 635 e o modelo original desta para esta estrutura.




Figura 3.17: Resposta a degrau unitário dos modelos identificados e da planta real (635). Planta (pontilhado); Metodologia tradicional (tracejado); *PRBS* (traço-ponto), Direções (linha contínua).

O modelo gerado através dos dados do teste *PRBS* não apresentou a mesma qualidade que apresentaram os modelos obtidos através da metodologia tradicional e da metodologia baseada nas direções do sistema. A resposta ao degrau do modelo identificado a partir de perturbações baseada nas direções do sistema encobriu a resposta ao degrau da planta original, nos gráficos mostrados na Figura 3.17. Além disto, pode-se observar na Tabela 3.8, que a variância do processo é muito menor nos dados da metodologia de projeto de perturbações baseada na direcionalidade do sistema que nas demais.

Tabela 3.8: Variância dos dados de saída das variáveis controladas da estrutura 635 para os três testes de identificação.

| Metodologia de Perturbações | Y1 ($\times 10^{-21}$) | Y2 ($\times 10^{-21}$) | Y3 ($\times 10^{-21}$) |
|-----------------------------|--------------------------|--------------------------|--------------------------|
| Degrau | 0,007 | 0,107 | 0,665 |
| <i>PRBS</i> | 8,310 | 12,350 | 74,960 |
| Baseada nas direções | 0,0003 | 0,008 | 0,437 |

Os zeros de transmissão dos modelos identificados e da planta real são apresentados pela Tabela 3.9, para a estrutura 635.

Tabela 3.9: Zeros de transmissão dos modelos identificados para a estrutura 635 e os da planta real.

| Metodologia de Perturbações | zeros de transmissão (ou zeros no semi-plano direito) |
|-----------------------------|---|
| Planta Real | 0,1081 e 0,6561 |
| Degrau | 0,1081 e 0,6563 |
| <i>PRBS</i> | 0,0806, 0,6622 e $1,2762 \cdot 10^5$ |
| Baseada nas direções | 0,1082 e 0,6562 |

Da mesma forma que ocorreu com os modelos identificados para a estrutura 142, os modelos identificados para a estrutura 635 usando os dados oriundos da metodologia tradicional e da metodologia baseada nas direções do sistema tiveram qualidade superior ao modelo gerados com dados da metodologia *PRBS*, fato que pode ser mais uma vez observado nos dados da Tabela 3.9.

Capítulo 4

Técnicas de Validação de Modelos

O capítulo quatro destina-se a apresentar as principais técnicas de validação empregadas tanto no meio acadêmico quanto no meio industrial. Durante este capítulo, é feita uma análise crítica das ferramentas existentes, tanto sob o ponto de vista da escolha do modelo utilizado pelos algoritmos quanto dos critérios de validação encontrados na literatura. É apresentado o critério da derivada, como um novo critério para a validação de modelos.

4.1 Critérios de Validação de Modelos

A etapa de validação dos modelos, conforme visto no capítulo 1, Figura 1.1 é a quarta etapa dentro de um procedimento de identificação de sistemas. Nesta etapa, os modelos identificados são avaliados por critérios de validação que indicam quais os modelos identificados são mais adequados a representar o sistema. Observe que os parâmetros estimados do modelo apresentam intervalos de confiança, podendo o problema de estimação/otimização apresentar múltiplos mínimos locais. Por isso, são gerados pela etapa de estimação de parâmetros, um conjunto M de prováveis modelos para o processo. Este fato é o motivo pelo qual a etapa de validação existe e apresenta indiscutível relevância dentro da tarefa de identificação de modelos.

Em quase todos os procedimentos e algoritmos de identificação, o problema de otimização para determinação dos parâmetros é formulado como a minimização do critério do erro quadrático, tal como $J = \min \sum [e(t)]^2$, onde, $e(t)$, é a diferença entre a variável medida, $y(t)$, e a predição da saída, $\hat{y}(t)$, isto é, $e(t) = y(t) - \hat{y}(t)$. Quanto menor esta diferença, teoricamente o modelo é apelidado de "bom". No entanto, como será apresentado a seguir, nem sempre os parâmetros que tornam os erros de predição mínimos são os parâmetros que melhor

representam o processo. Para averiguar esta aparente contradição, foi desenvolvido neste trabalho, um novo critério de validação de modelos, chamado de critério da derivada.

Esta seção, pretende apresentar os critérios de validação existentes na literatura, bem como o critério da derivada. Na próxima seção este novo critério é aplicado para identificar modelos para a planta de 2 tanques com aquecimento, a qual foi inicialmente discutida na seção 2.2.

4.2 Revisão da Literatura sobre os Critérios de Validação

Na busca da seleção dos melhores parâmetros dos modelos cujos erros de predição são mínimos, na literatura encontra-se dois critérios consagrados: o critério AIC (*Akaike's Information Criterion*) e o critério MDL (*Minimum Description Length*), propostos por Akaike e Rissanen, respectivamente [LJ99]. Ambos penalizam a função objetivo de determinação dos parâmetros do modelo, de modo que o modelo identificado represente bem o sistema com o menor número de parâmetros possível. O critério AIC afirma que os melhores parâmetros devem respeitar a seguinte condição:

$$V_{AIC}(\theta, Z^N) = \left(1 + \frac{2 \dim(\theta)}{N}\right) \frac{1}{N} \sum_{t=1}^N e^T(t, \theta) e(t, \theta) \quad (4.1)$$

em que $V_{AIC}(\theta, Z^N)$ é o valor da função objetivo usada no critério AIC, função do vetor de parâmetros do modelos, θ , e do conjunto de dados, Z , o qual contém N pontos para cada variável de entrada e de saída. A variável $e(t, \theta)$, presente na Equação (4.1) são os erros de predição do modelo, enquanto $\dim(\theta)$ é o tamanho do vetor de parâmetros do modelo identificado. Pouca diferença há entre o critério AIC e o critério MDL, visto que os parâmetros dos modelos pelo segundo critério, devem obedecer a:

$$V_{MDL}(\theta, Z^N) = \left(1 + \frac{2 \log(N \dim(\theta))}{N}\right) \frac{1}{N} \sum_{t=1}^N e^T(t, \theta) e(t, \theta) \quad (4.2)$$

A única diferença entre as duas funções objetivo é a presença do logaritmo da multiplicação entre o tamanho do conjunto de dados N e pelo tamanho do vetor de parâmetros do modelo identificado, $\dim(\theta)$. Esta mudança em relação ao critério de Akaike, aumenta a penalização sobre o número de parâmetros do modelo, fazendo com que os modelos identificados que respeitaram o critério MDL apresentem menor número de parâmetros em relação aos modelos identificados em que se utilizou o critério AIC. Um caso prático de utilização destes critérios pode ser encontrado em [BR03].

Na literatura encontramos também o critério UOV (*Unmodeled Output Variation*), o qual estabelece que, para cada ordem dos modelos testada na etapa de identificação, sejam calculadas a razão entre cada parâmetro e a covariância dos dados da variável de saída, razão esta chamada de r^{vk} , e também a relação entre a covariância dos valores da variável de saída nos intervalos em que as entradas estão constantes, isto é, apenas o ruído de medida afeta a

saída, e a covariância dos dados da variável de saída, razão esta chamada de r^w . O melhor modelo será escolhido quando o valor de r^{yk} for maior que o valor de r^w e a taxa de decréscimo de r^{yk} com o aumento da ordem for alta [BR03].

A validação cruzada é outra forma de avaliação dos modelos identificados. O modelo identificado baseado em um conjunto determinado de dados é simulado nas condições de um outro conjunto de dados. Caso os erros entre o valor real da variável de saída no segundo conjunto e a predição do modelo identificado com os dados do primeiro conjunto sejam pequenos, o modelo é considerado adequado.

Teoricamente, um bom modelo deve apresentar erros de predição não correlacionados com os dados das variáveis de entrada dos intervalos de amostragens do passado. Se existe alguma correlação, é porque ainda existe informação da dinâmica do sistema suficiente para incorporar aos parâmetros do modelo. Logo, caso exista esta correlação, o modelo identificado ainda não é o melhor modelo. Para tentar eliminar esta correlação, surge a necessidade de filtrar os erros de predição com funções específicas para cada sistema [LJ99].

Embora todos os critérios de validação anteriores apresentem bons resultados, os critérios *AIC* e *MDL*, estão vinculados aos erros de predição. No entanto, como freqüentemente ocorrem distúrbios externos não medidos em plantas industriais, os modelos identificados a partir destes critérios podem apresentar grandes incertezas e prejudicar a qualidade do controle do processo, visto que o erro de predição é afetado diretamente pelos distúrbios citados. Como este tipo de distúrbio está presente em praticamente todas as unidades industriais, propõe-se, neste trabalho, a utilização do critério da derivada, isto é, formular o problema de otimização com $\min \sum [de(t)/dt]^2$, em que $de(t)/dt$ é a derivada do erro, com o intuito de melhorar a qualidade dos modelos identificados em conjuntos de dados caracterizados por distúrbios externos não medidos. A seção 4.3 apresenta os fundamentos do novo critério de validação proposto por este trabalho.

4.3 Novo Critério de Validação: O critério da derivada

Os dados de plantas industriais, com freqüência, apresentam distúrbios externos não medidos nas variáveis de saída. Estes distúrbios afetam diretamente os erros de predição, fazendo com que os critérios de validação apresentados na literatura apresentem algumas incoerências quando aplicados a modelos identificados a partir de dados corrompidos com estes distúrbios. No sentido de minimizar o efeito dos distúrbios não medidos nas variáveis de saída, propõe-se utilizar tanto na etapa de determinação dos parâmetros do modelo quanto na etapa de validação do modelo, a derivada do erro de predição, formulando o problema de otimização como sendo $\min \sum [de(t)/dt]^2$, em que $de(t)/dt$ é a derivada do erro de predição.

Supondo que a estrutura do modelo contemple apenas a parte determinística, isto é, a saída depende apenas das entradas do sistema, os critérios de validação e o estimador $e(t)^2$ na presença de distúrbios fazem com que os parâmetros estimados representem informações

adicionais que não são consequência da parte determinística do modelo. Neste caso, a identificação com os critérios tradicionais apontarão que um modelo sem a parte estocástica (ex: OE, veja apêndice) é melhor que um modelo contemplando ambas as partes (ex: BJ, veja apêndice), apenas porque o modelo sem a parte estocástica apresentou menores erros de predição.

No entanto, se a derivada do erro de predição for utilizada, os parâmetros que fornecerem o menor somatório desta derivada, melhor representarão o sistema e a qualidade do modelo identificado, especialmente quando os dados de identificação apresentam distúrbios não medidos. Esta afirmação pode ser feita uma vez que necessariamente a presença de distúrbios não medidos obriga a predição do modelo determinístico, se os parâmetros forem corretamente estimados, a não sobrepor exatamente os dados utilizados para a identificação deste modelo. O reflexo deste efeito é o aumento dos valores dos erros de predição. Então, de acordo com a literatura, o melhor modelo é aquele que minimiza os erros de predição, mas no caso da presença de distúrbios não medidos, esta afirmação não é totalmente verdadeira. O critério da derivada pode ser utilizado não só na etapa de validação como também na etapa de estimação de parâmetros dos modelos. Como validação, a função objetivo resume-se à:

$$D = \sum_{k=1}^N \left(\frac{d}{dt} y_k - \frac{d}{dt} \hat{y}_{k|k-1} \right)^2 \quad (4.3)$$

em que D é o somatório da derivada dos erros de predição ($e(t) = y(t) - \hat{y}(t)$) elevado à segunda potência. O desafio imposto pelo critério é calcular a derivada dos dados da variável de saída, a qual na maioria dos casos contém ruídos de medida. Uma possível solução é utilizar filtros tipo passa-baixa, assim como presente na subrotina Idfilt, do MATLAB Signal Processing Toolbox [SIGPRO].

As derivadas são calculadas através da aproximação por diferenças finitas, usando como valor do tempo de discretização o próprio valor do tempo de amostragem dos dados de planta. Além da aplicação do critério da derivada na etapa de validação, na própria identificação do modelo o critério da derivada pode ser utilizado como função objetivo no problema de otimização. Basta minimizar:

$$S = \min \sum_{k=1}^N \left(\frac{d}{dt} y_k - \frac{d}{dt} \hat{y}_{k|k-1} \right)^2 \quad (4.4)$$

É importante salientar que o critério da derivada para a validação dos modelos pode ser utilizado em modelos que não foram identificados utilizando-se o critério da derivada para a determinação dos parâmetros. Na próxima seção será evidenciada as grandes potencialidades do critério da derivada.

4.4 Aplicação prática do critério da derivada: Identificação da Planta de dois tanques com aquecimento

Como já foi explicado no Capítulo 2, o principal distúrbio externo não medido da unidade é a temperatura da água de alimentação, T_0 . Um conjunto de dados com decaimento desta temperatura foi selecionado e é mostrado na Figura 4.1. Embora a temperatura T_0 seja medida, considerar-se-á um distúrbio não medido. Para projetar um controlador para esta unidade, é necessário se ter um bom modelo dinâmico entre a variável manipulada (potência de aquecimento, Q) e a variável controlada T_2 . No entanto, a temperatura da água de descarga é influenciada simultaneamente por Q e T_0 .




Figura 4.1: Conjunto de dados experimentais com decréscimo da temperatura da água de alimentação T_0 (distúrbio), carga térmica Q (variável manipulada) e temperatura da água de descarga, T_2 .

É possível isolar o real efeito da carga térmica na temperatura de saída, computando-se a diferença entre a temperatura de saída e a de entrada, isto é ($\Delta T = T_2 - T_0$), desde que a dinâmica de T_0 seja muito menor que a constante de tempo dominante do sistema. A Figura 4.2 compara os dois casos: com e sem a compensação da temperatura de entrada.




Figura 4.2: Conjuntos de dados usados na identificação dos modelos: (1) $\Delta T_2 = T_2(t) - T_2(0)$ (linha cheia) dados sem a compensação do efeito da temperatura de entrada e (2) $\Delta \Delta T = \Delta T(t) - \Delta T(0) = [T_2(t) - T_0(t)] - [T_2(0) - T_0(0)]$ (linha tracejada), dados com a compensação do efeito da temperatura de entrada.

Com os dois conjuntos de dados apresentados na Figura 4.2 foram identificados modelos lineares utilizando-se as estruturas *Box-Jenkins* e *Output-Error*, implementadas no MATLAB *System Identification Toolbox* [IDENT]. O modelo *Box-Jenkins* (BJ) fornece bons resultados quando distúrbios não medidos com T_0 estão presentes, enquanto que a estrutura *Output Error* (OE) é recomendável quando a discrepância entre o modelo e os dados experimentais seguem uma distribuição normal, ou seja, ruídos dos instrumentos de medição. A Figura 4.3 apresenta a comparação entre os modelos BJ, OE e os dados de planta do conjunto $\Delta \Delta T$ (de acordo com a Figura 4.2). Desde que haja a compensação do efeito da temperatura de entrada T_0 , ambas as estruturas produzem bons resultados.




Figura 4.3: Comparação entre os dados de planta sem o efeito das variações em T_0 (isto é $\Delta\Delta T$ da Figura 4.2) e os modelos identificados OE e BJ.




Figura 4.4: Comparação entre os dados de planta com os efeitos das variações de T_0 (isto é, ΔT_2) e os modelos identificados OE e BJ.

Aplicando-se o critério da derivada para a validação do modelo (dados da Figura 4.4), pode ser observado que o somatório das derivadas dos erros de predição do modelo BJ é inferior ao somatório das derivadas dos erros de predição do modelo OE, embora os erros de predição do modelo OE sejam menores, conforme pode ser observado nos dados da Tabela 4.1.

Tabela 4.1: Somatório dos erros de predição e da derivada do erros de predição quadráticos obtidos para os modelos OE e BJ identificados com os dados do conjunto ΔT_2 .

| Somatório dos erros quadráticos $\sum [e(t)]^2$ | | Somatório dos erros quadráticos da derivada $(\sum [de(t)/dt]^2)$ | |
|--|--------------------|--|--------------------|
| OE | BJ | OE | BJ |
| $0,75 \times 10^5$ | $4,25 \times 10^5$ | $1,73 \times 10^2$ | $0,32 \times 10^2$ |

A situação é completamente diferente quando os dados do conjunto ΔT_2 são usados. A Figura 4.4 claramente mostra que o modelo BJ capturou a tendência do modelo, embora tenha maior erro quadrático se comparado a estrutura OE, pelos dados da Tabela 4.1. Por outro lado, a estrutura OE não capturou a tendência do modelo tão bem quanto o modelo BJ. Em outras palavras, a discrepância entre o modelo e os dados experimentais é melhor descrito com uma função de $[de(t)/dt]^2$ ao invés de $[e(t)]^2$.

A Figura 4.5 apresenta as derivadas dos dados de planta filtrados (Idfilt) e dos modelos OE e BJ referentes ao dados do conjunto ΔT_2 .




Figura 4.5: Comparação entre a derivada dos dados de planta filtrados por Idfilt e a derivada dos modelos identificados OE e BJ.

Quando os dados estão afetados por distúrbios na carga, é possível afirmar que o critério do erro quadrático traz conclusões errôneas sobre a qualidade dos modelos identificados. No exemplo estudado, o modelo BJ foi melhor que o modelo OE, e não o oposto, como o critério do erro quadrático indicaria. Por outro lado, o critério do erro quadrático da derivada elucidou melhor a qualidade do modelo identificado. Estes resultados levam a pensar em usar um diferente critério para a identificação de sistemas, baseado em $\min \sum [de(t)/dt]^2$.

4.5 Utilização do critério da derivada como função objetivo

Como critério de identificação de modelos dinâmicos, a derivada dos erros de predição conduzem a resultados satisfatórios, justamente em dados contendo distúrbios não medidos, situação típica nos processos industriais. Com o intuito de mostrar os benefícios do novo critério, este será aplicado na identificação dos parâmetros $a0$, $a1$, $a2$, $a3$, e $a4$ da seguinte função de transferência de segunda ordem com tempo morto:

$$\hat{G}(s) = \frac{(a0 \cdot s + a1) \cdot e^{-a4s}}{a2 \cdot s^2 + a3 \cdot s + 1} \quad (4.5)$$

A função de transferência da Equação (4.5) será tomada com sendo representativa da dinâmica da temperatura da água de descarga do segundo tanque da unidade de dois tanques com aquecimento. Serão utilizados os critérios de minimização dos erros de predição (identificação tradicional) e da derivada dos erros de predição (nova proposta) na identificação de modelos a partir dos dados dos dois conjuntos: com e sem a compensação do efeito da variação da temperatura da água de alimentação.

Para o conjunto de dados ΔT , a Tabela 4.2 sumariza os parâmetros dos modelos identificados. A função de transferência $G1$ foi identificada usando uma estrutura OE discreta. O modelo discreto foi convertido para o domínio contínuo e os correspondentes parâmetros da Equação (4.5) estão listadas na tabela. A solução do problema de otimização $S1$ (erros de predição) e $S2$ (derivada dos erros de predição) para a função de transferência de segunda ordem Equação (4.5) geraram os modelos $G2$ e $G3$ da Tabela 4.2, respectivamente. O problema de otimização foi resolvido usando métodos de otimização padrão e genéricos implementados na função *lsqnonlin* do MATLAB *Optimization Toolbox* [OPT].

Tabela 4.2: Coeficientes da Equação (4.5) obtidos a partir do conjunto de dados ΔT .

| Funções de Transferência | Parâmetros da Equação (4.5) | | | | |
|--------------------------|-----------------------------|---------------------|--------|-------|------|
| | a0 | A1 | a2 | a3 | a4 |
| G1 / OE | $-1,3 \cdot 10^{-2}$ | $4,4 \cdot 10^{-3}$ | 4997,5 | 154,1 | 30,0 |
| G2 / S1 | 0,0 | $4,3 \cdot 10^{-3}$ | 5541,0 | 148,9 | 28,0 |
| G3 / S2 | 0,0 | $4,3 \cdot 10^{-3}$ | 5663,0 | 150,5 | 28,0 |

A Figura 4.6 mostra que todos os 3 modelos são muito similares, fato que pode ser comprovado pelas respostas a degrau unitário, mostrada na Figura 4.7. Estes resultados confirmam que para dados experimentais sem grandes distúrbios externos não medidos os critérios de otimização $S1$ e $S2$ são semelhantes.




Figura 4.6: Comparação com o conjunto de dados experimentais $\Delta\Delta T$: $G1$ identificado com OE, $G2$ identificado com o critério $S1$ e $G3$ com o $S2$.




Figura 4.7: Resposta a um degrau unitário de $G1$, $G2$ e $G3$.

Para o conjunto de dados ΔT_2 (sem compensação da temperatura da água de alimentação), a situação é completamente diferente do caso anterior. Devido aos distúrbios externos não medidos / não compensados, os critérios de otimização $S1$ e $S2$ convergem para parâmetros diferentes, como é mostrado na Tabela 4.3. Os resultados apresentados nesta tabela sobre o modelo $G4$, dizem respeito a uma estrutura discreta do tipo BJ. O modelo discreto foi convertido para o espaço contínuo e os parâmetros correspondentes da Equação (4.5) estão listados. A solução dos problemas de otimização $S1$ e $S2$ são $G5$ e $G6$, respectivamente.

Tabela 4.3: Coeficientes obtidos a partir dos dados experimentais do conjunto ΔT_2 , das funções de $G4$, $G5$ e $G6$.

| Funções de Transferência | Parâmetros da Equação (4.5) | | | | |
|--------------------------|-----------------------------|---------------------|--------|-------|------|
| | a0 | a1 | a2 | a3 | a4 |
| G4 /BJ | $-6,3 \cdot 10^{-3}$ | $4,4 \cdot 10^{-3}$ | 6013,2 | 142,6 | 30,0 |
| G5 / S1 | 0,0 | $1,9 \cdot 10^{-3}$ | 3158,0 | 112,4 | 30,0 |
| G6 / S2 | 0,0 | $4,0 \cdot 10^{-3}$ | 5156,0 | 143,6 | 30,0 |

A Figura 4.8 apresenta os modelos identificados para o caso sem compensação da temperatura da água de alimentação. Na Figura 4.9, são apresentadas as respostas a degrau unitário dos modelos $G4$, $G5$ e $G6$.




Figura 4.8: Comparação entre os dados de planta (sem a compensação dos efeitos da temperatura da água de entrada na temperatura da água de descarga), modelo BJ ($G4$), critério $S1$ ($G5$) e o critério $S2$ ($G6$).




Figura 4.9: Resposta a degrau unitário dos modelos identificados $G4$, $G5$, $G6$ e $G1$.

A partir dos resultados apresentados sobre a aplicação do critério da derivada na identificação de modelos, pode-se afirmar que este novo critério mostra-se de grande valia, especialmente para os casos em que os dados de planta estão corrompidos por distúrbios externos não medidos, os quais são frequentes no cenário industrial.

Capítulo 5

Identificação de Modelos de uma Planta Piloto

A necessidade da aplicação prática da metodologia de perturbações apresentada no capítulo 3, especialmente em sistemas mal condicionados, os quais estão cada vez mais presentes no meio industrial pelo fato da integração mássica e energética dos sistemas, motivou a elaboração deste capítulo. Neste sentido, descreve-se uma unidade piloto real, em que foram aplicadas e comparadas diferentes estratégias de identificação multivariável.

O objetivo principal desta aplicação é, de fato, analisar o potencial da usual estratégia (degraus isolados) e confrontá-la com a estratégia proposta por este trabalho, em sistemas reais, nos quais a presença de distúrbios não medidos, ruídos de medida e não-linearidades, fatores que limitam a qualidade dos modelos obtidos, são características intrínsecas do processo.

Para conduzir o assunto de forma a priorizar a didática, as subdivisões deste capítulo descrevem:

- a unidade piloto utilizada para os testes de identificação;
- os dados de planta tanto para o caso de perturbações isoladas quanto para o caso de perturbações orientadas nas principais direções, o procedimento de identificação;
- uma comparação sistemática entre os modelos identificados a partir dos dois conjuntos de dados.

5.1 Planta Piloto de Cinco Tanques

Esta unidade, foi desenvolvida principalmente para dar apoio ao ensino de engenharia química. Muitos fenômenos apresentados em sala de aula, podem ser vistos, de forma prática, nas unidades piloto do Laboratório de Controle e Integração de Processos (LACIP/DEQUI/UFRGS). Em especial, a unidade de 5 tanques abrange tópicos relacionados à identificação e controle multivariável. Desta forma, procurou-se explorar nesta unidade o aspecto do mal condicionamento do sistema para que fosse vislumbrado todo o potencial da sistemática de perturbações apresentada e defendida neste trabalho. Obviamente, não apenas em sistema mal condicionados a metodologia pode ser aplicada, mas também em qualquer sistema que necessite de identificação multivariável.

5.1.1. Descrição da Unidade

A unidade possui 5 tanques cilíndricos de igual formato e volume, dispostos em duas linhas horizontais em cotas diferentes. Três tanques estão na linha inferior (tanques 1, 5 e 2), interconectados entre si e dois tanques estão na linha superior (tanques 3 e 4), sem contato entre si mas ligados aos tanques da linha inferior. A unidade opera com água a temperatura ambiente, a qual permanece em um reservatório situado em cota igual a zero. O fluido é levado até os tanques através da ação de duas bombas centrífugas axiais e um conjunto de mangueiras rígidas. Estas mangueiras estão dispostas de forma que os tanques 1 e 4 e os tanques 2 e 3 sejam alimentados simultaneamente. Os tanques 3 e 4 (tanques superiores) têm suas descargas orientadas para os tanques 1 e 2, respectivamente, que por sua vez descarregam no reservatório inferior. Apenas o tanque 5 é alimentado pelas conexões com os demais tanques. As linhas de alimentação possuem duas válvulas de controle cada, de forma que num determinado momento tem-se a liberdade de orientar a alimentação de qualquer tanque em separado, parte deles ou todos simultaneamente. Para facilitar o entendimento do sistema, a Figura 5.1 apresenta um fluxograma simplificado do sistema e uma foto do mesmo.


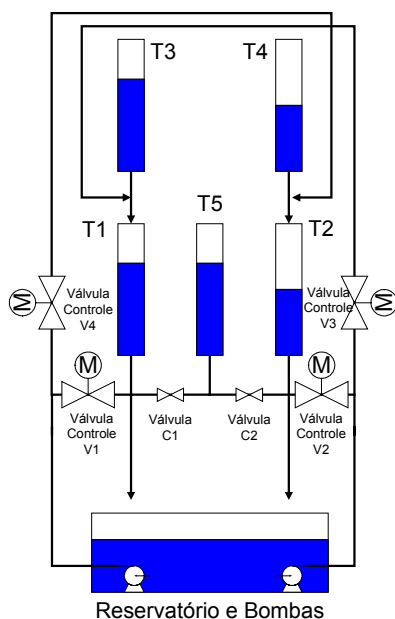


Figura 5.1: Fluxograma simplificado e foto da unidade de cinco tanques.

De acordo com o fluxograma da Figura 5.1, ainda existem na unidade, válvulas manuais tipo globo para a regulagem de vazão nas linhas de interconexão dos tanques. (válvulas C1 e C2). As válvulas de controle recebem o nome de V1, V2, V3 e V4. As válvulas V1 até V4, apresentam características interessantes que devem ser ressaltadas, como por exemplo, o efeito da não-linearidade de suas curvas de vazão, uma vez que estas válvulas são do tipo abertura rápida, apresentando uma "zona morta" inferior e superior e também o efeito da histerese, isto é, apresentam relação entre vazão e abertura de válvula diferentes na abertura e no fechamento, fazendo com que para uma mesma posição de abertura determinada pelo operador ou pelo controlador, corresponda a duas posições reais e distintas do obturador e consequentemente da vazão. A Figura 5.2 apresenta o comportamento de histerese da válvula e sua curva de vazão.

Além da histerese das válvulas, existe ainda uma peculiaridade nesta unidade: os tanques são alimentados pelo fundo, obedecendo um balanço de quantidade de movimento. Sendo assim, as colunas de líquido dos tanques superiores realizam uma força sobre os atuadores das quatro válvulas de controle. Se as colunas são altas, ou seja, se os tanques superiores estão cheios, menor será a abertura das válvulas de controle que enviam fluido para os tanques superiores, facilitando o enchimento dos tanques inferiores, e vice-versa. Por consequência, os níveis dos cinco tanques estão acoplados entre si, não só pelas ligações entre eles proporcionadas pelas tubulações, mas também devido às válvulas de controle. Este acoplamento traz dificuldades adicionais à identificação, levantando a possibilidade da identificação estruturada do sistema (ISS), a qual será discutida na próxima subseção.




Figura 5.2: Visualização da histerese no sistema provocada pelas válvulas de controle e curva de vazão destas válvulas.

5.2 Identificação Estruturada

Com o objetivo de minimizar o acoplamento entre os níveis dos tanques da unidade na identificação do modelo, estudou-se a identificação estruturada do sistema. Este tipo de identificação prioriza as características básicas do sistema ignorando interações secundárias entre os diversos canais da matriz de transferência. Num subcaso da unidade de 5 tanques,

utiliza-se as quatro válvulas e os tanques de 1 a 4 (exceto o tanque 5) e observa-se que as válvulas 1 e 2 afetam diretamente os níveis dos tanques 1 e 2, respectivamente e que as válvulas 3 e 4 afetam diretamente os níveis dos tanques [1, 3] e [2, 4] respectivamente. Ignorando-se as demais interações, a identificação torna-se facilitada, uma vez que na identificação dos modelos dos tanques inferiores as válvulas 3 e 4 permanecem fechadas e na identificação dos modelos dos tanques superiores as válvulas 1 e 2 ficam totalmente fechadas. No entanto, é possível que o controlador não apresente o máximo desempenho possível fazendo uso de um modelo estruturado, justamente por não conhecer os efeitos das interações secundárias do sistema. A Figura 5.3 apresenta a simulação dos modelos estruturado e não estruturado (modelo convencional em que não se desprezam as interações secundárias do sistema) para o sistema composto pelas 4 válvulas de controle (variáveis manipuladas) e pelos níveis dos tanques de 1 a 4 (variáveis controladas), em um conjunto de dados de validação, o qual é distinto dos conjuntos de identificação dos modelos estruturado e do modelo convencional.




Figura 5.3: Simulação dos modelos estruturado e convencional em conjunto externo de validação, com o confronto com os dados de planta, para os quatro níveis dos tanques da planta piloto. Nos gráficos de Y1 a Y4 (níveis dos tanques), a linha cheia (-) representa os dados de validação enquanto que as linhas (--) e (-.) representam, respectivamente, o modelo estruturado e o não estruturado.

Pode-se observar que os modelos dos canais das variáveis de saída 1 e 3 (níveis dos tanques do ramo esquerdo da planta) apresentaram menor qualidade no modelo estruturado em relação ao modelo convencional e que os resultados assemelham-se quanto à identificação dos modelos dos canais das saídas 2 e 4 (níveis dos tanques do ramo direito da planta). Provavelmente este resultado possa ser explicado pela grande influência que os níveis dos tanques do 2 e 4 têm sobre a posição de abertura real das válvulas de controle 1 e 3, as quais liberam ou não fluido para os tanques 1 e 3, (veja Figura 5.1). É possível que a coluna de líquido dos tanques 2 e 4 esteja impedindo a movimentação adequado do obturador de cada válvula do sistema, influenciando na vazão de fluido que se destina aos tanques 1 e 3. Os modelos estruturado e o convencional têm sua resposta a um degrau unitário mostrados na Figura 5.4.

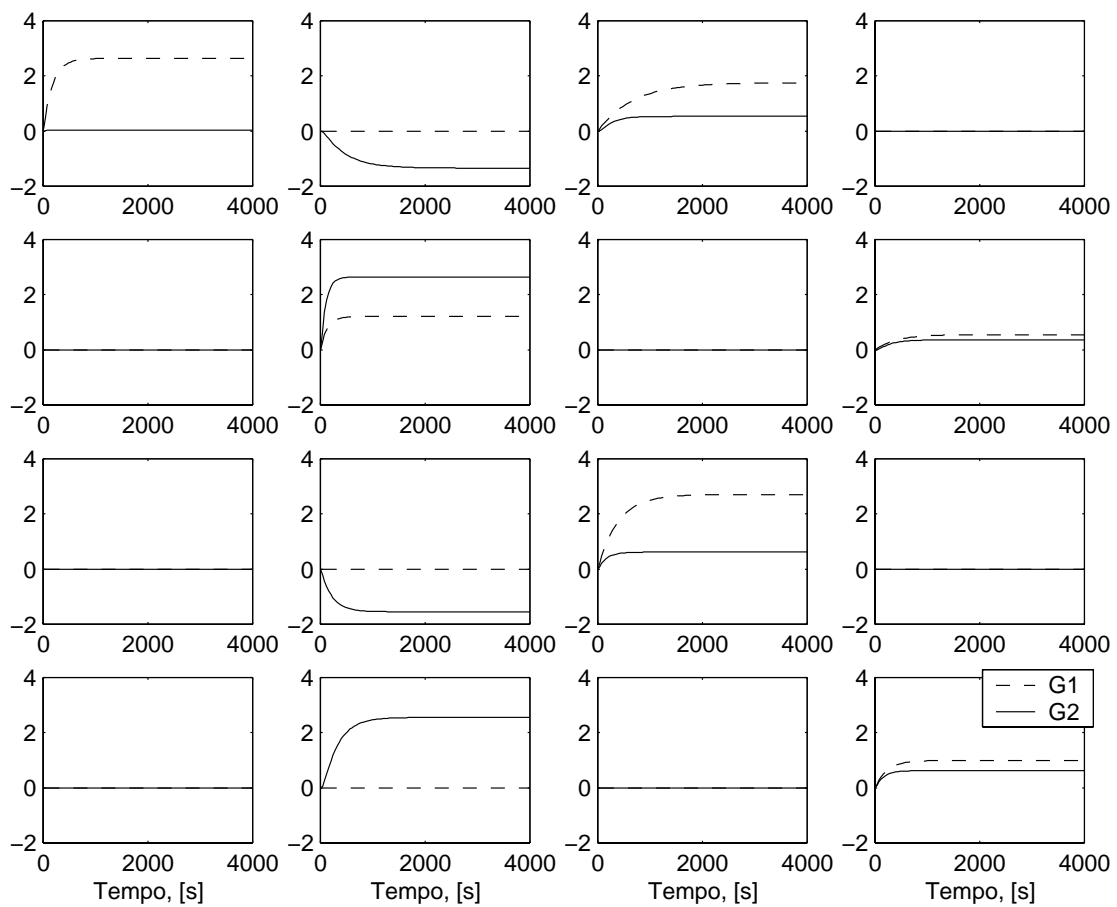


Figura 5.4: Comparação entre a resposta a um degrau unitário entre os modelos estruturado e o convencional do sistema composto por quatro níveis (tanques 1 a 4) e a posição de abertura das quatro válvulas do sistema (válvulas 1 a 4). G1 é o modelo estruturado (linha tracejada) e G2 é o modelo não estruturado (linha contínua). Por convenção, as linhas da matriz representam as saídas (níveis dos tanques de 1 a 4) e as colunas, as entradas do sistema (posição de abertura das válvulas de controle).

Os resultados apresentados nas figuras 5.3 e 5.4 apontam que a identificação estruturada não gerou modelos consistentes, especialmente para a primeira entrada (válvula V1). No entanto,

não se pode descartar os modelos dos demais canais do modelo estruturado, visto que a presença da histerese provavelmente corrompeu os resultados.

5.3 Identificação de Sistemas Mal-Condicionados

De acordo com a literatura [AK92] e conforme foi apresentado no capítulo 3 deste trabalho, perturbações multivariáveis melhoram a qualidade do modelo identificado especialmente quando se tratam de sistemas mal-condicionados. Neste tipo de sistema, dependendo das direções de entrada das variáveis manipuladas, a resposta das saídas pode ser insignificante frente à amplitude do ruído destas variáveis, diminuindo a qualidade do modelo identificado. Este fato ocorre porque a dinâmica e o ganho de diversos canais da matriz de transferência de um sistema mal-condicionado são próximas. Desta forma, as perturbações orientadas nas principais direções do sistema tendem a fornecer dados mais ricos em informações dinâmicas do processo em relação às perturbações de graus isoladas, amplamente praticadas.

Um dos possíveis subsistemas da planta de 5 tanques é um exemplo real de sistemas mal-condicionados. Utilizando-se apenas os três tanques inferiores (tanques 1, 5 e 2) e duas das quatro válvulas de controle da unidade (válvulas V1 e V2) (veja Figura 5.5). Neste subsistema deseja-se controlar os níveis dos tanques 1 e 5 com a manipulação das posições de abertura das válvulas de controle V1 e V2. A descarga para o reservatório inferior é feita através de linhas situadas logo abaixo dos tanques 1 e 2. Fisicamente, espera-se que a válvula V1 influencie mais rapidamente (menor constante de tempo) os níveis dos tanques 1 e 5 em relação às variações na válvula V2, uma vez que o fluido provindo da linha desta última válvula precisa passar por mais desvios e acidentes nas tubulações até chegar aos tanques 1 e 5. A influência de V2 nas variáveis controladas depende justamente das restrições à passagem de fluido na linha de alimentação, especialmente da posição de abertura da válvula manual C2 (veja Figura 5.5). Como o mal condicionamento advém da correlação entre as dinâmicas e os ganhos das funções de transferências dos níveis dos tanques 1 e 5, a posição de abertura da válvula C1 é fundamental e regula o quão próximo estarão os modelos dos diferentes canais do sistema entre si. Se C1 estiver totalmente aberta, as dinâmicas, teoricamente, tendem a ser as mesmas, embora exista fisicamente a preferência para o fluido provindo da linha da válvula de controle V1 alimentar antes o tanque 1 a alimentar o tanque 5.




Figura 5.5: Representação simplificada do subsistema 3 tanques da planta de 5 tanques.

Dois modelos foram obtidos para o subsistema: um através do planejamento de perturbações multivariáveis nas principais direções do sistema (G1) e o outro através de perturbações do tipo degraus isolados (G2). Para ilustrar aplicabilidade da metodologia de perturbações apresentada no capítulo 3 deste trabalho, optou-se por realizarem os testes com a válvula C1 totalmente aberta, fazendo com que o sistema ficasse, em teoria, o mais mal condicionado possível. Os modelos identificados foram validados em um terceiro conjunto de dados, diferente dos conjuntos de dados usados para identificar os modelos G1 e G2. Os dois testes de identificação realizados possuem tempo de amostragem de 5 (cinco) segundos. A simulação do modelo G1 (perturbações simultâneas) e os dados gerados pelas perturbações orientadas e simultâneas são apresentadas na Figura 5.6.




Figura 5.6: Confronto entre os dados de planta do modelo G1 e a simulação deste modelo.

Vale lembrar que a amplitude e o tempo de perturbação do teste de identificação cujos os dados estão na Figura 5.6 foram calculados segundo a metodologia apresentada no capítulo 3.

Da mesma forma que para o modelo anterior, os dados de planta contendo as perturbações do tipo degrau isolados e seus efeitos nos níveis dos tanques 1 e 2 são mostrados na Figura 5.7.






Figura 5.7: Confronto entre os dados de planta do modelo G2 e a simulação deste modelo.

Os dois modelos simulados confrontados com seus respectivos dados de identificação foram gerados através do algoritmo de Box-Jenkins, implementado no IDENT Toolbox do software MATLAB[®] [IDENT], e são de primeira ordem com uma unidade de amostragem de tempo morto para todos os canais de ambas as funções de transferência. As comparações feitas entre os modelos e os dados de planta para os dois modelos ainda não é suficiente para apontar qual modelo será escolhido para representar o sistema. É preciso e a literatura recomenda [LJ99], a realização de uma comparação em um terceiro conjunto de dados para ser realizada a etapa de validação do modelo. No entanto, no trabalho de Andersen e Kummel (1992) [AK92], foi verificado que modelos gerados a partir de dados de planta com perturbações isoladas tendem, embora representem bem a planta dentro de seu conjunto de dados de identificação, quando são simulados em conjuntos de dados contendo perturbações simultâneas perdem parcialmente suas capacidades preditivas. E como os controladores de processo multivariáveis tipo MPC (*Model Predictive Controller*), amplamente utilizados em indústrias de processo, manipulam simultaneamente todas as variáveis que têm à disposição, é mais seguro utilizar modelos que capturem corretamente as características multivariáveis da planta real, como é o caso dos modelos obtidos através de dados com perturbações multivariáveis (perturbações simultâneas). Desta forma, neste caso, os dados de validação dos modelos do subsistema de 3 tanques contém duas seções: uma seção com perturbações simultâneas e outra com perturbações isoladas. Os resultados práticos podem ser visualizados nos gráficos da Figura 5.8.



Trecho com perturbações simultâneas em V1 e V2 – Dados de Validação.



Trecho com perturbações isoladas em V1 e V2 - Dados de Validação.

Figura 5.8: Confronto entre os dados de validação (dados de planta) e a simulação dos modelos G1 (perturbações simultâneas) e G2 (perturbações isoladas).

Dentre as comparações mais usuais entre modelos, encontra-se a resposta a um degrau unitário. Para os modelos G1 e G2, este tipo de resposta está apresentado na Figura 5.9.




Figura 5.9: Comparação entre as respostas a um degrau unitário dos modelos G1 (perturbações simultâneas) e G2 (perturbações isoladas).

A Figura 5.10 apresenta os valores singulares máximos e mínimos dos modelos G1 e G2 para o intervalo de frequências considerado importante para o controle de processos.




Figura 5.10: Comparação entre os valores singulares máximos e mínimos dos modelos G1 (perturbações simultâneas) e G2 (perturbações isoladas)

A Figura 5.11 mostra a comparação entre o condicionamento mínimo dos modelos G1 (perturbações simultâneas) e G2 (perturbações isoladas).




Figura 5.11: Comparação entre os valores de condicionamento mínimo dos modelos G1 (perturbações simultâneas) e G2 (perturbações isoladas).

Sintetizando as comparações entre os modelos, a Tabela 5.1 contém informações quantitativas da remoção da planta de seu ponto de operação normal, através de avaliação da média, do desvio e da variância das medidas em torno do ponto em que os modelos foram obtidos. Além destas informações, a Tabela 5.1 indica numericamente qual dos dois modelos representou melhor o comportamento dinâmico do sistema.

Tabela 5.1: Análise estatística dos dados de planta dos testes de identificação e validação apresentados no capítulo 5, na identificação do modelo do subsistema de 3 (três) tanques.

| Conjuntos de dados | Variável | Média dos dados de planta | Desvio dos dados de planta em relação à média | Variância dos dados de planta | Integral do erro absoluto entre a simulação do modelo e os dados de planta dividido pelo tempo total de cada conjunto de dados. |
|--|------------------------|---------------------------|---|-------------------------------|---|
| Perturbações Simultâneas –Dados de Identificação (G1) 8570 segundos | y1 (nível do tanque 1) | 3,54 | 1,99 | 3,97 | 0,11 |

| | | | | | |
|--|------------------------|---|-----------|-------|-----------------------|
| | y2 (nível do tanque 5) | 1,74 | 2,08 | 4,36 | 0,31 |
| Perturbações Isoladas – Dados de Identificação (G2) 9145 segundos | y1 (nível do tanque 1) | -4,66 | 3,60 | 13,01 | 0,65 |
| | y2 (nível do tanque 5) | -2,99 | 2,74 | 7,51 | 0,32 |
| Perturbações Simultâneas –Trecho dos dados de Validação (G1 e G2) 5685 segundos | y1 (nível do tanque 1) | 0,16 | 1,90 | 3,63 | [G1,G2] = [0,12 0,15] |
| | y2 (nível do tanque 5) | 1,05 | 1,58 | 2,49 | [G1,G2] = [0,14 0,15] |
| Perturbações Isoladas – Trecho dos dados de Validação (G1 e G2) 7660 segundos | y1 (nível do tanque 1) | 6,53 | 4,98 | 24,85 | [G1,G2] = [0,78 0,68] |
| | y2 (nível do tanque 5) | 7,00 | 4,69 | 22,05 | [G1,G2] = [0,91 0,75] |
| Zeros de Transmissão Modelo G1 -0.0035 + 0.0009i e -0.0035 - 0.0009i | | Zeros de Transmissão Modelo G2 -0.0008 e -0.0061 | | | |
| Critério da derivada - dados de validação com perturbações simultâneas | Modelo G1 | | Modelo G2 | | |
| Saída 1 | 6.58 | | 6.11 | | |
| Saída 2 | 4.42 | | 4.01 | | |
| Critério da derivada - dados de validação contendo perturbações isoladas. | Modelo G1 | | Modelo G2 | | |
| Saída 1 | 8.71 | | 8.17 | | |
| Saída 2 | 5.86 | | 5.38 | | |

Confrontando os dados da Tabela 5.1 e os gráficos das figuras anteriores, pode-se claramente dizer que o modelo que melhor representa o sistema de três tanques é o modelo obtido através de perturbações simultâneas, especialmente para a saída 1. Este efeito é melhor verificado através da integral do erro absoluto entre os dados de planta e os dados das saídas do modelo. De acordo com os dados do teste de identificação com perturbações isoladas, tanto nos dados de identificação quanto no trecho dos dados de validação, os efeitos da histerese são mais pronunciados com perturbações isoladas, em relação aos dados contendo perturbações simultâneas. Além desta constatação, pode-se afirmar que as perturbações isoladas removem a planta com maior intensidade em relação aos testes com perturbações simultâneas. Este fato pode ser observado numericamente através da média, desvio e variância dos dados experimentais.

Capítulo 6

Aplicação da Metodologia de Perturbações Proposta em Planta Industrial

A metodologia de perturbações proposta no capítulo 3 (três) foi aplicada na identificação de modelos dinâmicos de uma unidade industrial de destilação da PETROBRAS-Petróleo Brasileiro SA.

Neste capítulo explica-se como foram calculadas as perturbações para cada variável manipulada considerada no sistema e faz-se uma análise da qualidade dos modelos obtidos, além da unidade em que os testes foram realizados ser descrita de forma sucinta. Como o sistema analisado possui proporções relativamente grandes, estudou-se a formação de subsistemas para o planejamento das perturbações. Em cada subsistema, correspondente a cada torre da unidade, procurou-se agrupar as variáveis controladas e manipuladas mais importantes e relacionadas entre si em função da proximidade física das mesmas no sistema. Desta forma, o modelo gerado pode ser visto como sendo um modelo bloco-diagonal, facilitando o projeto do controlador multivariável do sistema.

A qualidade dos modelos obtidos foi averiguada através da comparação entre os dados de planta e as saídas simuladas dos modelos. Somado a esta comparação, foram analisados através de ferramentas básicas de estatística os dados dos testes de identificação para se dimensionar o quanto a planta foi removida do ponto de operação ao longo do conjunto de perturbações planejadas.

6.1 Planta Industrial

A aplicação mais importante da estratégia de identificação com perturbações baseadas na direcionalidade do sistema é, sem dúvidas, em plantas industriais e especialmente mal-condicionadas. Este trabalho apresenta resultados práticos da aplicação dos testes de identificação usando a metodologia de perturbações proposta na planta de destilação da UN-RECAP (Refinaria de Capuava, Mauá, São Paulo, Brasil), pertencente à PETROBRAS (Petróleo Brasileiro). Embora esta unidade não seja tão mal-condicionada, afortunadamente, estava à disposição para a realização de testes de identificação projetados através da metodologia de perturbações desenvolvida neste trabalho.

6.2. Descrição da Unidade

O petróleo é bombeado dos reservatórios, passando por permutadores de calor, até chegar à primeira coluna de separação, cujo nome é N-507 (corriqueiramente conhecida como torre de pré-flash), a qual provocará uma separação bruta dos diferentes componentes do petróleo. Basicamente o fundo da coluna contém frações de gasolina, Diesel e querosene além de compostos mais pesados. No topo da coluna, o principal produto é a nafta leve e solventes. A corrente de fundo da coluna inicial (N-507) é encaminhada para a coluna de destilação (N-506), após ter sido aquecida num forno atmosférico (L-506). Nesta coluna, são produzidas na corrente de topo o Diesel, a nafta pesada e a carga para a unidade debutanizadora, a qual produzirá gasolina e gás liquefeito do petróleo (GLP). A corrente de fundo serve de carga para a unidade de RFCC (craqueamento catalítico), a qual produzirá gasolina. A Figura 6.1 apresenta um fluxograma simplificado da unidade de destilação da RECAP.

A unidade é controlada através de um controlador preditivo multivariável (CPM) que utiliza modelos lineares. Este controlador é responsável por determinar o setpoint de algumas variáveis manipuladas, mantendo o processo numa determinada faixa de operação. Uma vez calculado o setpoint de cada uma das variáveis manipuladas do sistema, cabe aos controladores PID's (Proporcional-Integral-Derivativo) o cálculo de ações de controle que façam com que as variáveis manipuladas do sistema alcancem os valores de setpoint para estas variáveis determinado pelo CPM. Em outras palavras, as ações de controle do controlador preditivo são os setpoints dos diversos controladores PID. Não se pode esquecer que os setpoints das variáveis manipuladas calculados pelo controlador preditivo estão de acordo com os setpoints das variáveis controladas (ou por faixas de operação) determinadas pela equipe de controle e otimização da unidade. Na Figura 6.1 as variáveis que apresentam a letra "U" são as variáveis manipuladas do controlador preditivo e as designadas pelas letra "Y" são as variáveis controladas em relação ao controlador preditivo. Estas variáveis estão descritas nas Tabelas 6.1 e 6.2, respectivamente as variáveis manipuladas e controladas em relação ao controlador preditivo. Não custa lembrar que a aplicação de algoritmos de controle preditivo em uma unidade caracteriza uma aplicação de controle avançado de processos.

Tabela 6.1: Variáveis manipuladas do sistema.

| Nº | Descrição | Unidade | Tag |
|----|---|---------------------|--------------|
| 1 | Vazão de carga | m ³ /dia | fc_50002b.sp |
| 2 | Temperatura de topo da coluna de pré-flash | °C | tc_50004.sp |
| 3 | Vazão de refluxo de Diesel pesado | m ³ /dia | fc_50041.sp |
| 4 | Temperatura de topo da coluna de destilação | °C | tc_50010.sp |
| 5 | Vazão de retorno de RCI | m ³ /dia | fc_50038.sp |
| 6 | Vazão de vapor de fundo da coluna de pré-flash | T/h | fc_50124.sp |
| 7 | Temperatura do forno de craqueamento entre a coluna de pré-flash e a coluna de destilação | °C | tc_50068.sp |
| 8 | Vazão de Querosene | m ³ /dia | fc_50036.sp |

Tabela 6.2: Variáveis controladas do sistema.

| Nº | Descrição | Unidade | Tag |
|----|---|---------------------|------------------|
| 1 | Ponto final de ebulição da nafta leve. | °C | infu500nl_dpf |
| 2 | Vazão de topo da torre de Pré-Flash | m ³ /dia | fi_50018 |
| 3 | Vazão de refluxo da torre de pré-flash | m ³ /dia | fc_50016 |
| 4 | Ponto de fulgor da corrente de Diesel da torre de pré-flash | °C | infu500del_fulgs |
| 5 | Ponto final de ebulição da nafta pesada. | °C | infu500np_dpf |
| 6 | Vazão de nafta pesada. | m ³ /dia | fc_50020 |
| 7 | Vazão de refluxo da torre de destilação. | m ³ /dia | fc_50022 |
| 8 | Ponto de fulgor da corrente de querosene. | °C | infu500qi_fulg |

| | | | |
|----|---------------------------------------|---------------------|-----------------|
| 9 | Ponto final de ebulição do querosene. | °C | infu500qi_dpf |
| 10 | Ponto de fulgor do Diesel linha. | °C | infu500dl_fulg |
| 11 | Ponto de entupimento do Diesel linha. | °C | infu500dl_entup |
| 12 | Especificação ASTM do Diesel Linha | °C | infu500dl_d85 |
| 13 | Vazão de Diesel Pesado | m ³ /dia | fc_50040 |
| 14 | Vazão de Resíduo Atmosférico. | m ³ /dia | fc_50203 |

6.3. Planejamento de Perturbações e Identificação dos Modelos

De acordo com a Figura 6.1, o sistema industrial estudado pode ser dividido em três blocos: o bloco da carga da unidade (bloco1), o bloco das variáveis pertencentes à torre de pré-flash (bloco2) e, por fim, o bloco 3 que reúne as informações relacionadas à coluna de destilação. Deve-se ter em mente que para o controle da unidade são necessários bons modelos entre as variáveis manipuladas e controladas de cada subsistema da planta total. Desta forma, procurou-se agrupar as variáveis da Tabela 6.2 que são mais relevantes para o controle do sistema para que o planejamento de perturbações das variáveis manipuladas correspondentes fosse realizado. Para ilustrar este agrupamento, a Figura 6.2 apresenta um diagrama simplificado de quais variáveis controladas e manipuladas constituíram os blocos de planejamento de perturbações.

| N° | YU | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 |
|----|-----------------|---------------|---------------|---------------|---------------|---------------|---------------|---------------|---------------|
| | | fc_50002b | tc_50004 | fc_50041 | tc_50010 | fc_50038 | fc_50124 | tc_50068 | fc_50036 |
| 1 | infu500nl_dpf | Bloco1 | BLOCO2 | s/ modelo | s/ modelo | s/ modelo | BLOCO2 | s/ modelo | s/ modelo |
| 2 | fi_50018 | Bloco1 | BLOCO2 | s/ modelo | s/ modelo | s/ modelo | BLOCO2 | s/ modelo | s/ modelo |
| 3 | fc_50016 | Bloco1 | Bloco2 | s/ modelo | s/ modelo | s/ modelo | Bloco2 | s/ modelo | s/ modelo |
| 4 | infu500del_fulg | Bloco1 | Bloco2 | s/ modelo | s/ modelo | s/ modelo | Bloco2 | s/ modelo | s/ modelo |
| 5 | infu500np_dpf | Bloco1 | Bloco2 | Bloco3 | Bloco3 | Bloco3 | Bloco2 | Bloco3 | Bloco3 |
| 6 | fc_50020 | Bloco1 | Bloco2 | BLOCO3 | BLOCO3 | BLOCO3 | Bloco2 | BLOCO3 | BLOCO3 |
| 7 | fc_50022 | BLOCO1 | Bloco2 | BLOCO3 | BLOCO3 | BLOCO3 | Bloco2 | BLOCO3 | BLOCO3 |
| 8 | infu500qi_fulg | Bloco1 | Bloco2 | Bloco3 | Bloco3 | Bloco3 | Bloco2 | Bloco3 | Bloco3 |
| 9 | infu500qi_dpf | Bloco1 | Bloco2 | Bloco3 | Bloco3 | Bloco3 | Bloco2 | Bloco3 | Bloco3 |
| 10 | infu500dl_fulg | Bloco1 | Bloco2 | BLOCO3 | BLOCO3 | BLOCO3 | Bloco2 | BLOCO3 | BLOCO3 |
| 11 | infu500dl_entup | Bloco1 | Bloco2 | Bloco3 | Bloco3 | Bloco3 | Bloco2 | Bloco3 | Bloco3 |
| 12 | infu500dl_d85 | Bloco1 | Bloco2 | BLOCO3 | BLOCO3 | BLOCO3 | Bloco2 | BLOCO3 | BLOCO3 |
| 13 | fc_50040 | Bloco1 | Bloco2 | BLOCO3 | BLOCO3 | BLOCO3 | Bloco2 | BLOCO3 | BLOCO3 |
| 14 | fc_50203 | BLOCO1 | Bloco2 | BLOCO3 | BLOCO3 | BLOCO3 | Bloco2 | BLOCO3 | BLOCO3 |

Figura 6.2: Diagrama das variáveis controladas e manipuladas constituintes dos blocos de planejamento de perturbações para a unidade de destilação.

Dentro de cada bloco existem pares de variáveis controladas (Y) e manipuladas (U) que estão destacados em letras maiúsculas, conforme é mostrado na Figura 6.2. Foram justamente estas variáveis cujos seus pré-modelos serviram de base para o planejamento de perturbações. Observe que esta escolha foi realizada com base na experiência de engenharia e controle de processos da equipe de controle e otimização da planta. Como pode ser observado na Figura 6.2, não foram obtidos modelos para as quatro primeiras saídas, as quais pertencem à primeira coluna do sistema, em relação às variáveis manipuladas 3, 4, 5, 7 e 8, uma vez que estas variáveis manipuladas afetam diretamente a segunda coluna da unidade. Cabe ressaltar que todas as variáveis controladas cujo nome (*tag*) inicia pelas letras "*inf*", são inferências de propriedades do processo. Em outras palavras, as inferências são estimativas dos valores de propriedades do sistema de difícil obtenção direta, baseadas em equações fenomenológicas do sistema aplicadas a variáveis conhecidas do processo.

Os modelos foram identificados com o algoritmo discreto OE (*Output Error*, do *Identification Toolbox*, do software MATLAB[®], [IDENT]), e da mesma forma que a identificação dos modelos da planta de 5 (cinco) tanques, os modelos discretos foram convertidos para modelos contínuos. Pela análise visual dos dados de planta, foi possível concluir que não houveram, ao longo dos testes de identificação, grandes distúrbios externos não medidos, fato que permite a utilização do algoritmo *Output Error* (veja Apêndice), uma vez que neste algoritmo apenas a parte determinística do sistema é considerada. Em outras palavras, para a parte estocástica não foi identificada função de transferência alguma, o que concorda com a observação da ausência de distúrbios externos não medidos durante os testes realizados. Além de se poder utilizar o algoritmo OE, devido à ausência de grandes distúrbios, o critério da derivada pouco acrescentaria à análise dos modelos. Conforme observado no capítulo 4 deste trabalho, a diferença mais acentuada entre usar o erro quadrático ou usar o erro quadrático da derivada verifica-se na presença de distúrbios externos não medidos.

Os dados foram gerados através da metodologia de perturbações baseada na direcionalidade do sistema, apresentada no capítulo 3 deste trabalho. Como pré-modelo foi utilizado o modelo vigente no controle da unidade, segundo as entradas e saídas de cada bloco. Vale lembrar que o pré-modelo foi obtido através da metodologia tradicional de perturbações (*step test*), identificado pouco tempo antes da aplicação da metodologia na unidade. A Figura 6.3 mostra as perturbações planejadas para as oito variáveis manipuladas do sistema. Vale lembrar que as perturbações calculadas apresentadas na Figura 6.3 estão sob a forma desvio, isto é, para se ter o valor real das variáveis manipuladas através dos gráficos, é necessário somar o valor do estado estacionário (ponto de operação) de onde foram feitas as perturbações.

É importante informar que os testes de identificação com as perturbações planejadas foram realizados com todas as malhas de controle regulatório e de inventário fechadas, isto é, todos os controlador PI (Proporcional-Integral) e PID (Proporcional-Integral-Derivativo) que atuam diretamente nas válvulas de controle permaneceram ativos ao longo das 30 horas de teste. O único controlador que esteve em malha aberta durante os testes foi o controlador preditivo multivariável, este baseado em resposta ao impulso FIR (*Finite Impulse Response*).

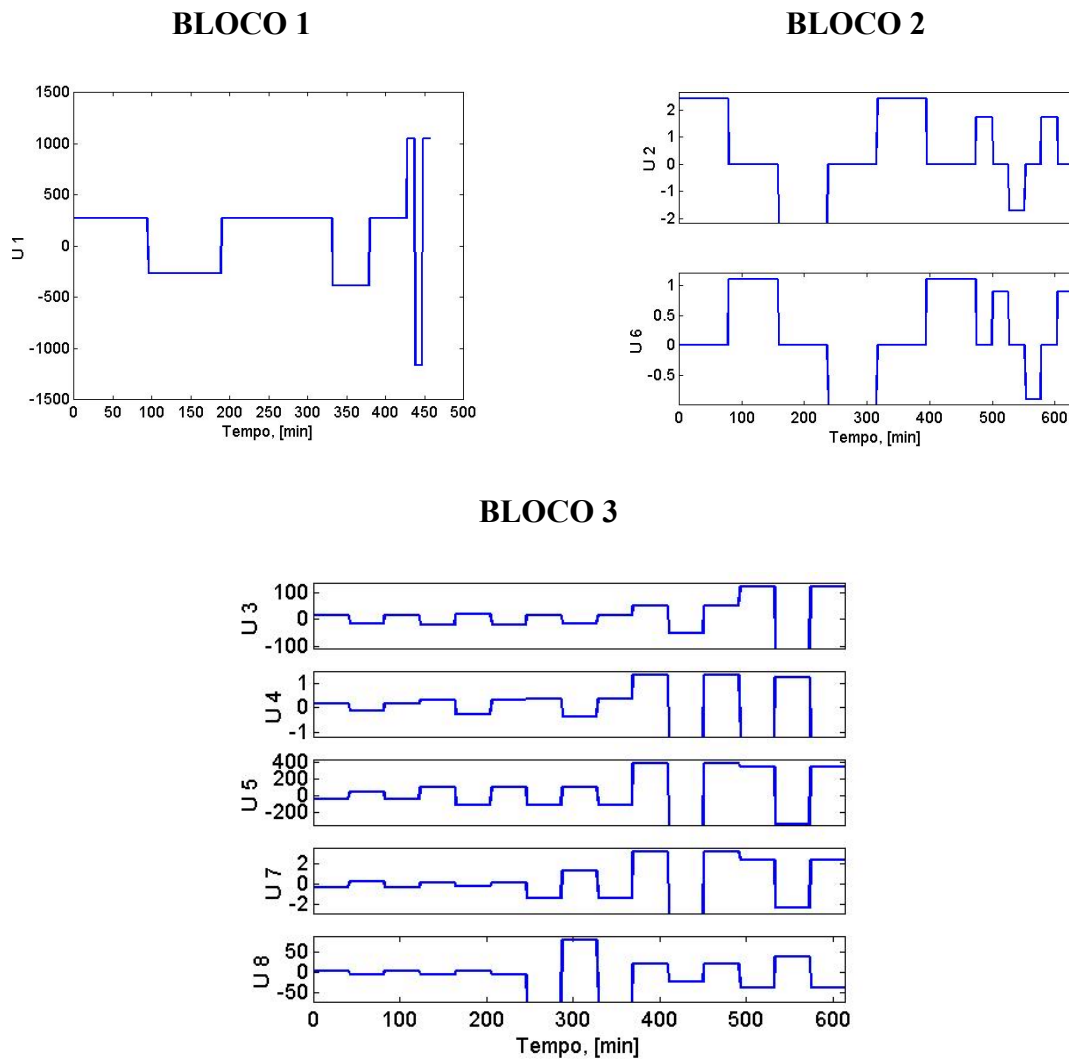


Figura 6.3: Perturbações planejadas para a identificação dos modelos da unidade de destilação.

Para exemplificar como foram calculadas as perturbações, tomar-se-á como exemplo o bloco 2, cujas variáveis controladas são as variáveis 1 e 2 da Tabela 6.2 e as variáveis de entrada do sistema são as variáveis 2 e 6 da Tabela 6.1. Veja também a Figura 6.2. O modelo vigente na planta foi usado como pré-modelo (G) para o planejamento. Este modelo tem sua resposta degrau, para as variáveis controladas 1 e 2 e manipuladas 2 e 6, mostrada na Figura 6.4.




Figura 6.4: Resposta degrau do pré-modelo (G) das variáveis do bloco 2.

O pré-modelo da Figura 6.4 tem a seguinte matriz de constantes de tempo:

$$CT = \begin{bmatrix} 15 & 35 \\ 30 & 25 \end{bmatrix} \text{ minutos}$$

originando uma constante de tempo baseada na média geométrica igual a $\tau_{GEO} = 25,04$ minutos. A frequência central de perturbações equivale a:

$$\omega_{GEO} = \frac{1}{\tau_{GEO}} = \frac{1}{25,04} = 0,0399 \text{ min}^{-1}$$

Nas perturbações realizadas nas variáveis manipuladas do bloco 2, foram utilizados os múltiplos 1 e 3 da frequência central, isto é, $0,0399 \text{ min}^{-1}$ e $0,1198 \text{ min}^{-1}$. O período de cada nível das variáveis manipuladas foram, então, iguais a:

$$tempo_permanencia = \left[\frac{\pi}{1 \cdot \omega_{GEO}} \quad \frac{\pi}{3 \cdot \omega_{GEO}} \right] = [78,69 \text{ min} \quad 26,23 \text{ min}]$$

Para cada frequência, o sistema G (pré-modelo) foi escalonado e submetido à subrotina de obtenção de valores singulares, cujas direções são os principais objetos da metodologia de perturbações proposta. As matrizes de direções das entradas para cada frequência estão mostradas a seguir:

$$\begin{array}{cc}
 0,0399 \text{ min}^{-1} & 0,1198 \text{ min}^{-1} \\
 \\
 V = \begin{bmatrix} 0,7071 & -0,7071 \\ 0,6981 + 0,1124i & 0,6981 + 0,1124i \end{bmatrix} & V = \begin{bmatrix} 0,7071 & -0,7071 \\ 0,7027 + 0,0786i & 0,7027 + 0,0786i \end{bmatrix}
 \end{array}$$

A matriz V contém as direções de maior ganho (coluna 1) e as direções de menor ganho (coluna 2). As amplitudes obtidas para as perturbações nas duas frequências e para as duas variáveis manipuladas estão mostradas na Tabela 6.3. Estas amplitudes foram obtidas após o cálculo dos fatores de expansão e utilizando a amplitude de ruído apresentada na Tabela 6.4,:

Tabela 6.3: Amplitude de perturbações para as duas variáveis manipuladas do bloco 2.

| Entradas | 0,0399 min ⁻¹ | 0,1198 min ⁻¹ |
|--------------------------------------|--------------------------|--------------------------|
| Entrada 1 (Variável 2 da Tabela 6.1) | 2,39 | 1,71 |
| Entrada 2 (Variável 6 da Tabela 6.1) | 1,10 | 0,90 |

Tabela 6.4: Amplitude do ruído de medida das variáveis controladas da unidade de destilação, obtidas para a determinação da amplitude das perturbações dos testes da metodologia de perturbações baseada na direcionalidade do sistema.

| Variável Controlada | Amplitude do Ruído | Variável Controlada | Amplitude do Ruído |
|---------------------|--------------------|---------------------|--------------------|
| 1 | 0,075 | 8 | 0,299 |
| 2 | 6,688 | 9 | 0,378 |
| 3 | 8,151 | 10 | 0,130 |
| 4 | 0,148 | 11 | 0,248 |
| 5 | 0,408 | 12 | 0,289 |
| 6 | 3,000 | 13 | 12,100 |
| 7 | 3,000 | 14 | 10,000 |

Para ilustrar a qualidade dos modelos identificados, confrontou-se as previsões do modelo e os dados de planta do teste de identificação, para a variável controlada n° 8 (infu500qi-fulg, veja Tabela 6.1). Cabe lembrar que variável escolhida é uma inferência e está sujeita a erros de modelagem e também é afetada por ruídos de medida das variáveis que compõem sua expressão de cálculo. O procedimento de comparação entre o modelo obtido e os dados de planta que foi aplicado à variável controlada n° 8 foi repetido para as demais variáveis controladas, naturalmente. A Figura 6.5 apresenta os resultados obtidos para a variável mencionada anteriormente.

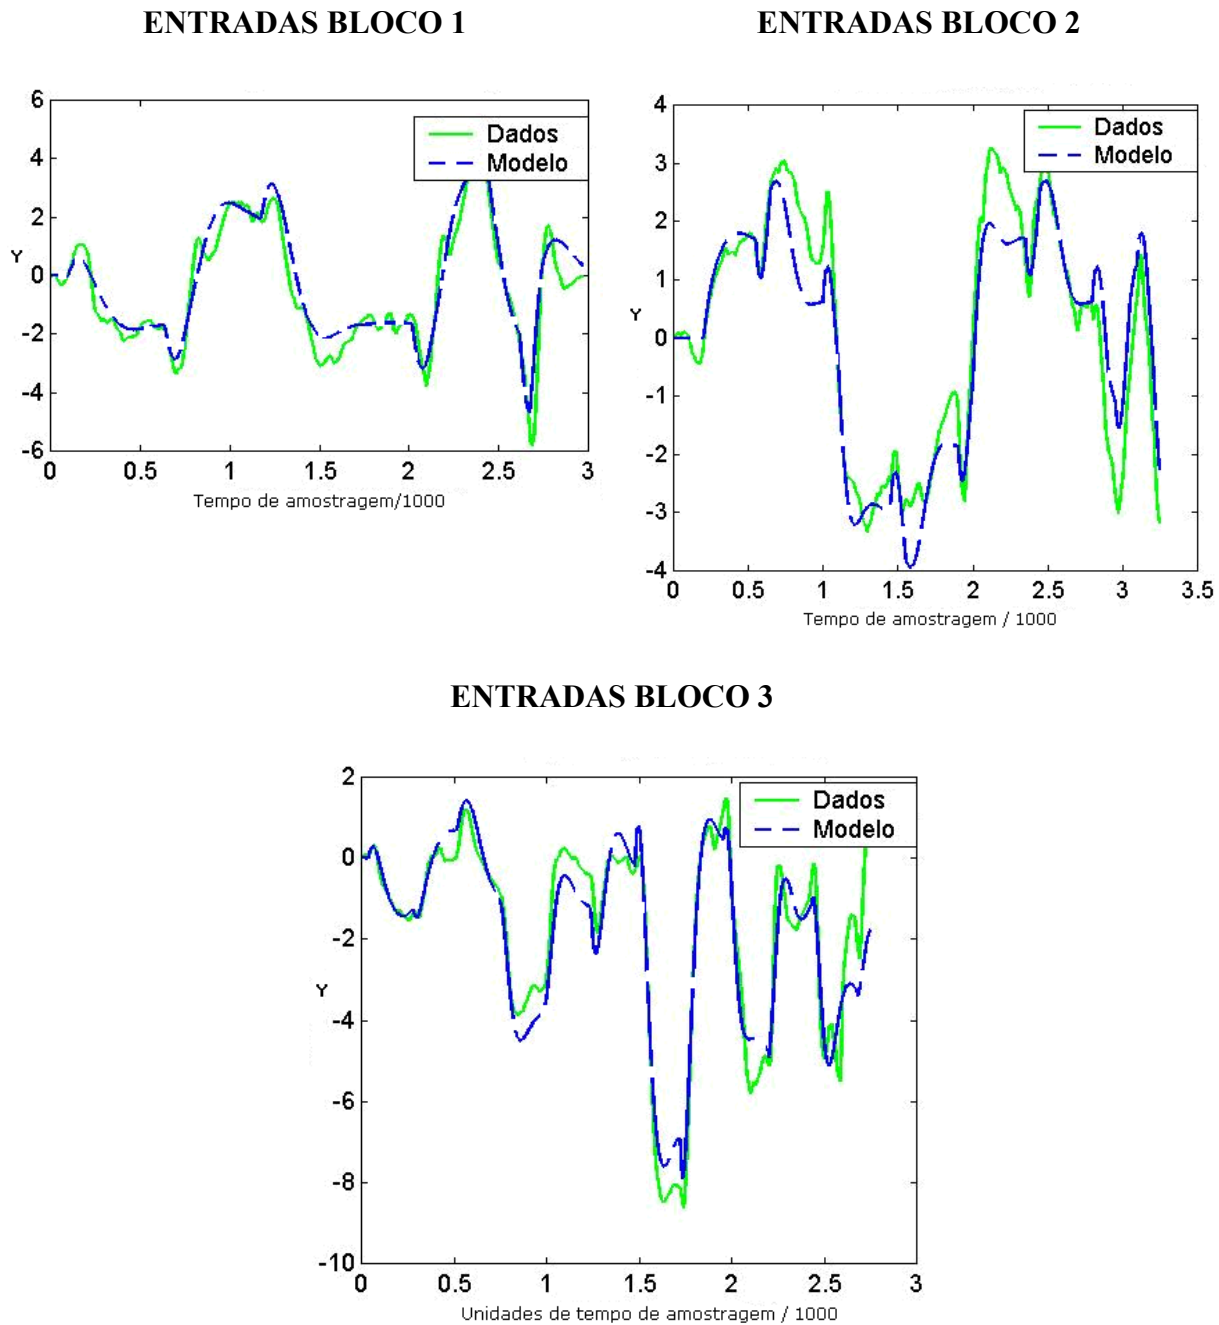


Figura 6.5: Comparação entre a previsão dos modelos obtidos para a saída 8 e os dados de planta desta variável (veja Tabela 6.2).

De maneira geral, os resultados obtidos na identificação dos modelos da unidade de destilação foram satisfatórios, uma vez que a duração dos testes foi pequena (30 horas), se comparada com o tempo de testes anteriores realizados com base nas perturbações da metodologia tradicional (45 horas). Outra vantagem da metodologia de perturbações baseada na direcionalidade do sistema, apontada experimentalmente, é a pequena remoção da planta do seu ponto de operação normal no momento dos testes. Este efeito minimiza a geração de produtos fora de especificação, diminuindo os custos de produção e operação. Para vislumbrar numericamente como a planta foi pouco removida de seu ponto de operação, foi feita análise semelhante à realizada na identificação dos modelos do subsistema de 3 tanques da planta de 5 tanques (ver capítulo 5) com os dados dos testes de identificação. A Tabela 6.5 apresenta os resultados desta análise.

Tabela 6.5: Propriedades estatísticas básicas dos dados da unidade de destilação estudada após os testes de identificação com perturbações projetadas a partir da metodologia proposta.

| Testes variando a carga da unidade, U1 | | | | | | | |
|---|--------------|---------------|------------------|-----------------|--------------|---------------|------------------|
| Variável | Média | Desvio | Variância | Variável | Média | Desvio | Variância |
| 1 | 144,07 | 0,55 | 0,31 | 8 | 46,35 | 2,06 | 4,25 |
| 2 | 758,86 | 17,17 | 294,83 | 9 | 249,02 | 4,33 | 18,76 |
| 3 | 1212,43 | 16,33 | 266,57 | 10 | 54,03 | 1,92 | 3,71 |
| 4 | 33,43 | 0,13 | 0,02 | 11 | -9,73 | 0,83 | 0,69 |
| 5 | 115,15 | 2,26 | 5,12 | 12 | 347,69 | 0,95 | 0,91 |
| 6 | 173,07 | 15,87 | 251,73 | 13 | 1839,43 | 130,06 | 16915,27 |
| 7 | 1874,53 | 106,47 | 11334,81 | 14 | 3423,85 | 153,91 | 23688,16 |
| Testes variando U2 e U6 | | | | | | | |
| Variável | Média | Desvio | Variância | Variável | Média | Desvio | Variância |
| 1 | 142,64 | 3,01 | 9,05 | 8 | 42,53 | 2,85 | 8,12 |
| 2 | 753,91 | 62,95 | 3962,74 | 9 | 235,88 | 3,21 | 10,31 |
| 3 | 1252,62 | 83,57 | 6984,69 | 10 | 53,03 | 3,91 | 15,30 |

| 4 | 34,63 | 3,52 | 12,39 | 11 | -10,05 | 1,50 | 2,25 |
|---|--------------|---------------|------------------|-----------------|--------------|---------------|------------------|
| 5 | 111,74 | 2,70 | 7,27 | 12 | 350,07 | 2,41 | 5,80 |
| 6 | 146,16 | 35,36 | 1250,63 | 13 | 1924,13 | 72,47 | 5252,47 |
| 7 | 2127,83 | 118,07 | 13940,54 | 14 | 3441,15 | 40,84 | 1667,96 |
| Testes variando simultaneamente U3,U4,U5,U7,U8 | | | | | | | |
| Variável | Média | Desvio | Variância | Variável | Média | Desvio | Variância |
| 1 | 143,80 | 0,51 | 0,26 | 8 | 41,86 | 2,39 | 5,71 |
| 2 | 783,37 | 12,32 | 151,71 | 9 | 227,05 | 4,19 | 17,57 |
| 3 | 1201,30 | 32,76 | 1073,31 | 10 | 56,48 | 2,56 | 6,55 |
| 4 | 35,33 | 0,10 | 0,01 | 11 | -9,63 | 1,50 | 2,25 |
| 5 | 116,06 | 3,50 | 12,23 | 12 | 350,41 | 1,94 | 3,75 |
| 6 | 157,12 | 37,83 | 1431,43 | 13 | 2035,30 | 85,50 | 7309,61 |
| 7 | 2227,72 | 92,07 | 8477,48 | 14 | 3585,73 | 42,37 | 1794,90 |

Capítulo 7

Conclusões e Sugestões para Futuros Trabalhos

7.1 Principais Conclusões

Neste trabalho foi desenvolvida uma metodologia de perturbações para a identificação de sistemas lineares baseada na direcionalidade do sistema, apoiada pelo sistemático estudo dos dados de planta também proposto e documentado nesta dissertação. Neste estudo incluiu-se ainda a caracterização da amplitude dos ruídos de medida das variáveis controladas. Observou-se em sistemas simulados apresentados no trabalho, que as perturbações geradas através da metodologia proposta trazem informações significativas a respeito da dinâmica do processo, em especial para os sistemas mal-condicionados. Para os demais sistemas estudados, tanto a metodologia tradicional (*step test*) quanto a metodologia desenvolvida, apresentaram resultados semelhantes. Mesmo assim, como a metodologia proposta gera perturbações ortogonais umas às outras, foi possível observar uma grande redução no tempo do teste de identificação quando comparado ao teste PRBS, conforme mostrou-se no exemplo do sistema LINDE no capítulo 3. Pode-se observar que a metodologia tradicional é um subcaso da metodologia proposta, tendo em vista que a matriz de direções nesta situação é a matriz identidade. Em outras palavras, cada variável manipulada é alterada de forma independente.

A aplicação da metodologia de perturbações baseada na direcionalidade do sistema em planta piloto (capítulo 5) apontou que a grande vantagem da metodologia é a geração de perturbações multivariáveis que removem muito pouco a planta do ponto de operação, em comparação com os sinais da metodologia tradicional, sem diminuir a qualidade dos modelos identificados. Com relação à aplicação em planta industrial, a metodologia gerou perturbações de tal forma que o tempo de duração do teste de identificação diminuiu (30 horas) em relação ao tempo de duração do teste de identificação realizado com os sinais da metodologia tradicional (45 horas, segundo os engenheiros de controle da unidade).

As vantagens comentadas anteriormente apenas foram observadas porque a primeira etapa da metodologia desenvolvida está fundamentada em um estudo sistemático dos dados de planta, apontando os dados mais propícios para a identificação, bem como caracterizando a amplitude do ruído das variáveis controladas, conforme foi apresentado no capítulo três. Com estas informações foi possível determinar um modelo simplificado da unidade para que o projeto das perturbações fosse corretamente realizado. De acordo com as propriedades estatísticas básicas dos dados de planta, após os testes planejados pela metodologia serem executados, concluiu-se que as perturbações planejadas pela metodologia removeram pouco a unidade do ponto de operação normal, praticamente minimizando a geração de produtos fora da qualidade exigida para a comercialização.

A respeito dos critérios de validação, é nítida a vantagem do critério da derivada, apresentado por este trabalho, frente aos critérios usualmente encontrados na literatura, tendo em vista que a presença de distúrbios não medidos dificultam a obtenção dos corretos parâmetros do modelo da planta e o critério da derivada lida muito bem com estes empecilhos.

É importante salientar que as três principais contribuições do trabalho são:

- 1) Sistematização da seleção de dados históricos mais propícios para a identificação de modelos simplificados do processo.
- 2) Criação de um novo critério de validação de modelos, contemplando a presença de distúrbios externos não medidos nas variáveis de saída.
- 3) Implementação e aplicação de uma nova metodologia de projeto de perturbações para a identificação de modelos lineares baseada na direcionalidade do sistema.

7.2 Sugestões para Trabalhos Futuros

De modo a dar continuidade a este trabalho observou-se a necessidade de investigar alguns pontos e novas idéias surgidas, discutidas a seguir:

- utilização do algoritmo de varredura dos dados de planta para a determinação do tempo morto do sistema.

O tempo morto desenvolve papel importantíssimo no sistema, uma vez que sua presença limita a performance do controlador. Se esta incógnita for corretamente estimada, certamente o projeto do controlador será mais consistente, de modo que se evitem ações rápidas suficientes para instabilizar o sistema em malha fechada.

- testar um critério de validação de modelos baseado não apenas na derivada dos erros de predição e nem apenas nos erros de predição, mas na combinação destas duas grandezas.

Basear-se apenas no critério da derivada pode ser fonte de erro na validação de modelos, especialmente se a estrutura do modelo for incorretamente selecionada. Além disto, num

conjunto de dados de identificação ou de validação, pode-se ter trechos contendo distúrbios e trechos sem distúrbios alternadamente, o que exigiria o uso de um critério misto. No entanto, um pequeno problema a ser resolvido na implementação deste critério misto é o correto escalonamento das grandezas dos valores da derivada do erro e do próprio erro.

- método de identificação baseado na derivada das saídas e não apenas nos valores das saídas.

Substituir o algoritmo de otimização usado na identificação de modelos baseada na derivada do erro (veja capítulo 4) é de fundamental importância para se aumentar a robustez do método, principalmente quanto à estimativa inicial a ser fornecida pelo usuário. Para que esta substituição ocorra, deve-se considerar a derivada do erro dentro do algoritmo de identificação.

- criação de uma metodologia para projeto de perturbações para a identificação em malha fechada.

Como foi observado ao longo deste trabalho, os modelos foram obtidos em malha aberta. No entanto, muitas malhas de controle não podem ser abertas para se realizarem os testes de identificação. Desta forma, é de extrema importância determinar os perfis de variação das variáveis manipuladas ao longo do teste de identificação em malha fechada.

Apêndice

Técnicas de Identificação

Este apêndice destina-se a apresentar alguns algoritmos de identificação encontrados na Literatura [LJ99], amplamente utilizados na indústria e citados/empregados neste trabalho. Entende-se por técnica de identificação a combinação entre as técnicas de perturbação e as técnicas de estimação de parâmetros dos modelos, bem como a correta escolha de pontos importantes para o sucesso da modelagem, tais como:

- seleção das características e estrutura do modelo
- seleção do algoritmo de estimação de parâmetros, quando o modelo é paramétrico
- modo de operação em que os dados de planta foram coletados, isto é, em malha aberta ou em malha fechada

Os modelos podem ser lineares ou não lineares. Embora os modelos não lineares sejam os que melhor reproduzam a realidade dos processos, a grande maioria dos controladores ativos nas plantas industriais utilizam modelos lineares devido à facilidade de cálculo das ações de controle. Na prática, o que se faz é linearizar o modelo não-linear, quando este é disponível, e operar-se em torno do ponto em que se linearizou. Diferentemente do modelo linear, o modelo não-linear é de natureza posicional, isto é, a mesma variação nas entradas em diferentes pontos de operação, pode produzir resultados significativamente distintos. Em alguns cenários industriais, a não-linearidade é confundida com distúrbios na carga, os quais são componentes estocásticos que precisam ser contempladas pelo modelo, assim como a distribuição estatística do ruído de medida. Modelos que contemplam estes efeitos são ditos modelos estocásticos. Por outro lado, se o interesse da identificação é obter a relação entre a entrada e a saída, ignorando os distúrbios, o modelo é chamado de determinístico.

Outra característica importante do modelo é sua representação ou não através de parâmetros. Os modelos não paramétricos procuram estabelecer uma relação entre a variável dependente e a independente, sendo esta última pertencente ao domínio do tempo ou da frequência. Os

modelos não-paramétricos mais simples, empregando-se o domínio do tempo, são obtidos através da resposta impulso e resposta degrau. No domínio da frequência, pode-se estimar uma função de transferência através da razão entre a transformada de Fourier discreta do sinal de saída e a transformada de Fourier discreta do sinal de entrada [LJ99].

Outro aspecto importante das técnicas de identificação é a escolha da estrutura do modelo. Entende-se por estrutura do modelo a presença ou não das parcelas determinística (resposta do sistema apenas depende das entradas), estocástica (resposta do sistema independe das entradas do sistema e sim de variáveis estocásticas) e mista (modelo apresenta tanto a parte determinística quanto a parte estocástica). Muitas são as estruturas de modelos para a identificação de sistemas desenvolvidas e documentadas na literatura [LJ99]. Basicamente, a grande maioria das as estruturas dos modelos discretos podem ser derivadas da Equação (A.1).

$$A(q)y(t) = \frac{B(q)}{F(q)}u(t) + \frac{C(q)}{D(q)}e(t) \quad (\text{A.1})$$

em que a variável q é a representação da variável z (domínio da frequência) no domínio do tempo. Os polinômios A , B , C , F e D são funções de q e contém os parâmetros a serem estimados. A variável $u(t)$ é o vetor ou matriz de dados da(s) entrada(s), enquanto $y(t)$ é o vetor da(s) saída(s) do sistema. A variável $e(t)$ representa distúrbios não medidos e ruídos de medida. A sumarização das principais estruturas dos modelos discretos mais utilizadas na identificação, encontra-se presente na Tabela A.1.

Tabela A.1: Principais estruturas de modelos discretos encontrados na literatura.

| Polinômios usados na Equação (A.1). | Estrutura do Modelo |
|-------------------------------------|---------------------|
| B | FIR |
| A, B | ARX |
| A, B, C | ARMAX |
| A, C | ARMA |
| A, B, D | ARARX |
| A, B, C, D | ARARMAX |
| B, F | OE (output error) |
| B, F, C, D | BJ (Box – Jenkins) |

Além dos métodos de identificação de modelos discretos, existem os modelos pertencentes ao domínio contínuo. A diferença básica entre os métodos de identificação discretos e contínuos é que os últimos fazem uso de operadores lineares ao modelo da planta, de modo a transformar a equação diferencial associada ao sistema em uma equação discreta, cujas derivadas de qualquer ordem podem ser conhecidas, aplicável a todos os instantes de tempo dos dados de planta, permitindo a construção de um sistema de equações para a estimação dos parâmetros do modelo final.

Outro importante algoritmo de identificação é a identificação no subespaço de estado (*SUBID*) [OM96]. Este algoritmo cria bloco de matrizes do tipo Hankel com os dados de entrada e de saída e faz uso de projeções oblíquas e decomposição em valores singulares para se determinar a ordem do sistema, as matrizes de observabilidade e o vetor de estados e, por conseqüência, determina as matrizes A , B , C e D que compõem a representação do sistema em espaço de estado. A grande vantagem deste algoritmo é a determinação da ordem do sistema, isto é, a ordem das funções de transferência envolvidas no sistema ou o tamanho das matrizes da representação em espaço de estado, e a possibilidade de utilizá-lo na identificação *MIMO* (*Multi-Input-Multi-Output*). Algoritmos anteriores a este, presentes na literatura, como por exemplo, *N4SID* (*Numerical algorithms for Subspace State Space System IDntification*), *MOESP* (*Multivariable Output-Error State sPace*) e *CVA* (*Canonical Variate Analysis*) realizam a identificação em espaço de estado utilizando diferentes projeções nos espaços de linhas e colunas obtidos através dos dados de planta.

Os dados de planta, principalmente os das variáveis de interesse, quase na totalidade dos casos, contêm além do efeito das entradas, os efeitos dos ruídos de medida e de distúrbios não medidos. Desta forma, a estrutura do modelo a ser identificado deverá conter tanto as relações determinísticas, quanto as relações estocásticas. Podem haver casos em que os dados de saída não são afetados por distúrbios e o modelo deverá conter apenas a estrutura determinística. Se observarmos a Tabela A.1, pode-se concluir que as estruturas *ARX*, *ARMAX* e *BJ* contemplam ambas as relações, enquanto que as estruturas *FIR* e *OE* não. O modelo gerado pelo algoritmo de *Poisson* é puramente determinístico enquanto que os modelos gerados pelo algoritmo *SUBID* podem considerar ambas as partes, determinística e estocástica. Além da estrutura do modelo, é necessário escolher um modo de identificação, o qual caracteriza sob quais condições foram coletados os dados de processo para a identificação. Estes modos são dois: modo malha aberta e modo malha fechada. Estes dois modos serão comentados mais adiante no texto deste apêndice.

A.1 Métodos Discretos

A maioria dos sistemas de controle das plantas industriais coletam os dados de forma discreta, segundo um determinado tempo de amostragem. Não é por acaso que os primeiros algoritmos de identificação e modelos dos controladores preditivos lineares apresentaram / apresentam a estrutura do modelo *FIR* (*Finite Impulse Response*), devido à simplicidade de implementação,

$$y = B \cdot u \quad (\text{A.2})$$

em que y é a resposta do sistema e u é a variável manipulada. A variável B representa o polinômio de ajuste entre as variáveis u e y . Os coeficientes do polinômio B representam a resposta a um impulso do sistema. Mais precisamente, a variável de saída, y , pode ser descrita como se segue:

$$y(k) = b_0 + b_1 q^{-1} u(k) + b_2 q^{-2} u(k) + b_3 q^{-3} u(k) + \dots + b_{nb} q^{-nb} u(k) \quad (\text{A.3})$$

em que o operador q^{-1} representa um atraso do valor da variável u em uma (01) unidade de tempo de amostragem. O índice k é o índice que representa o instante de amostragem atual. Naturalmente, u e y são, respectivamente, a entrada e a saída do sistema. O parâmetro nb é o número de coeficientes a serem estimados, compondo o modelo. Prosseguindo-se, obtém-se:

$$y(k) = b_0 + b_1 u(k-1) + b_2 u(k-2) + b_3 u(k-3) + \dots + b_{nb} u(k-nb) \quad (\text{A.4})$$

A Equação (A.4) é melhor representada e manipulada se for escrita de forma matricial, conforme Equação (A.5):

$$y(k) = \begin{bmatrix} 1 & u(k) & u(k-1) & \dots & u(k-nb) \end{bmatrix} \begin{bmatrix} b_0 \\ b_1 \\ \vdots \\ b_{nb} \end{bmatrix} \quad (\text{A.5})$$

Levando-se em conta que a Equação (A.5) deve ser resolvida para cada tempo de amostragem, o equacionamento torna-se:

$$\begin{bmatrix} y(k) \\ y(k-1) \\ \vdots \\ y(k-nb) \end{bmatrix} = \begin{bmatrix} 1 & u(k) & u(k-1) & \dots & u(k-nb) \\ 1 & u(k-1) & u(k-2) & \dots & u(k-nb-1) \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & u(nb) & & \dots & u(1) \end{bmatrix} \begin{bmatrix} b_0 \\ b_1 \\ \vdots \\ b_{nb} \end{bmatrix} \quad (\text{A.6})$$

Facilmente pode-se determinar os parâmetros do modelo *FIR* através do método dos mínimos quadrados, representado pela Equação (A.7):

$$B = (X^T \cdot X)^{-1} X^T Y \quad (\text{A.7})$$

em que X é a chamada matriz de regressores e Y é o vetor contendo a resposta do sistema em todos os instantes do intervalo dos dados de identificação. Matematicamente, X e Y são:

$$Y = \begin{bmatrix} y(k) \\ y(k-1) \\ \vdots \\ y(k-nb) \end{bmatrix} \quad X = \begin{bmatrix} 1 & u(k) & u(k-1) & \dots & u(k-nb) \\ 1 & u(k-1) & u(k-2) & \dots & u(k-nb-1) \\ \vdots & \vdots & \vdots & & \vdots \\ 1 & u(nb) & & \dots & u(1) \end{bmatrix}$$

É válido lembrar que a integral dos coeficientes da resposta impulso fornecem a resposta a um degrau unitário do sistema. Para fins didáticos, a Figura A.1 mostra a representação da estrutura de modelos *FIR* em diagrama de blocos.




Figura A.1: Representação em diagrama de blocos da estrutura de modelos *FIR*.

De modo semelhante ao modelo *FIR*, podemos escrever as equações para a estrutura *ARX*,

$$y(k) + a_1 q^{-1} y(k) + a_2 q^{-2} y(k) + \dots + a_{na} q^{-na} y(k) = b_1 q^{-1} u(k) + b_2 q^{-2} u(k) + \dots + b_{nb} q^{-nb} u(k)$$

$$y(k) + a_1 y(k-1) + a_2 y(k-2) + \dots + a_{na} y(k-na) = b_1 u(k-1) + b_2 u(k-2) + \dots + b_{nb} u(k-nb)$$

$$y(k) = b_1 u(k-1) + b_2 u(k-2) + \dots + b_{nb} u(k-nb) - [a_1 y(k-1) + a_2 y(k-2) + \dots + a_{na} y(k-na)]$$

$$y(k) = \begin{bmatrix} u(k-1) & u(k-2) & \dots & u(k-nb) & -y(k-1) & -y(k-2) & \dots & -y(k-n_a) \end{bmatrix} \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_{nb} \\ a_1 \\ a_2 \\ \vdots \\ a_{na} \end{bmatrix}$$

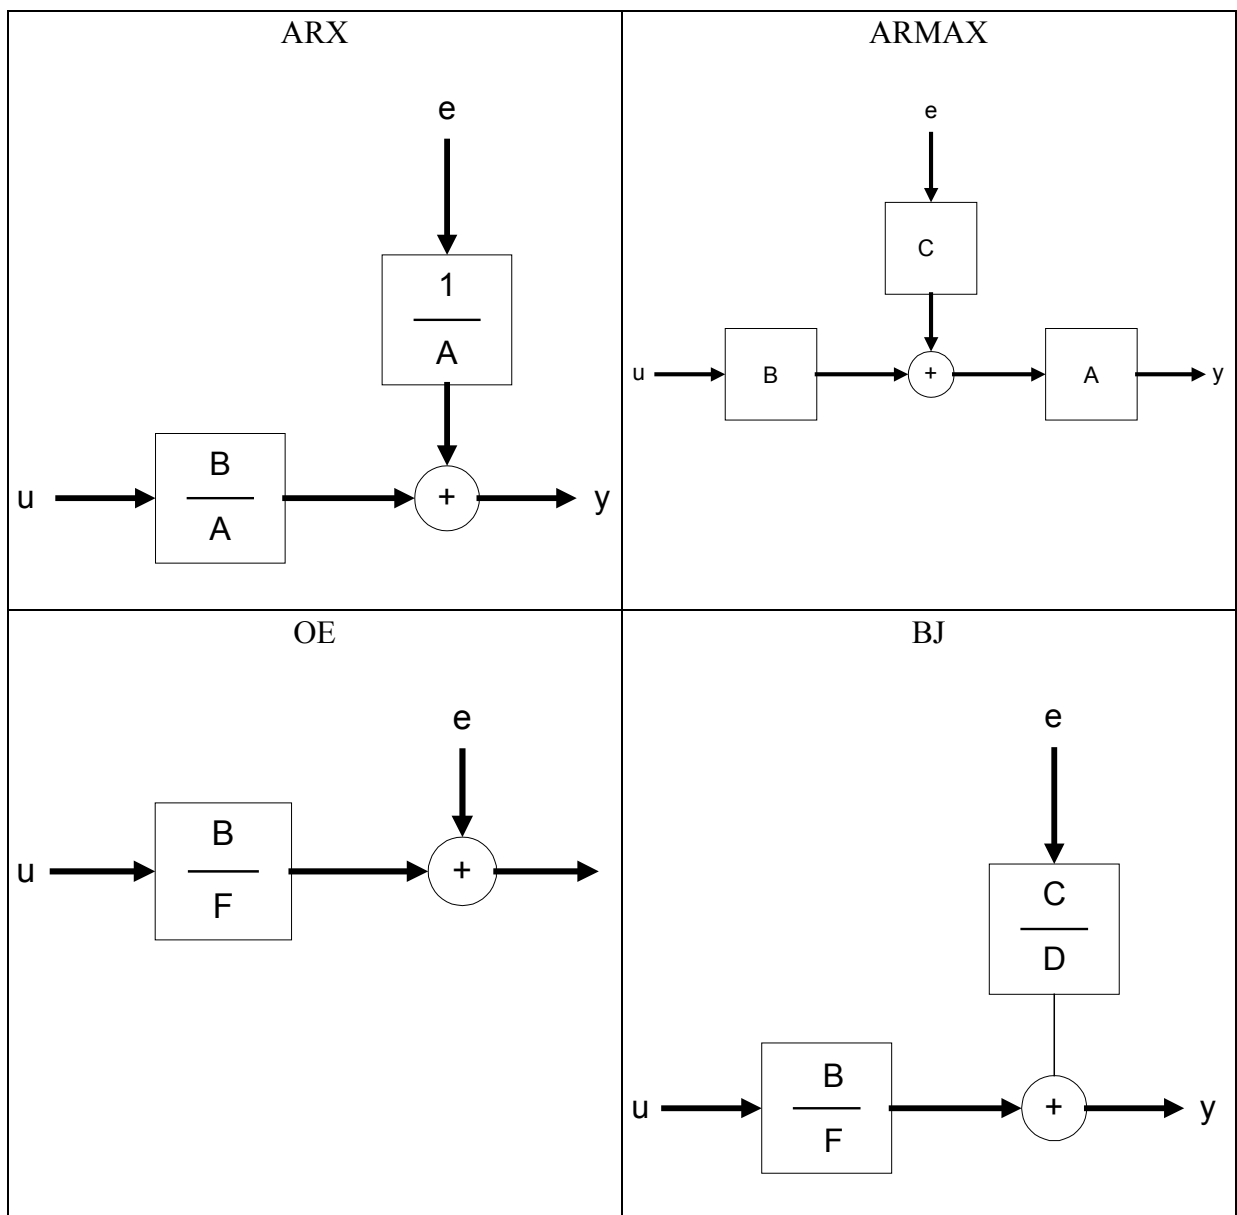
Utilizando a equação acima para N sucessivos intervalos de amostragem, obtém-se as matrizes X e Y da técnica dos mínimos quadrados.

$$X = \begin{bmatrix} u(k-1) & u(k-2) & \dots & u(k-nb) & -y(k-1) & -y(k-2) & \dots & -y(k-nb) \\ u(k-2) & u(k-3) & \dots & u(k-nb-1) & -y(k-2) & -y(k-3) & \dots & -y(k-nb-1) \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ u(k-N+nb) & u(k-N+nb-1) & \dots & u_1 & -y(k-N+na) & -y(k-N+na-1) & \dots & -y_1 \end{bmatrix}$$

$$Y = \begin{bmatrix} y(k) \\ y(k-1) \\ \vdots \\ y(k-nb) \end{bmatrix}$$

Similarmente às equações de estimação dos parâmetros dos modelos *FIR* e *ARX*, existem as equações para a determinação dos parâmetros das demais estruturas de modelos, tais como *OE*, *BJ* e *ARMAX*, por exemplo. A representação sob o formato de diagrama de blocos destas últimas estruturas citadas e o diagrama da estrutura *ARX* são mostrados na Tabela (A.2).

Tabela A.2: Diagrama de blocos das principais estruturas dos modelos discretos.



A.2. Métodos de Identificação em Espaço de Estados

Os principais algoritmos de identificação em espaço de estado presentes na literatura são: *SUBID*, *N4SID*, *MOESP* e *CVA*. Embora também sejam algoritmos de identificação discretos, ao invés de representarem o processo através de funções de transferência como fazem os algoritmos da seção A.1, os métodos de identificação em espaço de estado determinam as matrizes que representam o sistema no espaço de estados. Tal representação é mostrada abaixo:

$$\begin{aligned} \frac{dx}{dt} &= Ax + Bu \\ y &= Cx + Du \end{aligned} \quad (\text{A8})$$

em que a matriz A é a chamada matriz de estados, x são os estados, u são as entradas do sistema e y são as saídas do sistema.

Sem sombra de dúvidas, o principal algoritmo de identificação em espaço de estados é o algoritmo *SUBID* [OM96]. Este algoritmo aplica refinadas técnicas de álgebra linear para identificar as matrizes A , B , C e D (veja Equação (A8)) a partir dos dados de planta. Neste apêndice, detiver-se-á apenas em apresentar a versão determinística da identificação no subespaço de estado. Para maiores informações sobre a identificação estocástica e a combinação entre a identificação estocástica-determinística, consulte [OM96]. Desta forma, como o algoritmo é discreto, a Equação (A.9) pode ser escrita sob a forma:

$$\begin{aligned} x_{k+1}^d &= Ax_k^d + Bu_k \\ y_k &= Cx_k^d + Du_k \end{aligned} \quad (\text{A.9})$$

em que o índice k representa o instante de amostragem atual.

O algoritmo *SUBID* organiza os dados de planta selecionados para a identificação conforme a matriz:

$$U_{0|2i-1} \equiv \begin{pmatrix} u_0 & u_1 & u_2 & \dots & u_{j-1} \\ u_1 & u_2 & u_3 & \dots & u_j \\ \dots & \dots & \dots & \dots & \dots \\ u_{i-1} & u_i & u_{i+1} & \dots & u_{i+j-2} \\ u_i & u_{i+1} & u_{i+2} & \dots & u_{i+j-1} \\ u_{i+1} & u_{i+2} & u_{i+3} & \dots & u_{i+j} \\ \dots & \dots & \dots & \dots & \dots \\ u_{2i-1} & u_{2i} & u_{2i+1} & \dots & u_{2i+j-2} \end{pmatrix} \begin{matrix} \text{Passado} \\ \text{Futuro} \end{matrix} \quad (\text{A.10})$$

em que o índice i é um parâmetro definido pelo usuário e determina qual o número de linhas que a matriz $U_{0|2i-1}$ terá. Os dados são classificados em dados de “Passado”, para as linhas

acima da linha i , e de “Futuro” para as linhas abaixo da linha i . O índice j está relacionado à ordem do sistema, isto é, ao tamanho desejado para as matrizes A , B , C e D . Obviamente, assim como nos algoritmos apresentados na seção A.1 deste apêndice, quanto maior a ordem do sistema, maior é a quantidade de informações dos dados dos instantes de tempo antecessores ao instante de amostragem atual (subíndice 0 – primeiro elemento da matriz $U_{0|2i-1}$). Da mesma forma que os dados das variáveis manipuladas são ordenados, os dados das saídas seguem a mesma notação e representação. Esta representação dos dados de planta será útil mais adiante. No momento, é importante ressaltar que o sistema representado pela Equação (A.9) pode ser reescrito pela Equação (A.11):

$$\begin{aligned} Y_p &= \Gamma_i X_p^d + H_i^d U_p \\ Y_f &= \Gamma_i X_f^d + H_i^d U_f \\ X_f^d &= A^i X_p^d + \Delta_i^d U_p \end{aligned} \quad (\text{A.11})$$

em que Y_p é a submatriz superior da matriz $Y_{0|2i-1}$, Y_f é a submatriz inferior da matriz $Y_{0|2i-1}$, X_f^d é a matriz de estados, U_p é a submatriz superior da matriz $U_{0|2i-1}$, U_f é a submatriz inferior da matriz $U_{0|2i-1}$, e as matrizes Γ_i , H_i^d e Δ_i^d , são, respectivamente, a matriz de observabilidade, a matriz de controlabilidade e a matriz de complementos, definidas abaixo:

$$\Gamma_i \equiv \begin{pmatrix} C \\ CA \\ CA^2 \\ \dots \\ CA^{i-1} \end{pmatrix} \quad H_i^d \equiv \begin{pmatrix} D & 0 & 0 & \dots & 0 \\ CB & D & 0 & \dots & 0 \\ CAB & CB & D & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots \\ CA^{i-2}B & CA^{i-3}B & CA^{i-4}B & \dots & D \end{pmatrix} \quad \Delta_i^d \equiv \begin{pmatrix} A^{i-1}B & A^{i-2}B & \dots & AB & A \end{pmatrix}$$

De posse destas definições, sabe-se que:

$O_i \equiv Y_f /_{U_f} W_p$, isto é, a projeção oblíqua da matriz Y_f em U_f projetadas na matriz W_p , serve para determinar a ordem do sistema, através de sua decomposição em valores singulares. A matriz W_p é definida como sendo:

$$W_p \equiv \begin{pmatrix} U_p \\ Y_p \end{pmatrix} \quad (\text{A.12})$$

Esta decomposição pode ser expressa por:

$$W_1 O_i W_2 \equiv (U_1 \quad U_2) \begin{pmatrix} S_1 & 0 \\ 0 & 0 \end{pmatrix} \begin{pmatrix} V_1^T \\ V_2^T \end{pmatrix} = U_1 S_1 V_1^T \quad (\text{A.13})$$

Para a determinação das matrizes do modelo através do método *SUBID*, faz-se necessário definir a matriz a projeção O_{i-1} , dada por:

$$O_{i-1} \equiv Y_f^- /_{U_f^-} W_p^+ \quad (\text{A.14})$$

em que a matriz Y_f^- é a própria matriz Y_f com o deslocamento da linha i para uma unidade. Notação similar ocorre com U_f^- e W_p^+ . A matriz de observabilidade pode ser estimada através da Equação (A.15), apresentada a seguir.

$$\Gamma_i \equiv W_1^{-1} U_1 S_1^{1/2} \quad (\text{A.15})$$

O próximo passo do algoritmo é determinar as seqüência de estados X_i^d e X_{i+1}^d , através de:

$$X_f^d \equiv \Gamma_i^{pinv} O_i \quad (\text{A.16})$$

$$X_{i+1}^d = \Gamma_{i-1}^{pinv} O_{i-1} \quad (\text{A.17})$$

Resolvendo o sistema de equações abaixo, obtém-se as matrizes que compõem a representação do modelo em espaço de estado.

$$\begin{pmatrix} X_{i+1}^d \\ Y_{ii} \end{pmatrix} = \begin{pmatrix} A & B \\ C & D \end{pmatrix} \begin{pmatrix} X_i^d \\ U_{ii} \end{pmatrix} \quad (\text{A.18})$$

A.3. Método dos Momentos de Poisson

O método em questão, utiliza a definição de momentos para realizar a tarefa de identificação, somado ao emprego da distribuição de probabilidades de *Poisson*. Este tipo de distribuição é muito utilizada em problemas de estatística aplicados à engenharia de processos de manufatura, em que o tempo é um fator relevante, como por exemplo, a relação entre o número de peças com falhas e o tempo de fabricação das peças. A função de densidade de probabilidades de *Poisson* é representada pela Equação (A.19).

$$p_k(t_i) = (t_i)^k \cdot \frac{e^{(-\lambda \cdot t_i)}}{k!} \quad (\text{A.19})$$

em que t_i é o tempo no instante i de amostragem, λ é o parâmetro da distribuição de *Poisson*, responsável pelo formato da curva e o índice k refere-se a ordem da função de distribuição. O formato da distribuição de *Poisson* assemelha-se com a resposta a um impulso unitário de funções de transferência típicas, as quais descrevem os principais processos químicos e petroquímicos. Por esta razão, a distribuição de *Poisson* é amplamente usada na identificação destes sistemas, ao invés de outras distribuições. Para melhor ilustrar esta semelhança, a Figura A.2 compara uma curva de distribuição de *Poisson* e as respostas a impulso unitário de funções de transferência de primeira, segunda e terceira ordens.




Figura A.2: Comparação entre o formato da distribuição de probabilidades de Poisson (gráfico superior) e a resposta a um impulso unitário de funções de transferência de primeira, segunda e terceira ordens.

Para capturar ordens mais elevadas de forma satisfatória, pode-se alterar o parâmetro λ , tornando a distribuição mais ou menos amortecida. A construção do sistema de equações para a estimação de parâmetros do modelo através do método de *Poisson* é feita através das relações seguintes. O momento de ordem k é definido a partir da Equação (A.20).

$$M_K \{f(t)\} = \int_0^{t_0} f(\tau) \cdot p_K(t - \tau) \cdot d\tau \quad (\text{A.20})$$

A função $f(t)$, no caso do problema de identificação, pode ser a própria resposta da variável de interesse do modelo/planta, $y(t)$, ou a derivada de qualquer ordem de $y(t)$. A variável p_k é a função de distribuição de probabilidades, neste caso a distribuição de *Poisson*. O sub-índice, k , é relativo à ordem do momento. Aplicando-se à derivada de $y(t)$, e substituindo-a na expressão da distribuição de *Poisson*, obtém-se a Equação (A.21).

$$M_K \left\{ \frac{dy(t)}{dt} \right\} = \int_0^{t_0} \frac{(t_0 - t)^K}{k!} \cdot e^{-\lambda(t_0 - t)} \cdot \frac{dy(t)}{dt} \quad (\text{A.21})$$

Integrando por partes o lado direito da Equação (A.21), obtém-se:

$$\frac{(t_0 - t)^K}{k!} \cdot e^{-\lambda(t_0 - t)} \cdot y(t) \Big|_0^{t_0} - \int_0^{t_0} \left[-\frac{(t_0 - t)^{K-1}}{(k-1)!} \cdot e^{-\lambda(t_0 - t)} + \lambda \cdot \frac{(t_0 - t)^K}{k!} \cdot e^{-\lambda(t_0 - t)} \right] \cdot y(t) \cdot dt \quad (\text{A.22})$$

Implicando em:

$$M_K \left\{ \frac{dy(t)}{dt} \right\}_{t_0} = M_K \{ y^{(j=1)}(t) \}_{t_0} = y_{(k-1),0,j=0} - \lambda \cdot y_{k,0,j=0} - p_{k,0} \cdot y_{k=1,0,j=0} \quad (\text{A.23})$$

em que o subíndice da variável y , composto de três números, representa respectivamente: a ordem do momento, o tempo de amostragem em que se está calculando o momento e a ordem da derivada de y . Se $k = 1$, se está trabalhando com o primeiro valor do vetor y . Se $j = 1$, tem-se a derivada primeira e se $j = 0$, tem-se a própria função $y(t)$.

A técnica dos momentos de Poisson permite escrever o termo da derivada de y da equação diferencial como uma combinação linear dos próprios momentos de menor ordem. Por exemplo, em uma equação diferencial ordinária de segunda ordem, o momento de segunda ordem pode ser escrito como uma combinação linear dos momentos de ordem 0 e 1.

A título de exemplo, considerar-se-á um sistema SISO, de primeira ordem. A representação matemática deste sistema é dada pela equação (A.24):

$$a \cdot \frac{dy(t)}{dt} + y(t) = b \cdot u(t) \quad (\text{A.24})$$

Aplicando a definição de momento de *Poisson*, tem-se:

$$a \cdot M_K \left\{ \frac{dy(t)}{dt} \right\}_{t_0} + M_K \{ y(t) \}_{t_0} = b \cdot M_K \{ u(t) \}_{t_0} \quad (\text{A.25})$$

Prosseguindo, obtém-se:

$$a \cdot [y_{k-1,0,j=0} - \lambda \cdot y_{k,0,j=0} - p_{k,0} \cdot y_{k=1,0,j=0}] + [y_{k,0,j=0}] = b \cdot [u_{k,0,j=0}] \quad (\text{A.26})$$

ou

$$[y_{k-1,0,j=0} - \lambda \cdot y_{k,0,j=0} - p_{k,0} \cdot y_{k=1,0,j=0} \quad (-u_{k,0,j=0})] \cdot \begin{bmatrix} a \\ b \end{bmatrix} = -y_{k,0,j=0} \quad (\text{A.27})$$

Deve-se ressaltar que, deste momento em diante, montar-se-á um sistema de equações algébricas de modo a iniciar o processo de estimação de parâmetros. Neste caso, os

parâmetros do modelo a serem estimados são a e b . A construção do sistema de equações pode ser realizada de duas formas, colocadas em paralelo, na Tabela A.3.

Tabela A.3: Formas de construção do sistema de equações algébricas para estimação de parâmetros via método de Poisson.

| |
|--|
| Modo 1: Emprego dos momentos em um tempo fixo e com variação do número de ordens dos momentos. ($k=1,2$) |
| $\begin{bmatrix} y_{0,0,j=0} - \lambda \cdot y_{1,0,j=0} - p_{1,0} \cdot y_{1,0,j=0} & -u_{1,0,j=0} \\ y_{1,0,j=0} - \lambda \cdot y_{2,0,j=0} - p_{2,0} \cdot y_{2,0,j=0} & -u_{2,0,j=0} \end{bmatrix} \cdot \begin{bmatrix} a \\ b \end{bmatrix} = \begin{bmatrix} -y_{1,0,j=0} \\ -y_{2,0,j=0} \end{bmatrix}$ |
| Modo 2: Ordem fixa e emprego da definição dos momentos em tempos diferentes. ($k=1, t_0=t_1$ e t_2) |
| $\begin{bmatrix} y_{0,1,j=0} - \lambda \cdot y_{1,1,j=0} - p_{1,1} \cdot y_{1,0,j=0} & -u_{1,1,j=0} \\ y_{0,2,j=0} - \lambda \cdot y_{1,2,j=0} - p_{1,2} \cdot y_{1,0,j=0} & -u_{1,2,j=0} \end{bmatrix} \cdot \begin{bmatrix} a \\ b \end{bmatrix} = \begin{bmatrix} -y_{1,1,j=0} \\ -y_{1,2,j=0} \end{bmatrix}$ |

Resolvendo o sistema de equações através de mínimos quadrados (Equação (A.7)), obtém-se os parâmetros a e b . A matriz Y (veja Equação (A.7)) representa os valores da variável de interesse do sistema e X (veja Equação (A.7)) é a matriz de regressores, as quais assumem o seguinte formato, para N pontos experimentais, para o exemplo da Tabela A.3:

$$X = \begin{bmatrix} y_{0,1,j=0} - \lambda \cdot y_{1,1,j=0} - p_{1,1} \cdot y_{1,0,j=0} & -u_{1,1,j=0} \\ y_{0,2,j=0} - \lambda \cdot y_{1,2,j=0} - p_{1,2} \cdot y_{1,0,j=0} & -u_{1,2,j=0} \\ \cdot & \cdot \\ \cdot & \cdot \\ \cdot & \cdot \\ y_{0,N,j=0} - \lambda \cdot y_{1,N,j=0} - p_{1,N} \cdot y_{1,0,j=0} & -u_{1,N,j=0} \end{bmatrix} \quad Y = \begin{bmatrix} -y_{1,1,j=0} \\ -y_{1,2,j=0} \\ \cdot \\ \cdot \\ \cdot \\ -y_{1,N,j=0} \end{bmatrix}$$

Conforme a ordem do modelo a ser identificado aumenta, o formato da matriz X varia, resultado do uso de uma ordem superior dos momentos de *Poisson*. Para maiores detalhes de outros métodos de identificação contínua veja referência [UH42].

A.4 Modos de Operação de Plantas Industriais

O modo em que são coletados os dados para a identificação de modelos influencia nos resultados obtidos após a identificação dos modelos. Em termos práticos, existem dois modos de operação de plantas industriais: modo malha aberta e modo malha fechada. Cada modo produz dados com características distintas, devido à presença do controlador (malha fechada). Estes modos estão sucintamente descritos nas próximas subseções.

A.4.1 Modo Malha Aberta

Na grande maioria das plantas industriais, o processo de identificação é conduzido no modo chamado “malha aberta”. Neste modo de operação, os controladores (*PID*'s, *CPM*'s) trabalham em modo manual, caso existam no sistema. Em outras palavras, os controladores estão desabilitados. As variáveis manipuladas são variadas, segundo algum projeto de perturbações ou até mesmo de forma manual. Por isso, o teste de identificação pode conduzir o sistema para um ponto de operação indesejado. Durante os testes de identificação, o sistema, $G(q)$, está sujeito a fatores estocásticos $e(t)$, além das excitações determinísticas, $u(t)$. A Figura A.3 mostra uma representação esquemática do sistema durante o modo de operação em malha aberta.




Figura A.3: Representação do sistema em malha aberta.

A grande vantagem da identificação em malha aberta são, de fato, a facilidade de implementação das perturbações e do acompanhamento da resposta do sistema $y(t)$, no sentido de se conferirem as respostas com o conhecimento prévio do processo, especialmente se as perturbações são de graus não simultâneos. Por outro lado, a desvantagem da identificação em malha aberta é justamente a necessidade de remover o controlador do processo, podendo-se aumentar consideravelmente a variabilidade das variáveis de interesse para o controle da unidade.

Assumindo-se que $e(t)$ é uma variável randômica (erros de medida, por exemplo) ou representa distúrbios não medidos, pode-se afirmar que os sinais $e(t)$ e $u(t)$ não são correlacionados. Esta característica é, em termos de característica dos sinais presentes, a que difere das características dos sinais em malha fechada. Para ilustrar a utilização dos algoritmos de identificação com dados em malha aberta, considerou-se a identificação de modelos de uma planta industrial de polimerização [Res03]. Uma das variáveis manipuladas

do processo é a vazão de catalisador, e as controladas são a razão entre a massa de hidrogênio e etileno dentro do reator a vazão de alimentação de eteno.

Os modelos foram identificados empregando-se a estrutura *BJ* e *SUBID* (métodos discretos) e o método de *Poisson* (método contínuo), todos de primeira ordem. Após a identificação, os modelos foram confrontados, através de simulação, com os dados experimentais de planta, além da comparação entre os pólos e zeros dos modelos identificados. O primeiro exemplo trata do modelo entre a vazão de catalisador e a razão entre H_2/C_2 . A Figura A.4 apresenta o confronto entre os modelos identificados e simulados e os dados de planta.




Figura A.4: Confronto entre os dados de planta e modelos identificados entre a vazão de catalisador e a razão entre H_2/C_2 . (A, ponto) Dados de planta, (B, linha tracejada) *Box-Jenkins*, (C, linha contínua) Subespaço de Estado, (D, linha traço-ponto) *Poisson*.

De acordo com a Figura A.4, para a mesma ordem do modelo, selecionada para todos os métodos de identificação, o modelo obtido por *BJ* não reproduziu os dados de planta. Os modelos obtidos por *Poisson* e *SUBID* são próximos, no entanto, surgiu um zero inexistente neste sistema, como será apresentado na Tabela A.4. A Figura A.4 ainda permite afirmar que altos níveis de ruído no dados da variável manipulada corrompem os resultados do modelo discreto. Este efeito não é tão relevante para a identificação contínua, devido a implementação da cadeia de filtros. Um segundo exemplo, do mesmo sistema, envolve as variáveis vazão de catalisador e vazão de alimentação de etileno. A Figura A.5 apresenta os resultados do confronto entre os dados de planta e dos modelos identificados. É importante salientar que os dados das figuras A.4 e A.5 estão em quantidade insuficiente para se dizer que os modelos gerados são consistentes. Apenas quer se mostrar que os algoritmos contínuos tendem a fornecer modelos mais coerentes na presença de ruídos nas entradas quando comparados aos modelos gerados por algoritmos discretos.




Figura A.5: Confronto entre os dados e planta e modelos identificados entre a vazão de catalisador e a vazão de etileno. Na figura, Dados de planta (ponto), *Box-Jenkins* (linha tracejada), Subespaço de Estado (linha contínua), *Poisson* (linha traço-ponto).

Ao se observar a Figura A.5, claramente conclui-se que dados com menores amplitudes ruído de medida e de processo fazem com que tanto os métodos discretos quanto os métodos contínuos apresentem resultados semelhantes. Este fato pode ser visto através da comparação entre pólos e zeros, resumizada na Tabela A.4.

Tabela A.4: Comparação entre pólos e zeros dos modelos identificados dos exemplos 1 e 2.

| Modelo | Exemplo 1 | | Exemplo 2 | |
|---------------------|-----------|---------|-----------|-------|
| | Pólos | Zeros | Pólos | Zeros |
| Box – Jenkins | -0,7790 | - | -0,0037 | - |
| Subespaço de Estado | -0,0041 | -2,6995 | -0,0040 | - |
| Poisson | -0,0136 | - | -0,0038 | - |

A. 4.2 Modo Malha Fechada

Recentemente, as indústrias de transformação química vêm demonstrando um grande apelo à identificação em malha fechada. Neste modo de operação, o controlador está ativo, de modo a

reduzir a variabilidade do processo. O controlador, $C(q)$, atua para que $y(t)$ fique próximo à $r(t)$ (setpoint ou trajetória de referência). Naturalmente, da mesma forma que ocorre em malha aberta, em malha fechada o sistema está sujeito a ruídos de medida e de processo e distúrbios na carga, representado pelo sinal $v(t)$. A Figura A.6 apresenta de forma esquemática um sistema em malha fechada.

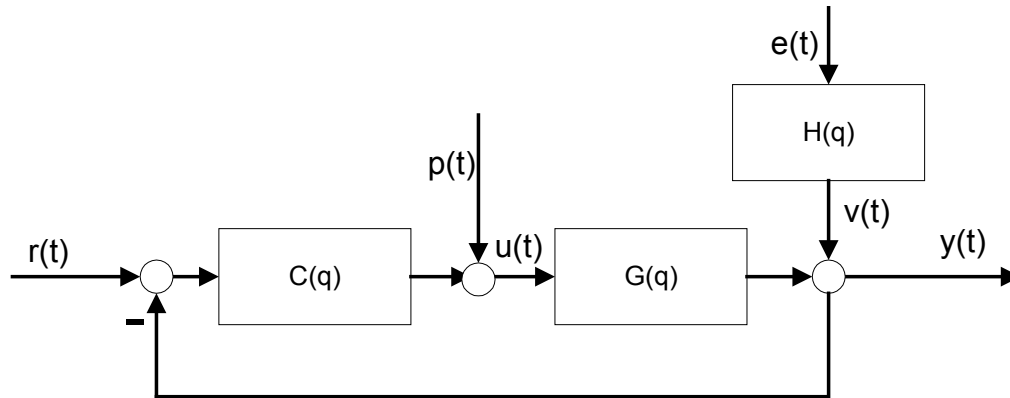


Figura A.6: Representação do sistema em malha fechada.

Note-se que na Figura A.6, a ação de controle $u(t)$, é fruto da soma da ação calculada pelo controlador e do sinal $p(t)$, ou ação de controle de referência – ubias. Para se realizar a identificação em malha fechada, as perturbações podem ser feitas tanto em $r(t)$ quanto em $p(t)$. Deve-se observar que a presença do controlador produz uma correlação entre $u(t)$ e $e(t)$, fato que causa a incorreta determinação do modelo da planta, $G(q)$, caso o modelo que caracteriza o distúrbio, $H(q)$, seja mal determinado. Apenas para se dar uma idéia dos métodos de identificação em malha fechada, serão discutidos sucintamente as técnicas mais conhecidas na literatura para este propósito.

A.4.2.1 Método Direto

A identificação direta em malha fechada toma os dados em malha fechada das variáveis manipulada (u) e controlada (y) ignorando a malha *feedback*, tratando o problema como se fosse em malha aberta [EM00]. Os dados são inseridos em algoritmos de identificação discreta, através de métodos de erros de predição, e é obtido o modelo da planta. A vantagem deste método é a simplicidade e dispensa o conhecimento da equação do controlador, a qual em muitos casos, é de difícil obtenção devido à presença de elementos *anti-windup*'s, saturação das variáveis controladas, entre outros fatores.

A.4.2.2 Métodos indiretos

A identificação indireta em malha fechada procura empregar a equação do controlador na obtenção do modelo da planta. Dependendo das variáveis envolvidas, a identificação indireta pode ser do tipo série ou paralelo. É importante ressaltar que a geração dos modelos através dos vetores de dados é realizada através de estruturas de identificação discretas ou contínuas descritas anteriormente.

Identificação em Série

O modelo da planta é obtido em duas etapas, dispostas em série. Na primeira identifica-se a função sensibilidade $S(q)$. Para tanto, são usados os dados do distúrbio programado $p(t)$ e a ação do controlador $u(t)-p(t)=uc(t)$ com o objetivo de identificar a função $-T(q)$. Feito isto, obtém-se $S(q)$ ($S(q) = 1 + T(q)$). Na Segunda etapa, de posse da função sensibilidade, pode-se seguir dois caminhos: filtrar o vetor de perturbações externas na variável manipulada $p(t)$ com a função $S(q)$, gerando a variável df ou filtrar o vetor da variável controlada ($y(t)$) com a inversa da função sensibilidade ($S^{-1}(q)$), gerando a variável yf . No primeiro caso, o modelo da planta é obtido a partir da relação entre os vetores df e y e no segundo, a partir da relação entre d e yf . [EM00], [HS97]

Identificação em Paralelo

A identificação em malha fechada pelo método indireto em paralelo, identifica de forma independente as funções de transferências $S(q)$ e $G(q)S(q)$. O modelo da planta, $G(q)$, é obtido pela razão entre $G(q)S(q)$ e $S(q)$. A função $S(q)$ é obtida de modo similar ao método de identificação em malha fechada em série. Para a identificação da função $G(q)S(q)$ são utilizados os vetores $p(t)$ (distúrbio programado na variável manipulada) e $y(t)$ (variável controlada) [EM00].

Referências Bibliográficas

- [AK92] Andersen H. W, Kümel M., “Dynamics and Identification of a binary Distillation Column”, *Chemical Engineering Science*, **44**, vol.11, 2571-2581, 1989.
- [BR03] Bindlish Rahul, Model order selection for process identification applied to an industrial ethylene furnace, *Journal of Process Control* **13**, 569-577, 2003.
- [BR66] E.H Bristol, “On a new measure of interactions for multivariable process control”, *IEEE Trans. on Aut. Control*. AC-11, 133-134, 1966.
- [EM00] Esmaili A., MacGegor J. F., “Direct and two-step methods for closed-loop identification: a comparison of asymptotic and finite data set performance”, *Journal of Process Control* **10**, 525-537, 2000.
- [HS97] Huang B., Shah S. L., “Closed-loop identification: a two step approach”, *Journal of Process Control* **7**, 425-438, 1997.
- [IDENT] L. Ljung, “System Identification Toolbox”, The Mathworks, Inc., 1992.
- [LJ99] L. Ljung, “System Identification: Theory for the User ”, 2nd Edition, Prentice Hall, Englewood Cliffs, N. J, 1999.
- [Luy92] W.L Luyben, “Practical Distillation Control”, Van Nostrand Reinhold, New York ,1992.
- [OM96] Overschee V. Moor B., “Subspace Identification for Linear Systems”, Kluwer Publishers, 1996.
- [OPT] Coleman, T., Branch M. A., Grace A., “Optimization Toolbox – for use with MATLAB”, The Mathworks, Inc.,v. 2, 1999.
- [Res03] “Identificação de Modelos de uma Planta de Polietileno”, Dissertação de Mestrado, Universidade Federal do Rio Grande do Sul, Brasil, 2003.
- [SIGPRO] J. Little, L. Shure, “Signal Processing Toolbox – for use with MATLAB”, The Mathworks, Inc.,v. 4.2, 1999.
- [TE00] Trierweiler, J.O., Engell, S., A Case Study for Control Structure Selection: Air Separation Plant. *Journal of Process Control* **10**, 237-243, 2000.

- [TRI97] Trierweiler, J.O., A Systematic Approach to Control Structure Design, Tese de Doutorado, Universidade de Dortmund, 1997.
- [UH42] Unbehauen, Heinz, Identification of Continuous systems, North – Holland systems and control series, v.10, Holanda, 1942.
- [WW99] Wang W. “A Robust Frequency Response Design Procedure for Multivariable Control Systems”, Tese de Doutorado, Universidade de Dortmund, 1999.
- [Yu98] Yu C. C, “Autotuning of PID Controllers: relay feedback approach”, Springer, 1998.
- [Zhu02] Zhu Y., Butoyi F., “Case studies on closed-loop identification for MPC”, *Control Engineering Practice*, **10**, pp. 403-417, 2002.