

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

**MANUTENÇÃO DE MODELOS PARA CONTROLADORES
PREDITIVOS INDUSTRIAIS**

DISSERTAÇÃO DE MESTRADO

Denilson de Oliveira Francisco

Porto Alegre

2017

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

MANUTENÇÃO DE MODELOS PARA CONTROLADORES PREDITIVOS INDUSTRIAIS

Denilson de Oliveira Francisco

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

Área de concentração:

Pesquisa e Desenvolvimento de Processos

Linha de Pesquisa:

Projeto, Simulação, Modelagem, Controle e Otimização de Processos.

Orientador:

Prof. Dr. Jorge Otávio Trierweiler

Co-orientadora:

Prof.^a Dr.^a Viviane Rodrigues Botelho

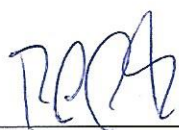
Porto Alegre

2017

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 *Manutenção de Modelos para Controladores Preditivos Industriais*, elaborada por Denilson de Oliveira Francisco, como requisito parcial para obtenção do Grau de Mestre em Engenharia.

Comissão Examinadora:



Prof. Dr. Pedro Rafael Bolognese Fernandes (DEQUI – UFRGS)



Prof. Dr. João Manoel Gomes da Silva Júnior (PPGEE – UFRGS)



Dr. Antônio Carlos Zanin (PETROBRAS)

Resumo

O escopo desta dissertação é o desenvolvimento de uma metodologia para identificar os modelos de canais da matriz dinâmica que estejam degradando o desempenho de controladores preditivos, ou MPC (*Model Predictive Control*), baseado nas técnicas de auditoria e diagnóstico deste tipo de controlador propostas por BOTELHO et al. (2015) e BOTELHO; TRIERWEILER; FARENZENA (2016) e CLARO (2016). A metodologia desenvolvida contempla dois métodos distintos. O primeiro, chamado método direto compensado, tem como base o método direto de identificação em malha fechada (LJUNG, 1987) e compensa cada saída medida do processo de modo a se reter apenas a contribuição do canal que se deseja identificar. O segundo, chamado método do erro nominal, utiliza a definição de saída nominal do processo, proposta por BOTELHO et al. (2015), como métrica para se quantificar o quão próximo o modelo está do comportamento da planta através da minimização do erro nominal. Os métodos foram aplicados ao sistema de quatro tanques cilíndricos (JOHANSSON, 2000) para dois cenários distintos, sendo o primeiro um sistema 2x2 em fase não mínima contendo um MPC trabalhando com *setpoint* e o segundo um sistema 4x4 em fase mínima com o MPC atuando por faixas. Para o sistema 2x2, se avaliou a influência da localização do canal discrepante (dentro ou fora da diagonal principal da matriz dinâmica de transferência) na eficácia dos métodos. Para o sistema 4x4, o estudo foi voltado para a eficácia dos métodos frente a controladores que atuam dentro de limites para as variáveis. Os modelos identificados foram comparados pela capacidade de identificar um modelo que capturasse o zero de transmissão da planta e o RGA dinâmico, para o sistema 2x2, e pelas respostas degrau e diagrama de Bode para o sistema 4x4. O método direto compensado resultou em baixo erro relativo no valor do zero para a discrepância na diagonal principal da matriz dinâmica e alto valor quando a discrepância se encontrava fora da diagonal principal. O método do erro nominal, por sua vez, foi capaz de identificar um modelo cujo zero de transmissão possuía baixo erro relativo frente ao zero da planta em ambos os cenários. No cenário do controlador atuando por faixas, os métodos propostos obtiveram melhores estimativas dos modelos quando comparados com o método concorrente, uma vez que apresentou alto percentual de aderência das saídas simuladas com as saídas medidas. Em todos os cenários estudados, o método do erro nominal se mostrou capaz de identificar um modelo mais robusto, pois este apresentou RGA dinâmico compatível com a planta em todo o range de frequências analisado.

Palavras-chave: controladores preditivos, identificação de sistemas, canais da matriz dinâmica de transferência, auditoria e diagnóstico de desempenho

Abstract

The objective of this dissertation is to develop a method to identify the model for the channel of the dynamic matrix that are affecting the performance of model predictive controllers (MPC), based on the assessment and diagnosis techniques for this type of controller proposed by BOTELHO et al. (2015) e BOTELHO; TRIERWEILER; FARENZENA (2016) and CLARO (2016). The proposed methodology includes two different methods. The first, called the compensated direct method, is based on the closed-loop direct identification method (LJUNG, 1987) and compensates each process measured output in order to retain only the contribution of the channel being identified. The second, called nominal error method, uses the definition of the process nominal output, proposed by BOTELHO et al. (2015), as a metric to quantify how close the model is to the actual plant behavior by minimizing the nominal error. The proposed methods were applied to the quadruple-tank system (JOHANSSON, 2000) for two distinct scenarios, the first being a nonminimum-phase 2x2 system containing a MPC working with setpoint and the second a minimum-phase 4x4 system with the MPC working by ranges. For the 2x2 system, the influence of the model mismatch location (inside or outside the main diagonal of the dynamic transfer matrix) on the effectiveness of the methods was evaluated. For the 4x4 system, the study was focused on the effectiveness of the methods with controllers that operate within limits for the variables. The identified models were compared by the capability of identifying a model with accurate plant transmission zero and dynamic RGA, for the 2x2 system, and by the step responses and Bode diagram for the 4x4 system. The compensated direct method resulted in low relative error in the value of the transmission zero for the model mismatch located in the main diagonal of the dynamic matrix and high relative error when the mismatch was outside the main diagonal. On the other hand, the nominal error method was able to identify a model whose transmission zero had low relative error against the plant zero in both scenarios. In the scenario of a controller working by range, the proposed methods obtained better estimates of the models when compared to the concurrent method, since it presented a high percentage of adherence of the simulated outputs with the measured outputs. In all the studied scenarios, the nominal error method was able to identify a more robust model, since it presented dynamic RGA compatible with the plant in the entire range of analyzed frequencies.

Keywords: model predictive controller, system identification, transfer matrix channels, performance assessment and diagnosis

Agradecimentos

Primeiramente e acima de tudo, quero agradecer aqueles que sempre me encorajaram a estudar e que me possibilitaram ingressar e finalizar este mestrado. Este trabalho é em sua totalidade dedicado a vocês: meu pai, Tarcísio, minha mãe, Cleusa, e meu irmão, Fernando.

Gostaria de agradecer toda a ajuda, ensinamentos e incentivos que recebi de meu orientador, Jorge Otávio Trierweiler, e de minha co-orientadora, Viviane Rodrigues Botelho. Também agradeço a Érica Claro, que me ajudou com parte da metodologia que aqui emprego.

Em suma, agradeço também a todos aqueles que de alguma forma contribuíram com este trabalho.

SUMÁRIO

Capítulo 1 – Introdução	1
1.1 Motivação.....	5
1.2 Objetivos do trabalho.....	8
1.3 Estrutura da dissertação	8
Capítulo 2 – Revisão Bibliográfica	9
2.1 Métodos de Identificação em Malha Fechada.....	9
2.1.1 Identificação em Malha Fechada: Método Direto.....	13
2.1.2 Identificação em Malha Fechada: Método Indireto	14
2.1.3 Identificação em Malha Fechada: Two-stage Method	15
Capítulo 3 – Fundamentos: Metodologia para Determinação dos Canais com Erro de Modelo 17	17
3.1 Auditoria e Diagnóstico de MPCs	17
3.2 Localização dos Canais com Discrepância Modelo-Planta.....	24
Capítulo 4 – Metodologia	29
4.1 Método Direto Compensado de Identificação em Malha Fechada	29
4.2 Método do erro nominal.....	32
4.3 Método Sequencial de Identificação em Malha Fechada.....	34
Capítulo 5 – Estudo de Caso	37
5.1 Considerações gerais.....	37
5.2 Descrição do sistema de quatro tanques.....	39
5.2.1 Configuração 1: Modelo 2x2 por setpoint.....	40
5.2.2 Configuração 2: Modelo 4x4 por faixas e camada RTO	45
5.3 Resultados	49
5.3.1 Sistema 2x2: discrepância na diagonal principal da matriz de transferência.....	49
5.3.2 Sistema 2x2: discrepância fora da diagonal principal da matriz de transferência	61
5.3.3 Sistema 4x4 por faixas	72
Capítulo 6 – Conclusões e Trabalhos Futuros.....	83
6.1 Principais conclusões.....	83
6.2 Sugestões para trabalhos futuros	86
Referências	89
Apêndice A – Método do Erro de Predição.....	93

LISTA DE FIGURAS

Figura 2.1: Sistema genérico em malha fechada	10
Figura 2.2: Diagrama de blocos para um sistema com retroalimentação de um grau de liberdade.....	12
Figura 3.1: Fluxograma do passo-a-passo da etapa de auditoria de controladores preditivos	21
Figura 3.2: Fluxograma do passo-a-passo da etapa de diagnóstico de controladores preditivos	24
Figura 3.3: Fluxograma do passo-a-passo da etapa de diagnóstico dos canais mais discrepantes do modelo utilizado no controlador	28
Figura 4.1: Diagrama esquemático do processo de compensação do sinal de saída	31
Figura 4.2: Fluxograma do passo-a-passo da etapa de identificação de um novo modelo para controladores preditivos	34
Figura 5.1: Diagrama esquemático do sistema de quatro tanques cilíndricos (Adaptado de JOHANSSON (2000))	39
Figura 5.2: Respostas degrau dos modelos nominal e da planta para o Cenário 1	42
Figura 5.3: Respostas degrau dos modelos nominal e da planta para o Cenário 2	43
Figura 5.4: Distúrbios não-medidos inseridos nas saídas do processo.....	43
Figura 5.5: Respostas degrau dos modelos nominal e da planta para o sistema de 4 tanques por faixas	47
Figura 5.6: Distúrbios não-medidos inseridos nas saídas h_2 e h_3 do processo	47
Figura 5.7: Sinais das variáveis controladas e manipuladas para o cenário 1 do sistema 2x2	49
Figura 5.8: Auditoria de erros de modelagem para o cenário 1 do sistema 2x2	50
Figura 5.9: Diagnóstico da fonte dos erros de modelagem para o cenário 1 do sistema 2x2	51
Figura 5.10: Localização da MV mais relacionada à discrepância de modelo para o cenário 1 do sistema 2x2 para (a) a variável h_1 (b) a variável h_2	52
Figura 5.11: Resposta degrau dos modelos identificados pelo método direto compensado para o cenário 1 do sistema 2x2.....	53
Figura 5.12: Resposta degrau dos modelos identificados pelo MEN para o cenário 1 do sistema 2x2	55
Figura 5.13: Resposta degrau dos modelos identificados pelo método dos dois estágios para o cenário 1 do sistema 2x2.....	56
Figura 5.14: Elemento dominante λ_{ij} do RGA dinâmico do modelos identificados e da planta para o cenário 1 do sistema 2x2	59
Figura 5.15: Entradas e saída da malha fechada com os modelos identificados para o cenário 1 do sistema 2x2 para um (a) ajuste brando do controlador (b) ajuste agressivo do controlador	60
Figura 5.16: Sinais das variáveis controladas e manipuladas para o cenário 2 do sistema 2x2	61
Figura 5.17: Auditoria de erros de modelagem para o cenário 2 do sistema 2x2	62
Figura 5.18: Diagnóstico da fonte dos erros de modelagem para o cenário 2 do sistema 2x2	63
Figura 5.19: Localização da MV mais relacionada à discrepância de modelo para o cenário 2 do sistema 2x2 para (a) a variável h_1 (b) a variável h_2	64
Figura 5.20: Resposta degrau dos modelos identificados pelo método direto compensado para o cenário 2 do sistema 2x2.....	65

Figura 5.21: Resposta degrau dos modelos identificados pelo MEN para o cenário 2 do sistema 2x2	66
Figura 5.22: Resposta degrau dos modelos identificados pelo método dos dois estágios para o cenário 2 do sistema 2x2.....	68
Figura 5.23: Elemento dominante λ_{ij} do RGA dinâmico do modelos identificados e da planta para o cenário 2 do sistema 2x2	70
Figura 5.24: Entradas e saída da malha fechada com os modelos identificados para o cenário 2 do sistema 2x2 para um (a) ajuste brando do controlador (b) ajuste agressivo do controlador	71
Figura 5.25: Sinais das variáveis controladas para o sistema 4x4 por faixas	72
Figura 5.26: Sinais das variáveis manipuladas e <i>target</i> para o sistema 4x4 por faixas	73
Figura 5.27: Auditoria e diagnóstico por CV para o sistema 4x4 por faixas	73
Figura 5.28: Diagnóstico da fonte dos erros de modelagem para o sistema 4x4 por faixas	75
Figura 5.29: Localização da MV mais relacionada à discrepância de modelo para o sistema 4x4 por faixas para (a) a variável h_2 (b) a variável h_3 (c) a variável h_4	76
Figura 5.30: Resposta degrau dos modelos identificados pelo método direto compensado para o sistema 4x4 por faixas	78
Figura 5.31: Resposta degrau dos modelos identificados pelo método sequencial para o sistema 4x4 por faixas	79
Figura 5.32: Respostas degrau dos modelos da planta e identificados pelo método direto para o sistema 4x4 por faixas	80
Figura 5.33: Diagrama de Bode Magnitude (Db) <i>versus</i> Frequência [rad/s] para os modelos identificados e da planta para o sistema 4x4 por faixas	80
Figura 5.34: Saídas da malha fechada com os modelos identificados para o sistema 4x4 por faixas	81
Figura 5.35: Entradas da malha fechada com os modelos identificados para o sistema 4x4 por faixas	81

LISTA DE TABELAS

Tabela 2.1: Requisitos para os métodos de identificação em malha fechada.....	11
Tabela 5.1: Parâmetros originais do sistema de quatro tanques cilíndricos.....	40
Tabela 5.2: Parâmetros de ajuste do MPC.....	41
Tabela 5.3: Canais discrepantes no modelo utilizado no controlador	42
Tabela 5.4: Percurso de simulação do sistema de quatro tanques	44
Tabela 5.5: Divisão dos dados para calibração e validação	44
Tabela 5.6: Variáveis do controlador e ponto de operação para linearização do sistema de 4 tanques por faixas	45
Tabela 5.7: Parâmetros de sintonia do controlador e do otimizador para o sistema de 4 tanques por faixas	45
Tabela 5.8: Discrepância inseridas no modelo da planta para o sistema de 4 tanques por faixas.....	46
Tabela 5.9: Percurso de simulação do sistema de 4 tanques por faixas	48
Tabela 5.10: Divisão dos dados para calibração e validação para o sistema de 4 tanques por faixas	48
Tabela 5.11: Resultados do teste F de Levene para igualdade de variâncias para o cenário 1 do sistema 2x2	50
Tabela 5.12: Indicadores <i>MDI</i> do diagnóstico por canal para o cenário 1 do sistema 2x2	51
Tabela 5.13: Ordem e valores NRMSE dos modelos estimados pelo método direto compensado para o cenário 1 do sistema 2x2	52
Tabela 5.14: Ordem e valores NRMSE da redução de ordem os modelos estimados pelo método direto compensado para o cenário 1 do sistema 2x2	53
Tabela 5.15: Ordem e valores RMSE entre a resposta degrau dos modelos estimados pelo método do erro nominal e da planta para o cenário 1 do sistema 2x2.....	54
Tabela 5.16: Ordem e valores NRMSE das funções de sensibilidade estimados pelo método indireto de dois estágios para o cenário 1 do sistema 2x2	55
Tabela 5.17: Ordem e valores NRMSE dos modelos da planta estimados pelo método indireto de dois estágios para o cenário 1 do sistema 2x2	56
Tabela 5.18: Ordem e valores NRMSE da redução de ordem do modelo da planta estimado pelo método indireto de dois estágios para o cenário 1 do sistema 2x2	57
Tabela 5.19: Zero de transmissão e suas direções de saída e entrada para os modelos identificados para o cenário 1 do sistema 2x2	57
Tabela 5.20: Resultados do teste F de Levene para igualdade de variâncias para o cenário 2 do sistema 2x2.....	62
Tabela 5.21: Ordem e valores NRMSE dos modelos estimados pelo método direto compensado para o cenário 2 do sistema 2x2	64
Tabela 5.22: Ordem e valores NRMSE da redução de ordem os modelos estimados pelo método direto compensado para o cenário 2 do sistema 2x2	65
Tabela 5.23: Ordem e valores RMSE entre a resposta degrau dos modelos estimados pelo método do erro nominal e da planta para o cenário 2 do sistema 2x2.....	66
Tabela 5.24: Ordem e valores NRMSE das funções de sensibilidade estimados pelo método indireto de dois estágios para o cenário 2 do sistema 2x2	67
Tabela 5.25: Ordem e valores NRMSE dos modelos da planta estimados pelo método indireto de dois estágios para o cenário 2 do sistema 2x2	67
Tabela 5.26: Ordem e valores NRMSE da redução de ordem do modelo da planta estimado pelo método indireto de dois estágios para o cenário 2 do sistema 2x2	68
Tabela 5.27: Zero de transmissão e suas direções de saída e entrada para os modelos identificados para o cenário 2 do sistema 2x2	69

Tabela 5.28: Resultados do teste F de Levene para igualdade de variâncias para o sistema de quatro tanques por faixas.....	74
Tabela 5.29: Indicador <i>MDI</i> para o sistema de quatro tanques por faixas.....	75
Tabela 5.30: Ordem e valores NRMSE dos modelos estimados pelo método direto compensado para o sistema 4x4 por faixas	76
Tabela 5.31: Ordem e valores NRMSE da redução de ordem os modelos estimados pelo método direto compensado para o sistema 4x4 por faixas.....	77
Tabela 5.32: RMSE entre a resposta degrau dos modelos estimados pelo método sequencial e da planta para o sistema 4x4 por faixas.....	78
Tabela 5.33: Ordem e valores NRMSE dos modelos da planta estimados pelo método direto completo para o sistema 4x4 por faixas	79

NOTAÇÃO E SIMBOLOGIA

ARX	AutoRegressive Exogenous
ARMAX	AutoRegressive Moving Average eXogenous
BJ	Box-Jenkins
CV	Controlled Variable – Variável Controlada
DV	Disturbance Variable – Distúrbio Medido
MPC	Model Predictive Control – Controle Preditivo baseado em modelo
MV	Manipulated Variable – Variável Manipulada
MPM	Model-Plant Mismatch – Discrepância Modelo-Planta
MIMO	Multiple Input Multiple Output – Múltiplas Entradas Múltiplas Saídas
MDC	Método Direto Compensado
MEN	Método do Erro Nominal
MS	Método Sequencial
OE	Output Error
PID	Proporcional- Integral-Derivativo
RTO	<i>Real Time Optimization</i> – Otimização em Tempo Real
SISO	<i>Single Input Single Output</i> – Única Entrada Única Saída
UD	Unmeasured Disturbance – Distúrbio não Medido
A, B, C, D, F	Polinômios das estruturas <i>black-blox</i>
C	Modelo linear do controlador
c_z	Coefficiente de correlação da distribuição Z
CI	Valor absoluto do intervalo de confiança para o coeficiente de correlação
$c_{\hat{y}_{pf}, e_N}$	Estimativa do coeficiente de correlação cruzada entre \hat{y}_{pf} e e_N
cov	Covariância
$dskn$	Derivada da distribuição de assimetria
$dkts$	Derivada da distribuição de curtose

e	Sinal do ruído branco
e_N	Erro nominal
$e_{N\,diag}$	Erro nominal diagonal
F_N	Função objetivo da minimização do erro nominal
$F_{N\,diag}$	Função objetivo da minimização do erro nominal diagonal
\check{F}_{ex}	Sinal da variável externa descontado do valor do instante inicial
G_0	Parte determinística da planta real
G	Parte determinística do modelo da planta parametrizado
G^C	Parte determinística do modelo parametrizado da malha fechada
G_0^C	Parte determinística do modelo da malha fechada
\hat{G}_K^C	Modelo estimado da malha fechada
\hat{G}_K	Modelo estimado da malha aberta
$G_{i,k}$	Parte determinística do modelo do canal mais discrepante de uma saída
$H_{i,k}$	Parte estocástica do modelo do canal mais discrepante de uma saída
H_0	Hipótese nula
H_A	Hipótese alternativa
H_1	Parte estocástica da função de sensibilidade parametrizada
H_*	Parte estocástica do modelo parametrizado da malha fechada
H_0^C	Parte estocástica do modelo da malha fechada
H	Parte estocástica do modelo da planta parametrizado
H_0	Parte estocástica da planta real
I_{var}	Índice de variância
$I_{var\,diag}$	Índice de variância diagonal
J	Função objetivo da camada de otimização em tempo real
K	Número de elementos do vetor

kts	Estatística de curtose
MW	Moving window – Janela Móvel
mh	Horizonte de controle
MS	Matriz peso da supressão de movimento das variáveis manipuladas
MDI	Model Discrepancy Indicator – Indicador de Discrepância Modelo
$NMDI$	Normalized Model Discrepancy Indicator – Indicador MDI Normalizado
n_p	Número de populações
n_o	Número de variáveis na entrada/manipuladas
n_i	Número de variáveis na saída/controladas
n_b, n_a, n_d, n_f, n_c	Ordem dos polinômios B, A, D, F e C
n_k	Ordem do tempo morto
ph	Horizonte de predição
$p-value$	Valor p da estatística F de Levene
q	Operador discreto de retardo
r	Sinal externo de referência ou <i>setpoint</i>
s	Variância da amostra
S_N	Função de sensibilidade nominal
$S_{N\,diag}$	Função de sensibilidade nominal diagonal
\hat{S}_K	Função de sensibilidade estimada
S	Modelo da função de sensibilidade parametrizada
S_0	Função de sensibilidade real na saída
S_0^i	Função de sensibilidade real na entrada
skn	Estatística de assimetria
T_s	Tempo de amostragem
T_N	Função de sensibilidade complementar nominal
u	Sinal da variável manipulada/entrada medida da planta

\hat{u}	Sinal de referência filtrado pela função de sensibilidade estimada
Δu	Variação na saída do controlador
\check{u}	Sinal das variáveis manipuladas descontado do valor do instante inicial
u_{min}	Limite inferior da restrição das variáveis manipuladas
u_{max}	Limite superior da restrição das variáveis manipuladas
U	Matriz de entradas da planta
var	Variância
V_K	Função objetivo da minimização do erro de predição
W	Matriz peso das variáveis controladas
W_N	Função objetivo da minimização do erro nominal
XCF	Correlação cruzada
\tilde{x}_i	Mediana da amostra i
y_{min}	Limite inferior da restrição das variáveis controladas
y_{max}	Limite superior da restrição das variáveis controladas
y_{soft}	Restrição flexível das variáveis controladas
Y	Matriz de saídas da planta
$y_{i,k}$	Sinal da saída compensada referente ao canal $(y_i \times u_k)$
$\hat{y}_{i,k}$	Predição um passo a frente da saída compensada do canal $(y_i \times u_k)$
$\Delta \hat{y}$	Predição da variação da saída da planta
\hat{y}_p	Estimação da saída analisada
\hat{y}_{pf}	Saída parcial filtrada
\hat{y}_{pf}^{ex}	Saída parcial filtrada da variável externa
y_{sim}	Saída simulada com o modelo nominal
y_N	Saída nominal
y_{Ndiag}	Saída nominal diagonal

y	Sinal da variável controlada/saída medida da planta
\hat{y}	Predição um passo a frente da saída da planta
Z^K	Conjunto de dados para identificação
Z	Distribuição analisada
z_{cal}	Teste bicaudal do valor crítico de uma distribuição normal z
v	Sinal do distúrbio não medido
v_c	Distúrbio não-medido da malha fechada
Λ	Matriz de pesos da norma quadrática ponderada
Λ_0	Matriz de covariância do ruído branco
θ	Parâmetros do modelo da planta
$\hat{\theta}_K$	Parâmetros estimados do modelo da planta
ε	Erro de predição
δ_c	Vetor de parâmetros dos modelos nominais dos canais discrepantes
λ	Intervalo de defasagem
α	Nível de significância
σ	Desvio padrão
$\ \cdot\ _W$	Norma quadrática ponderada

Capítulo 1 – Introdução

Modelos de processos possuem um importante papel no projeto de qualquer sistema de controle. Em estruturas clássicas de controle, como malhas que utilizam controle proporcional-integral-derivativo (PID), o modelo da planta, que é usado indiretamente na malha de controle, é necessário em conjunto com diretrizes bem definidas para realizar o ajuste do controlador (YERRAMILI; TANGIRALA, 2016). Em técnicas de controle avançado, como controladores baseados em modelos (MPC, do inglês *Model Predictive Control*), o modelo *online*, isto é, usado diretamente na malha de controle, é necessário para gerar previsões da saída (geralmente uma variável controlada) e tomar medidas corretivas apropriadas (MACIEJOWSKI, 2002).

Mesmo com técnicas avançadas de controle, o uso de estruturas fixas de baixa ordem, como controladores PID, ainda são amplamente utilizadas em estruturas de controle devido à sua simplicidade, confiabilidade e robustez (SEER; NANDONG, 2017). A maioria dos trabalhos desenvolvidos ao longo dos anos propuseram regras de sintonia que relacionam, de uma maneira mais simples, os parâmetros do controlador com os parâmetros do modelo do processo (VILANOV; ALFARO, 2011). Além disso, índices de desempenho da malha fechada, como estabilidade relativa, margem de ganho e margem de fase, também dependem de um bom modelo da planta para serem estimados. Logo, a qualidade do modelo do processo afeta significativamente o desempenho da malha fechada.

Ainda que a presença do controle clássico na indústria seja forte, o uso do MPC tem aumentado significativamente nas duas últimas décadas (BADWE et al., 2009) para controle de unidades-chave, isto é, que causam um maior impacto na planta como um todo, como uma torre de destilação na indústria petroquímica (DOMA; TAYLOR; VERMEER, 1996) devido à sua capacidade de controle multivariável sujeito a restrições. Outra característica de controladores preditivos está no cálculo de movimentos ótimos, geralmente de entrada na planta, como uma determinada abertura de uma válvula, pela solução de um problema de otimização, no qual, através de uma função objetivo definida para o controlador, utilizam-se previsões das variáveis controladas até um certo horizonte de previsão. Para isso, esses controladores utilizam modelos explícitos do processo, relacionando as variáveis de entrada (variáveis manipuladas, ou MVs, e variáveis de distúrbio, também conhecidas por distúrbios medidos, ou DVs) e as variáveis de saída (variáveis controladas, ou CVs), para levar a planta de um estado estacionário a outro mais rentável.

Conforme QIN; BADGWELL (2003), o controlador preditivo é parte de um nível da hierarquia das funções de controle. A união destas funções resulta numa estrutura de controle capaz de substituir uma série de controladores clássicos. A Figura 1.1 ilustra, à esquerda, uma estrutura convencional de controle e, à direita, a hierarquia que compõe uma estrutura de controle preditivo. No topo desta, um otimizador global determina os pontos estacionários ótimos para cada unidade da planta. Estes pontos, por sua vez, são enviados para otimizadores locais em cada subunidade, as quais consideram mais detalhadamente o processo. Como exemplo, um processo de craqueamento de frações do petróleo constitui uma unidade e, nesta, uma coluna de destilação uma subunidade. Os otimizadores locais computam um ótimo econômico e enviam para um nível inferior que, por sua vez, move a planta, minimizando violações das restrições impostas pelo nível superior. Na estrutura convencional, essa etapa é atingida utilizando uma combinação de algoritmos PID, blocos lead-lag (L/L) e seletores lógicos (High/Low). Já na estrutura utilizando controladores preditivos, essa combinação de blocos é substituída apenas por um controlador MPC.

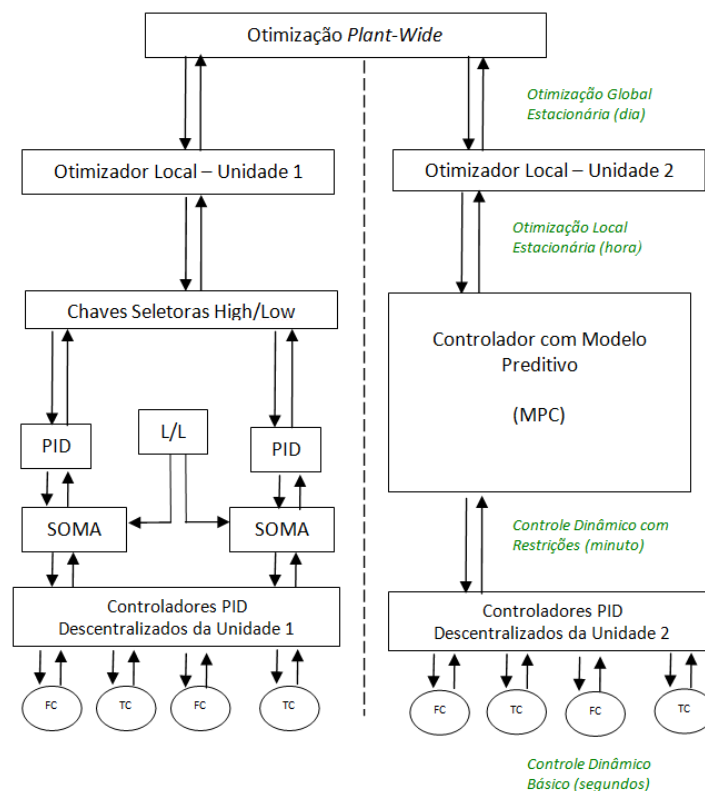


Figura 1.1: Hierarquia de controle
(Adaptado de QIN; BADGWELL, 2003)

Mesmo com uma hierarquia de controle superior, isto é, que pode levar a um melhor desempenho e redução de custos, frente aos sistemas clássicos, o sucesso de uma boa implementação de sistemas de controle preditivo está na identificação de um bom modelo, uma vez que sua função é prever o comportamento futuro do processo para que ações de controle, que antecipem possíveis violações dos limites do sistema, possam ser tomadas (CAMPOS; GOMES; PEREZ, 2013). O modelo utilizado deve, portanto, ser avaliado por esta capacidade de previsão “k” intervalos de tempo no futuro.

O controle preditivo multivariável é um algoritmo de controle, industrialmente adotado na versão discreta, e sua metodologia se baseia na predição em cada instante de tempo, através da utilização de um modelo, das saídas do processo para um determinado horizonte, P , chamado horizonte de predição. As ações de controle são calculadas em cada instante de amostragem através da minimização de uma função objetivo, a fim de manter o processo mais perto possível da trajetória de referência, ao longo de um horizonte de controle, M . A variação dessas variáveis pode também ser incluída na função objetivo a ser minimizada, e somente a primeira ação de controle é enviada ao processo. No próximo instante de amostragem todo o procedimento é repetido, sendo essa técnica chamada de “Horizonte Deslizante”. Tal procedimento é ilustrado na **Erro! Fonte de eferência não encontrada.**, onde esse procedimento pode ser visualizado.

O controlador MPC calcula a predição em cada instante de tempo, através da utilização de um modelo, das saídas do processo para um determinado horizonte, P , chamado horizonte de predição. As ações de controle são calculadas em cada instante de amostragem através da minimização de uma função objetivo, a fim de manter o processo mais perto possível da trajetória de referência, ao longo de um horizonte de controle, M . Apenas a primeira ação de controle é utilizada em cada instante de tempo e o processo é repetido nas próximas ações ao longo do chamado de horizonte deslizante. Fazendo-se uma analogia com uma viagem de carro, cujo destino depende das vias disponíveis para o trajeto, o modelo utilizado no controlador seria equivalente a um mapa para se identificar qual a melhor via a ser tomada para se chegar ao destino desejado. Se mais de uma rota é possível, a camada de otimização do controlador seria equivalente ao se observar características das vias, como acesso a pista simples ou dupla, rodovia com pedágio, se é estadual ou federal, entre outros, de modo a se decidir qual o melhor caminho, isto é, o caminho ótimo, para se chegar ao destino final.

Um tipo de problema de otimização de um MPC pode ser expresso pela Equação (1.1), na qual o desvio da variável de processo é penalizado em relação à variável de referência, bem como o esforço das variáveis manipuladas para atingir o objetivo de controle, o desvio da variável manipulada em relação a um *target*, se existir, e a violação da faixa de operação.

$$\min_{u, \varepsilon_k} J = \min_{u, \varepsilon_k} \left(\sum_{j=1}^M \|u(t+j|t) - u_{target}(t+j|t)\|_{W_u}^2 + \sum_{j=1}^P \|\hat{y}(t+j|t) - r(t+j|t)\|_Q^2 + \sum_{j=1}^M \|\Delta u(t+j-1|t)\|_W^2 + \rho_\varepsilon \varepsilon_k^2 \right)$$

sujeito à

(1.1)

$$u_{min[1]}^M \leq u_{[1]}^M \leq u_{max[1]}^M$$

$$-\Delta u_{min[1]}^M \leq \Delta u_{[1]}^M \leq \Delta u_{max[1]}^M$$

$$\hat{y}_{min[1]}^P - \varepsilon_k \leq \hat{y}_{[1]}^P \leq \hat{y}_{max[1]}^P + \varepsilon_k$$

onde $u(t + j|t)$ são as ações de controle futuras calculadas, $u_{target}(t + j|t)$ é o target (valor de referência) para as variáveis manipuladas, $\hat{y}(t + j|t)$ é a saída predita pelo modelo, $r(t + j|t)$ é o *setpoint*, $\Delta u(t + j - 1|t) = u(t) - u(t - 1)$ é o esforço das variáveis de controle, W_u , Q e W são matrizes de peso para as variáveis manipuladas, variáveis controladas e supressão do movimento, ρ_ϵ é o peso da penalização por violação da *soft-constraint*, ϵ_k é a máxima folga de desvio da faixa, que quantifica o pior caso de violação das variáveis controladas e $\|x\|_W^2 = x^T W x$ é a norma-peso euclidiana de x . A escolha do tempo de amostragem (t_s), horizonte de predição (P), horizonte de controle (M), as matrizes de peso (W_u , Q e W) e a penalização das restrições brandas (*soft-constraint*, (ρ_ϵ)) consistem nos parâmetros de sintonia para o controlador MPC.

Alguns casos particulares de problemas de controle podem ser derivados da Equação (1.1), como quando não há *target* para as variáveis manipuladas, onde o termo correspondente a essa penalização é desconsiderado (ou os pesos da matriz W_u são iguais à zero). O mesmo ocorre para a penalização por violação quando são consideradas faixas de operação ao invés de *setpoint*.

Dentre os algoritmos disponíveis para controle preditivo, os mais populares e que possuem maior difusão na indústria são: *Dynamic Matrix Control* (DMC) e *Generalized Predictive Control* (GPC) (Camacho e Bordons, 1999). Para a configuração como DMC, o modelo do processo utilizado é dado pelo vetor de coeficientes da resposta do processo ao degrau unitário, ou seja, os elementos desse vetor representam a mudança observada na saída do processo em instantes discretos de mesma amostragem e duração, após uma perturbação do tipo degrau unitário na variável de entrada.

No caso do controlador do tipo GPC, considera-se como modelo uma matriz de transferência da transformada z da resposta degrau da planta. Para um caso genérico de dimensão $[n_{CV} \times n_{MV}]$, sendo n_{CV} o número de saídas (variáveis controladas) e n_{MV} o número de entradas (variáveis manipuladas), a matriz de transferência é composta pela combinação das funções de transferência que associam cada saída y a uma entrada u , onde cada coluna dessa matriz (n_{MV}) representa as entradas e cada linha da matriz (n_{CV}) representa as saídas tal que:

$$G(z) = \begin{bmatrix} g_{1,1}(z) & g_{1,2}(z) & \cdots & g_{1,n_{MV}}(z) \\ g_{2,1}(z) & g_{2,2}(z) & \cdots & g_{2,n_{MV}}(z) \\ \vdots & \vdots & \ddots & \vdots \\ g_{n_{CV},1}(z) & g_{n_{CV},2}(z) & \cdots & g_{n_{CV},n_{MV}}(z) \end{bmatrix} \quad (1.2)$$

onde $G(z)$ é a matriz de transferência e $g_{n_{CV},n_{MV}}(z)$ é o modelo do canal que associa a saída n_{CV} à entrada n_{MV} . Utilizando os índices i e j , tal que $i = 1, \dots, n_{CV}$ e $j = 1, \dots, n_{MV}$, para denotar, respectivamente, às variáveis de entrada e de saída do controlador, temos que um canal da matriz de transferência corresponde a cada elemento da matriz, ou seja, uma função de transferência que retorna a predição da variação de uma saída, $\Delta \hat{y}_i(t)$, para uma dada variação em uma entrada, $\Delta u_j(t)$, tal que:

$$\frac{\Delta \hat{y}_i(t)}{\Delta u_j(t)} = g_{i,j}(z) \quad (1.3)$$

onde Δy_i é a variação da variável de saída, $g_{i,j}$ é o modelo do canal entre as variáveis de entrada u_j e de saída y_i e Δu_j é a variação da variável de entrada u_j .

1.1 Motivação

Técnicas avançadas de controle, como o uso de controladores preditivos multivariáveis, alinhadas com a obtenção e manutenção de um modelo que represente adequadamente o processo, conseguem auxiliar na melhoria da eficiência, qualidade e robustez do processo, e conseqüentemente melhorando a qualidade dos produtos com e redução dos custos operacionais. Por outro lado, como qualquer estrutura de controle, sistemas que utilizam MPC são suscetíveis a várias fontes de degradação de desempenho, como controlador mal sintonizado, configuração inapropriada de restrições e presença de distúrbios não medidos (UD, do inglês *Unmeasured Disturbance*) (SUN et al., 2013). Mudanças no processo, como obsolescência dos equipamentos, incrustações, variações nos regimes de operação, etc., fazem com que o mesmo opere de forma diferente daquela para a qual o modelo foi identificado. Além disso, os modelos identificados são lineares enquanto o processo em si é não linear (YERRAMILLI; TANGIRALA, 2016). Em todos estes casos, o modelo utilizado reduz a sua capacidade preditiva e aumentar a discrepância entre modelo e planta (MPM, do inglês *Model Plant Mismatch*), causando uma degradação na performance da malha fechada.

Controladores preditivos possuem um determinado ciclo de vida, que depende de uma boa implementação e de manutenção contínua, especialmente do modelo, de forma a se garantir um funcionamento adequado ou, até mesmo, melhorar o desempenho da malha pós fase de implantação. Na Figura 1.2, o ciclo de vida de um MPC é retratado em três regiões. Inicialmente, na região A, observa-se que grande parte do benefício é agregado logo após o projeto de implantação do controlador, visto que os modelos identificados e as restrições consideradas são bastante aderentes ao processo. Esse patamar de benefícios é sustentado por um certo período durante o qual o controle efetuado é adequado ao processo. Quando os modelos dinâmicos identificados, os quais são empíricos na maioria das vezes, possuem discrepância com a planta real, o desempenho da malha fechada é prejudicado e o ganhos trazidos pelo MPC entram em declínio, como indicado na região B. Caso não haja um trabalho para revisar o controlador, retornando ao patamar de operação desejado, o controle não adequado do processo coloca o controlador em risco de desativação, encerrando seu ciclo de vida. Por outro lado, se a origem do mau desempenho é diagnóstica e uma manutenção adequada é realizada, o processo pode voltar a ter o desempenho adequado ou, alinhando-se uma melhoria contínua do processo como um todo, como manutenção da instrumentação, da estratégia do controle regulatório e da sintonia dos controladores, os ganhos do controle preditivo podem ser ampliados, como indicado na região C.

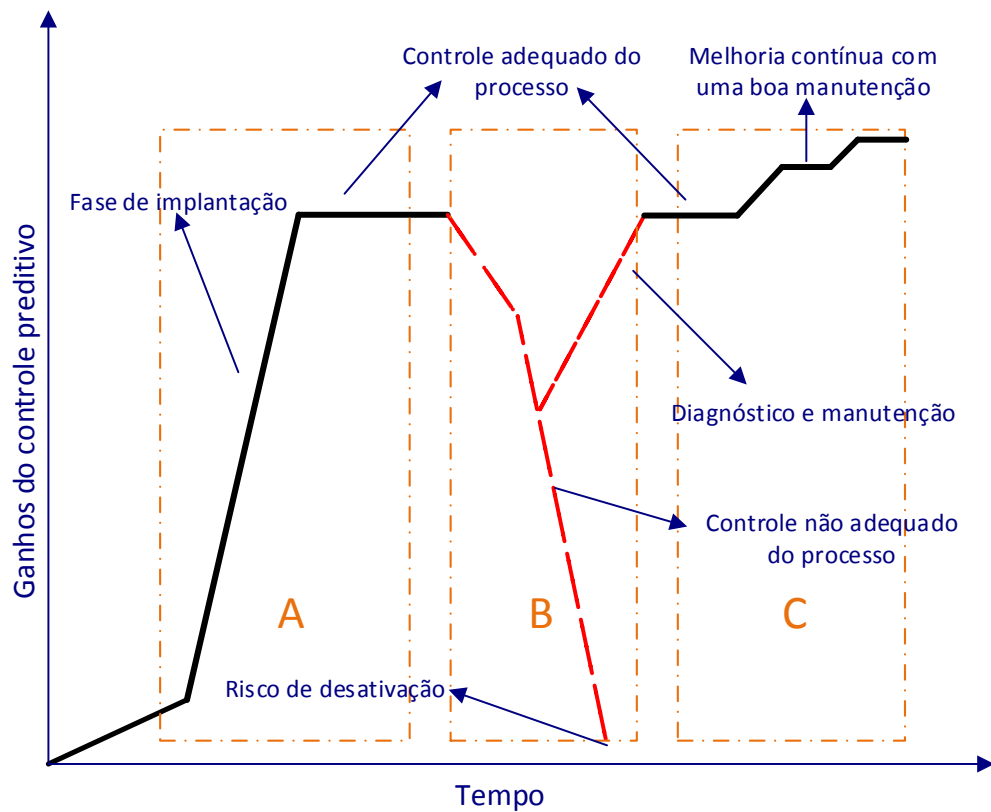


Figura 1.2: Ciclo de vida de um sistema de controle avançado (Adaptado de CAMPOS; GOMES; PEREZ (2013))

Apesar da manutenção dos controladores ser uma tarefa essencial para manter o patamar de benefícios em seu ciclo de vida, ela é fortemente dependente dos componentes de cada planta e do domínio técnico do assunto pelos engenheiros e operadores. Segundo CLARO (2016), a indústria petroquímica, por exemplo, tem a prática de considerar um período de cinco anos como tempo de vida útil de um controlador antes que este entre na região de queda crítica de desempenho (região B da Figura 1.2). Neste período, deve-se conciliar as demandas adicionais por agregação de valor, como novos controladores e/ou escopos adicionais aos existentes, com a manutenção propriamente dita do controlador, além de se levar em conta se as condições operacionais da planta são favoráveis para a remodelagem.

Utilizando como exemplo as centrais de matéria-prima nas petroquímicas da Braskem, CLARO (2016) expõe a dimensão da tarefa de manutenção nas áreas de produção de olefinas, aromáticos e utilidades, que são controladas por uma média de sessenta controladores preditivos multivariáveis. Para se assegurar o desempenho adequados dessas aplicações e tomando-se como único fator determinante para a remodelagem um ciclo de vida de cinco anos, é necessária a revisão de cada controlador, contemplando o planejamento de experimentos de teste na planta, a reconstrução da matriz de transferência, no caso de um controlador preditivo GPC, o comissionamento e sintonia da aplicação e o treinamento de operadores, além de possíveis demandas por novos controladores ou projetos de melhoria contínua em controladores existentes.

Além da grande carga de trabalho que a remodelagem oferece, existem outros fatores que impactam na tarefa de se obter um bom modelo, como a ferramenta utilizada na identificação. FORBES et al. (2015) expõe a importância que pacotes especializados, ou software, oferecem na remodelagem, os quais ajudam o usuário a obter dados de planta e de desenvolver os modelos necessários para o MPC. Por outro lado, a facilidade com a qual o software pode ser utilizado tem grande efeito no resultado da manutenção. Por exemplo, grande número de etapas para se obter um modelo, o que aumenta a possibilidade de se cometer algum erro, e a alta complexidade que estas ferramentas podem requerer, podendo intimidar usuários não familiarizados com os conceitos necessários e necessitar pessoal altamente capacitado para executar a tarefa.

Entre as possíveis causas de degradação do desempenho de controladores preditivos, a baixa qualidade do modelo é, frequentemente, mais impactante (BOTELHO et al., 2015). O foco principal do monitoramento de malhas de controle é manter um desempenho suficiente ou, ao menos, prevenir que o mesmo deteriore. Para isso, os engenheiros de controle precisam saber a causa da degradação da malha e tomar medidas preventivas (KANO et al., 2010). Assim, a auditoria dos modelos de MPCs está posicionada como um pré-requisito para a remodelagem, visando se extrair informações relevantes sobre o modelo que permitam formular uma estratégia sistemática para a atualização da matriz dinâmica do processo. Para isso, as tarefas iniciais do escopo da remodelagem devem englobar uma etapa de auditoria que consiga indicar se há uma degradação do desempenho do controlador, seguida de uma etapa de diagnóstico que seja capaz de identificar a origem da degradação, ou seja, que exponha se é necessário identificar de um novo modelo. Além disso, para limitar o escopo da revisão de controladores, a auditoria deve ser capaz de indicar exatamente qual canal do modelo da matriz dinâmica do controlador, ou seja, a combinação do par CV-MV, é discrepante da planta.

Considerando este cenário, a manutenção de modelos de controladores preditivos diretamente alinhada às etapas de auditoria e diagnóstico está posicionada como um tema muito atrativo, pois:

- Otimiza a utilização de recursos nas atividades de remodelagem do controlador, pois possibilita focar exatamente nos canais discrepantes do modelo, reduzindo o escopo da identificação e possibilitando a remodelagem no momento do diagnóstico de mau desempenho, em contraste às manutenções programada após período determinados de operação;
- Maximiza o potencial de retorno econômico dos controladores preditivos, priorizando a revisão destas aplicações em conjunto com índices de desempenho de auditoria das malhas, obtendo modelos dentro de padrões estipulado e diminuindo o tempo em que o controlador opera como desempenho inadequado;
- Possibilita a redução da carga de trabalho, pois requer as mesmas informações utilizadas nas etapas de auditoria e diagnóstico e permite a identificação de modelos baseada no desempenho no controle, ao invés do critério aderência aos dados utilizados identificação (erro de predição do modelo identificado);

1.2 Objetivos do trabalho

O objetivo principal deste trabalho é a manutenção de modelos com o desenvolvimento de uma metodologia para identificação da matriz de transferência do controlador que estejam efetivamente degradando o desempenho do controlador preditivo baseado em modelos, fornecendo uma remodelagem para os canais da matriz mais correlacionados ao problema de discrepância com a planta real do processo. Além disso, visa-se realizar uma manutenção de modelos com as mesmas informações necessárias para a etapa de auditoria e diagnóstico do controlador, utilizando dados históricos das variáveis do processo em detrimento a testes em linha na planta, visto esta ser uma abordagem intrusiva a qual nem todos os processos industriais permitem ser realizada;

1.3 Estrutura da dissertação

Essa dissertação apresenta-se dividida em 6 capítulos. Nesta introdução, apresentou-se a problemática geral do tema, abrangendo a motivação necessária para realização deste estudo, seus objetivos gerais e a estrutura do trabalho.

No Capítulo 2 são abordadas as principais metodologias utilizadas na identificação de sistemas em malha fechada, bem como as premissas necessárias para que seja possível utilizá-las.

O Capítulo 3 apresenta uma breve explicação sobre algumas técnicas de auditoria e diagnóstico disponíveis na literatura bem como os fundamentos dos métodos base para realização da auditoria e diagnóstico neste trabalho, que são apresentadas detalhadamente neste capítulo.

A metodologia proposta é apresentada no Capítulo 4. Primeiramente, é exposta a metodologia de identificação direta em malha fechada que compensa os sinais utilizados na identificação para priorizar os canais que estejam afetando diretamente o desempenho do controlador. Em seguida, é abordada a metodologia de remodelagem dos canais discrepantes baseados na análise do erro nominal em malha fechada, que engloba conceitos diretos da técnica de auditoria e diagnóstico utilizada neste trabalho. Além disso, o capítulo finaliza com a junção dos métodos apresentadas para formar um método sequencial de identificação em malha fechada.

No Capítulo 5, é apresentado o estudo de caso para duas das possíveis configurações de um controlador preditivo (por *setpoint* e por faixas), visando avaliar a eficiência das metodologias desenvolvidas no capítulo 4. Os resultados obtidos e a análise dos mesmos são demonstrados na sequência.

O capítulo 6 apresenta as considerações finais, conclusões da pesquisa e sugestões para trabalhos futuros

Capítulo 2 – Revisão Bibliográfica

Neste capítulo é realizado um levantamento bibliográfico dos métodos clássicos de identificação em malha fechada para o desenvolvimento deste trabalho, sendo eles o método direto, indireto e em dois estágios (*Two-stage* ou *Joint Input-Output*)

2.1 Métodos de Identificação em Malha Fechada

HUANG & SHAH (1999) descrevem que, na identificação em malha fechada, o objetivo é obter um modelo dinâmico para o processo utilizando-se dados em malha fechada gerados com um sinal *dither* de excitação, ou seja, um sinal externo que é diretamente injetado no sinal de entrada da planta de forma a se causar uma interferência mínima na operação da malha fechada (TANGIRALA, 2015). Desta forma, o processo de identificação se dá naturalmente na operação da planta, ou seja, sem a necessidade de se abrir a malha para coletar dados, como ocorre com a identificação em malha aberta.

No campo da identificação de sistemas, existe uma forte relação econômica e de segurança vinculadas a necessidade de se coletar dados em malha fechada, como o fato de que mesmo plantas estáveis em malha aberta estão sujeitas a distúrbios não estacionários (AGÜERO; GOODWIN; VAN DEN HOF, 2011) ou ainda plantas que devem trabalhar em malha fechada por serem instáveis em malha aberta (FORSSELL; LJUNG, 1999). Por outro lado, este tipo de identificação torna-se conflitante com o objetivo de controle, que é rejeitar qualquer perturbação para estabilizar o sistema, devido à necessidade de o sistema ser suficientemente perturbado para se gerar dados ricos em informações para a identificação (FERRAMOSCA et al., 2013).

Os diferentes métodos existentes na literatura que tratam de identificação em malha fechada, de acordo com FORSELL & LJUNG (1999), são classificados de acordo com as informações utilizadas na identificação, como:

- a) Ter conhecimento sobre a natureza do mecanismo de retroalimentação do controlador e usar apenas medidas da entrada da planta, ignorando entradas extras ou sinais de *setpoint*, mesmo se disponíveis;

- b) Assumir que a retroalimentação é conhecida e usar possíveis entradas extras e *setpoint*;
- c) Assumir que o controlador é desconhecido, mas possui uma certa estrutura, como a indicada na Figura 2.1 (com/sem retroalimentação, com/sem *feedforward*, etc.).

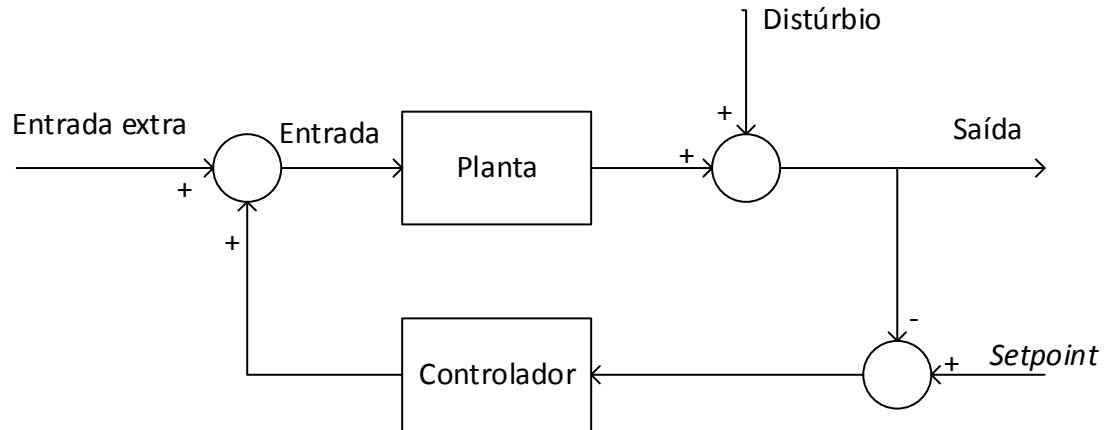


Figura 2.1: Sistema genérico em malha fechada

Os autores FORSELL & LJUNG (1999) ressaltam que as premissas (b) e (c) são comumente utilizadas assumindo-se que o controlador é linear, também podendo, entretanto, serem aplicadas para controladores não-lineares ou variantes no tempo. Neste caso, os problemas na estimação de parâmetros serão mais pronunciados. Além disso, chamam atenção para o fato de que:

- i. Se a entrada da planta é medida, ter conhecimento da forma do controlador, bem como entradas extras ou sinais de setpoint, não traz nenhuma informação adicional sobre o sistema em malha aberta;
- ii. Se o conhecimento sobre o controlador está disponível, desde que este seja linear, invariante no tempo e livre de ruídos, é possível reconstruir a entrada da planta usando-se medidas da saída da mesma bem como sinais de entradas extras ou setpoint e, então, estes não carregam nenhuma informação extra sobre o sistema em malha aberta.

Considerando-se as informações disponíveis antes da identificação, como exposto em (i) e (ii), não haveria problema no método escolhido desde que o controlador seja linear, invariante no tempo e livre de ruídos. Entretanto, este não é o caso normalmente encontrado em indústria de processos, nas quais os controladores possuem, na maioria das vezes, uma estrutura complexa, como restrições nas variáveis controladas e manipuladas, funções *anti-windup*, além da própria não linearidade inerente ao processo. Logo, um método baseado na premissa (c) seria fortemente desfavorecido (FORSELL; LJUNG, 1999).

Com as possibilidades expostas de (a) a (c), os métodos de identificação em malha fechada podem ser classificados em direto, indireto ou uma combinação dos dois, chamada de *two-stage method* ou *joint input-output*.

O método direto se refere à identificação da dinâmica da planta realizada diretamente com sinais medidos na entrada e saída utilizando-se uma estrutura pré-definida, como modelos paramétricos ou fenomenológicos (AGÜERO; GOODWIN; VAN DEN HOF, 2011). Sua vantagem é não requerer o conhecimento exato do controlador, o que possibilita também a estimação de modelos quando o controlador é não-linear. Entretanto, para se alcançar uma boa estimação, é necessário modelar com precisão a dinâmica do ruído presente no processo (HUANG; SHAH, 1999). Um diferencial do método direto é que ele também pode ser utilizado para plantas instáveis, desde que o controlador torne a malha fechada estável. Esta condição é automaticamente satisfeita com modelos ARX (*AutoRegressive Exogenous*) e, tomando-se medidas especiais, como descritas por FORSELL; LJUNG (1999), OE (*Output Error*) e BJ (*Box-Jenkins*).

O método indireto, por sua vez, não estima o modelo diretamente, como sugere seu nome, e ainda necessita o conhecimento exato do controlador, que deve ser linear (HUANG; SHAH, 1999). Primeiramente, identifica-se a função de sensibilidade da malha fechada, que é o modelo que relaciona o sinal de referência (*setpoint*) e a saída da planta. Em seguida, o modelo da planta é obtido utilizando-se a função de sensibilidade e as informações do controlador (BADWE; PATWARDHAN; GUDI, 2011).

Baseando-se na premissa de que o controlador é linear, uma terceira categoria, chamada de método de dois estágio, do inglês *two-stage method*, também é relatada na literatura. Neste método, tanto a entrada como a saída da planta são tratadas como saídas de um sistema aumentado que é guiado por uma entrada extra, como um sinal de referência. A partir de uma estimação da função de sensibilidade deste sistema aumentado, obtém-se um novo sinal, do qual, em conjunto com a saída da planta, estima-se os parâmetros do sistema em malha aberta (BADWE; PATWARDHAN; GUDI, 2011).

A Tabela 2.1 adaptada de BADWE; PATWARDHAN; GUDI (2011), apresenta um resumo dos requisitos básicos necessários para cada um dos métodos expostos.

Tabela 2.1: Requisitos para os métodos de identificação em malha fechada

Método	Modelo para o ruído branco	Perturbação externa	Controlador linear	Controlador conhecido
Direto	Sim	Sim	Não	Não
Indireto	Não	Sim	Sim	Sim
<i>Two-stage</i>	Não	Sim	Sim	Não

A identificabilidade de um sistema depende de algumas premissas e condições que devem ser satisfeitas, como expunha LJUNG (1987). Nesta dissertação, são apresentadas apenas algumas definições e premissas básicas para o entendimento dos métodos citados na Tabela 2.1. Assim, seja um conjunto de dados do processo tal que:

$$Z^K = \{u(1), y(1), \dots, u(K), y(K)\} \quad (2.1)$$

onde as entradas e saídas medidas são, respectivamente, dadas por $u(t)$ e $y(t)$, $t = 1, \dots, K$. Além disso, seja a estrutura da malha fechada com retroalimentação e um grau

de liberdade (SKOGESTAD; POSTLETHWAITE, 2005) como aquele ilustrado na **Figura 2.2**: Diagrama de blocos para um sistema com retroalimentação de um grau de liberdade.




Figura 2.2: Diagrama de blocos para um sistema com retroalimentação de um grau de liberdade

Para fins de identificação, FORSELL; LJUNG (1999) expunham a premissa de que o sistema real é causal, linear e invariante no tempo com p saídas e m entradas. Assim, pela **Figura 2.2**: Diagrama de blocos para um sistema com retroalimentação de um grau de liberdade tem-se que:

$$\begin{aligned} y(t) &= G_0(q)u(t) + v(t) \\ v(t) &= H_0(q)e(t) \end{aligned} \quad (2.2)$$

onde $e(t)$ é um ruído branco Gaussiano com média zero e matriz de covariância Λ_0 e $G_0(q)$ e $H_0(q)$ são, respectivamente, as partes determinística e estocástica do modelo da planta no operador q^{-1} de retardo ($q^{-1}u(t) = u(t-1)$), sendo $H_0(q)$ estável e inversamente estável.

Assumindo que, na **Figura 2.2**: Diagrama de blocos para um sistema com retroalimentação de um grau de liberdade, $C(q)$ representa um controlador linear, as ações de controle $u(t)$ são tais que:

$$u(t) = r(t) - C(q)y(t) \quad (2.3)$$

onde $C(q)$ é um controlador linear e invariante no tempo e $r(t)$ é o sinal quasi-estacionário dado, sendo uma entrada extra ou um sinal *setpoint*, e independente de $v(t)$, como apresentado na Equação (2.2). De acordo com FORSELL; LJUNG (1999), se a relação entre os sinais de entrada $\{u(t), r(t)\}$ e de saída $\{y(t)\}$ for determinística e a Equação (2.3) for válida, o sistema em malha fechada será exponencialmente estável. Logo, as equações da malha fechada para esta configuração com um controlador linear são:

$$y(t) = S_0(q)G_0(q)r(t) + S_0(q)H_0(q)e(t) \quad (2.4)$$

$$u(t) = C(q)S_0^i(q)r(t) - C(q)S_0^i(q)H_0(q)e(t) \quad (2.5)$$

onde $S_0(q)$ e $S_0^i(q)$ são, respectivamente, a função de sensibilidade na saída e na entrada, definidas como:

$$S_0(q) = (I + G_0(q)C(q))^{-1} \quad (2.6)$$

$$S_0^i(q) = (I + C(q)G_0(q))^{-1} \quad (2.7)$$

Quanto à etapa de escolha da estrutura do modelo, existe uma gama de estruturas propostas na literatura. Na identificação de modelos *black-box*, é assumido que o sistema é desconhecido e todos os parâmetros do modelo são ajustáveis em uma estrutura pré-selecionada. No geral, esta estrutura é derivada do seguinte modelo linear:

$$A(q)y(t) = \frac{B(q)}{F(q)} u(t) + \frac{C(q)}{D(q)} e(t) \quad (2.8)$$

onde A, B, C, D e F são funções polinomiais de q e contém os parâmetros a serem estimados (Ljung, 1987). Dependendo da escolha dos polinômios que serão utilizados, diferentes modelos podem ser obtidos, dos quais se pode destacar os modelos *ARX* (*AutoRegressive Exogenous*), *OE* (*Output Error*) e *BJ* (*Box-Jenkins*).

2.1.1 Identificação em Malha Fechada: Método Direto

A identificação em malha fechada pelo método direto se resume em utilizar, diretamente, dados de entrada e saída da planta com o método do erro de predição, PEM (do inglês, *Prediction Error Method*), o qual se encontra detalhado no Apêndice A. Seja uma estrutura genérica do modelo

$$y(t) = G(q, \theta)u(t) + H(q, \theta)e(t) \quad (2.9)$$

onde θ é o vetor de parâmetros desconhecidos pertencentes a um conjunto compacto e conexo. Para esta estrutura, a predição um passo à frente, como descrita por LJUNG (1987), é dada por:

$$\hat{y}(t|t-1, \theta) = H^{-1}(q, \theta)G(q, \theta)u(t) + (I - H^{-1}(q, \theta))y(t) \quad (2.10)$$

onde $\hat{y}(t|t-1, \theta)$ é a predição da saída $y(t)$ baseada nos dados até o momento $t-1$ e nos parâmetros θ .

O método direto ignora a existência da retroalimentação na malha fechada, o que torna possível sua utilização em sistema com retroalimentação desconhecida. Assim, pode-se desconsiderar a correlação existente entre as variáveis manipuladas e o distúrbio e os parâmetros θ podem ser diretamente estimados com um conjunto de dados Z^K , como na Equação (2.1). Assim, dada uma estrutura de modelo, como em (2.9), utiliza-se os dados de entrada e saída, isto é, um conjunto de dados Z^K com as saídas medidas y e as ações de controle u diretamente na estimação dos parâmetros pela minimização do erro de predição, isto é:

$$\hat{\theta}_K = \min_{\theta} V_K(\theta, Z^K) \quad (2.11)$$

$$V_K(\theta, Z^K) = \frac{1}{K} \sum_{t=1}^K \|\varepsilon(t, \theta)\|_{\Lambda} = \frac{1}{K} \sum_{t=1}^K \varepsilon^T(t, \theta) \Lambda^{-1} \varepsilon(t, \theta) \quad (2.12)$$

$$\varepsilon(t, \theta) = y(t) - \hat{y}(t|t-1, \theta) = H^{-1}(q, \theta)(y(t) - G(q, \theta)u(t)) \quad (2.13)$$

onde $\varepsilon(t, \theta)$ é o erro de predição e $\|\cdot\|_W$ representa a norma quadrática ponderada por uma matriz simétrica e positiva definida Λ , que é escolhida de acordo com a importância que se deseja para cada saída do sistema MIMO que se deseja identificar.

De acordo com FORSELL; LJUNG (1999), o método do erro de predição também pode ser utilizado em malhas instáveis desde que o controlador seja estável. Para isso, pode-se utilizar modelos ARX e ARMAX (*AutoRegressive Moving Average eXogenous*), ou mesmo para modelos OE e BJ.

2.1.2 Identificação em Malha Fechada: Método Indireto

O método indireto de identificação em malha fechada pode ser utilizado quando o controlador, que deve ser linear, e algum sinal de entrada extra ou setpoint são conhecidos. O procedimento consiste de duas etapas: primeiro, identifica-se o modelo do sistema em malha fechada e, em seguida, um modelo do sistema em malha aberta é computado. Para o controlador linear, as ações de controle são dadas pela Equação (2.3) e a saída do sistema em malha fechada será:

$$y(t) = G_0^C(q)r(t) + v_c(t), \quad v_c(t) = H_0^C(q)e(t) \quad (2.14)$$

$$G_0^C(q) = S_0(q)G_0(q) \quad H_0^C(q) = S_0(q)H_0(q) \quad (2.15)$$

onde G_0^C e H_0^C são, respectivamente, o modelo em malha fechada da planta e do distúrbio. O modelo utilizado na identificação, conhecidos os sinais de saída e referência da planta, é dado por:

$$y(t) = G^C(q, \theta)r(t) + H_*(q)e(t) \quad (2.16)$$

onde $G^C(q, \theta)$ é um modelo parametrizado do sistema em malha fechada. Assim, com o conhecimento do controlador, obtém-se uma estimativa \hat{G}_K do modelo em malha aberta pela função da malha fechada :

$$\hat{G}_K^C = \left(I + \hat{G}_K(q)C(q) \right)^{-1} \hat{G}_K(q) \quad (2.17)$$

onde \hat{G}_K^C é o modelo da malha fechada. Este procedimento de identificação em malha fechada do modelo da planta, por primeiramente requerer identificar o modelo do sistema em malha fechada, acaba tornando-se uma identificação em malha aberta, pois $r(t)$ e $v_c(t)$ não são correlacionados. Isto se torna um benefício do método pois qualquer abordagem de identificação em malha aberta poderia ser utilizada para

obtenção do modelo parametrizado $G^C(q, \theta)$, como por exemplo, o método das variáveis instrumentais ou dos subespaços de estados. O método do erro de predição, entretanto, continuará sendo a abordagem aqui utilizada, pois permite uma parametrização arbitrária dos modelos, como expunham FORSELL; LJUNG (1999).

A solução exata da Equação (2.17) nos retorna a estimativa \hat{G}_K do modelo como:

$$\hat{G}_K(q) = \hat{G}_K^C \left(I - \hat{G}_K^C(q)C(q) \right)^{-1} \quad (2.18)$$

A desvantagem de se obter \hat{G}_K desta forma é que o modelo geralmente será de ordem elevada, tipicamente equivalente à soma das ordens de \hat{G}_K^C e C . Além disso, qualquer erro no modelo do controlador C , incluindo desvios de linearidade, serão diretamente incluídas em \hat{G}_K .

2.1.3 Identificação em Malha Fechada: Two-stage Method

O terceiro método de identificação em malha fechada é chamado *Two-stage Method* ou *Joint Input-Output* (FORSELL; LJUNG, 1999). Sua premissa básica é gerar o sinal de entrada utilizando um controlador de estrutura específica e linear. Isto significa que o conhecimento exato do controlador não é necessário, como é o caso do método indireto. O método consiste nos seguintes passos:

- 1) Estimar os parâmetros β da estrutura de modelo

$$u(t) = S(q, \beta)r(t) + H_1(q, \beta)e(t) \quad (2.19)$$

onde S é a função de sensibilidade na entrada e H_1 corresponde a sua parte estocástica. Os sinais $u(t)$, $r(t)$ e $e(t)$, $t = 1, 2, \dots, K$, K sendo o número de pontos, são, respectivamente, as ações de controle medidas, o valor de referência (*setpoint*) e um ruído aleatório branco de média zero e matriz de covariância Λ_0 . Então, com a função de sensibilidade estimada, $\hat{S}_K(q, \hat{\beta}_K)$, onde $\hat{\beta}_K$ são os parâmetros estimados, o sinal \hat{u} é construído, de modo a se obter um sinal não correlacionado com o distúrbio (LJUNG, 1987), tal que

$$\hat{u}(t) = \hat{S}_K(q, \hat{\beta}_K)r(t) \quad (2.20)$$

- 2) O processo em malha aberta é identificado utilizando-se a estrutura

$$y(t) = G(q, \theta)\hat{u}(t) + H_2(q, \theta)e(t) \quad (2.21)$$

onde G e H_2 são, respectivamente, a parte determinística e estocástica do modelo da planta.

Para se estimar ambos $S(q, \beta)$ e $G(q, \theta)$, o PEM pode ser utilizado. Para o caso da estimação do modelo da planta, Eq. (2.21), a predição um passo à frente é dada por

$$\hat{y}(t|t-1, \theta) = H_2^{-1}(q, \theta)G(q, \theta)\hat{u}(t) + (I - H_2^{-1}(q, \theta))y(t) \quad (2.22)$$

onde $\hat{y}(t|t-1, \theta)$ é a predição da saída medida $y(t)$ baseada nos dados de processo até o intervalo de amostragem $t-1$, utilizando o modelo cujos parâmetros são θ . Portanto, o erro de predição é

$$\varepsilon(t, \theta) = y(t) - \hat{y}(t|t-1, \theta) = H_2^{-1}(q, \theta)(y(t) - G(q, \theta)\hat{u}(t)) \quad (2.23)$$

Assim, dado um conjunto de dados Z^K , os parâmetros são estimados com a minimização do erro de predição, como exposto na seção 2.1.1.

Capítulo 3 – Fundamentos: Metodologia para Determinação dos Canais com Erro de Modelo

O fundamento básico da metodologia proposta nesta dissertação é o conhecimento dos canais do modelo utilizado no controlador que possuam discrepância de modelo. Assim, este capítulo explana as metodologias adotadas para se localizar o canal mais discrepante para cada saída do controlador. A seção 3.1 aborda o método para se determinar qual CV possui erro de modelagem com posterior diagnóstico para se conhecer qual a fonte deste erro, isto é, se ocorre devido à discrepância entre modelo e planta ou à presença de distúrbio não medido. Na sequência, a seção 3.2 expõe como determinar qual é a MV mais correlacionada à CV diagnosticada com erro de modelo, isto é, localizar os canais (combinação CV-MV) mais discrepantes no modelo utilizado no controlador.

3.1 Auditoria e Diagnóstico de MPCs

De acordo com FORBES et al. (2015), a deterioração do desempenho de controladores preditivos em aplicações industriais tem sido uma crescente preocupação, visto que parte significativa dos benefícios iniciais desta aplicação podem reduzir no decorrer do tempo. Além disso, existe sempre um esforço constante para melhorar o desempenho de sistemas de controle, sejam estes avançados (ex. MPC) ou clássicos (ex. PID), e otimizar a eficiência geral da planta. KANO et al. (2010) reportaram, por meio de uma pesquisa realizada no Japão por uma força tarefa constituída por 32 engenheiros de indústrias e 12 pesquisadores de universidades, que 37% dos MPCs avaliados indicaram a discrepância entre modelo e planta como fator principal na degradação de desempenho destas aplicações.

O diagnóstico da causa da deterioração de desempenho tem um papel crucial no monitoramento de controladores preditivos, o que levou a um crescimento na pesquisa sobre o assunto, tanto no meio acadêmico como no meio industrial. KAMMER; GORINEVSKY; DUMONT (2003) propuseram uma técnica na qual, primeiramente, a malha

é aberta, para que o modelo do distúrbio possa ser identificado. Assim, nenhuma discrepância entre modelo e planta está presente caso o modelo estocástico para o erro na saída seja igual ao modelo do distúrbio. Caso contrário, o diagnóstico indica a presença de MPM ou um distúrbio com características que se alteram com o tempo. A vantagem do método é não necessitar de testes online, mas ele requer que a malha seja aberta e é sensível à variação dos distúrbios, caso no qual, o método não é capaz de distinguir a origem do problema (MPM ou distúrbio não medido).

BADWE et al. (2010) propuseram uma metodologia baseada na análise de relações chave na malha fechada, pelos índices de sensibilidade relativa (*Relative Sensitivity Index*, ou SRI) e de sensibilidade projetada (*Designed Sensitivity Index*, ou DSI), e na direcionalidade do sinal de referência, pela relação de variabilidade (*Variability Ratio*, ou VR), para se estimar um desempenho alcançável para a malha fechada. Em seguida, o método compara tal desempenho com o desempenho real e é capaz de distinguir a fonte do erro de modelagem entre distúrbio não medido e discrepância entre modelo e planta. Esta metodologia também concluiu que o impacto da MPM depende tanto da intensidade da discrepância quanto da variação dos *setpoints* no período avaliado.

Ji; ZHANG; ZHU (2012) propuseram um método para detecção de discrepância entre modelo e planta baseado no uso de pequenas perturbações senoidais para se obter estimações precisas da resposta, no domínio da frequência, do processo em pontos de frequência distintos. Com isso, uma matriz índice de discrepância de modelo é construída para indicar diferenças entre as respostas em frequência estimadas e as respostas em frequência do modelo real do MPC. Apesar de identificar a presença de MPM, a metodologia requer testes em linha, o que o torna intrusivo ao processo.

Baseado no princípio da retroalimentação invariante, isto é, que inovações dos distúrbios não são afetadas pela retroalimentação, SUN et al. (2013) desenvolveram um método para se avaliar a qualidade do modelo utilizado no MPC através da estimação do erro do distúrbio estocástico com os dados de *setpoint* e saídas medidas do processo. Em seguida, de posse teste erro estimado e do erro de predição (resíduo entre a saída predita pelo modelo e a saída real da planta), um indicador de performance normalizado indica que o problema se origina de distúrbios não medidos e o modelo, portanto, é adequado. Apesar do método distinguir entre MPMP e UD, sua desvantagem é não ser capaz de identificar quais componentes específicos do modelo, isto é, os canais (combinação do par CV-MV), que possuam MPM.

Analogamente a ideia de um indicador de variabilidade, introduzida por BADWE et al. (2010), BOTELHO et al. (2015) propuseram uma metodologia para quantificar a discrepância entre a dinâmica da planta e o modelo do controlador pelo cálculo do indicador de variância relativa, que relaciona dados rotineiros de operação da planta a dados estimados para o caso nominal, no qual considera-se uma malha fechada livre de qualquer erro de modelagem que afete o desempenho do controlador. Assim, a metodologia possui uma base para se avaliar o quão “longe” a planta real está do caso nominal e quantificar a magnitude desta “distância”. Para isso, a saída nominal do sistema em malha fechada, y_N , pode ser calculada através da função de sensibilidade nominal, S_N (como na equação (2.6) para uma malha fechada sem MPM ou UD):

$$y_N = S_N(y_{sim} - y) + y \quad (3.1)$$

onde y_{sim} é a saída simulada do modelo nominal perturbado pela matriz das ações de controle e y é a matriz de saídas medidas da planta. Para identificar as variáveis controladas que possuem problemas de modelagem, utiliza-se o indicador de variância relativa, I_{var} , que relaciona a variância das variáveis medidas na saída, y , com aquela da saída estimada para o caso nominal em malha fechada, y_N , em relação ao valor de referência (*setpoint*), y_{set} , no período em que os dados foram analisados:

$$I_{var} = var(y - y_{set})/var(y_N - y_{set}) \quad (3.2)$$

A função de sensibilidade indica a capacidade de atenuação de distúrbios da malha fechada. Assim, além dos distúrbios não-medidos propriamente ditos, que estão presentes num processo real, uma discrepância de modelo também pode ser vista como um distúrbio, visto que esta discrepância é desconhecida e gera, conseqüentemente, uma degradação do desempenho da malha fechada. Dessa forma, a função de sensibilidade para a malha nominal é capaz de fornecer um diagnóstico de como o MPM contido em uma saída afeta as demais saídas. Além disso, também é desejável se obter um diagnóstico sobre o efeito das incertezas no modelo apenas nas saídas correspondentes (i.e., sem levar em conta o efeito de interação). Neste caso, a análise é realizada considerando apenas os elementos diagonais de S_N . Assim, as saídas nominais do controlador calculadas apenas com base nos elementos diagonais de S_N (denominado $S_{N\,diag}$) são:

$$y_{N\,diag} = S_{N\,diag}(y_{sim} - y) + y \quad (3.3)$$

A função de sensibilidade nominal diagonal, $S_{N\,diag}$, funciona como um filtro para os resíduos de simulação e é capaz de reter somente a parte deste resíduo que não é compensada pela retroalimentação do controlador. Analogamente, o indicador I_{var} calculado com base em $y_{N\,diag}$ é chamado indicador de variância diagonal, $I_{var\,diag}$, e dado por:

$$I_{var\,diag} = var(y - y_{set})/var(y_{N\,diag} - y_{set}) \quad (3.4)$$

Nas Equações (3.2) e (3.4), pode-se utilizar o valor médio de cada saída, \bar{y} , ao invés do sinal de referência, y_{set} , para o caso em que o MPC trabalha por faixas.

O indicador I_{var} pode ser utilizado quando se busca identificar o impacto do problema de modelagem na saída y devido a um problema nas demais saídas e o indicador $I_{var\,diag}$ quando se deseja avaliar apenas o problema de modelagem na própria saída. Ademais, uma variável deve ser considerada como não impactante na degradação de desempenho do controlador avaliado caso os indicadores de variância I_{var} e $I_{var\,diag}$ forem homogêneos, ou seja, quando não houver uma diferença significativa entre as variâncias das saídas medida e nominal do controlador.

Na auditoria do controlador, a avaliação dos indicadores I_{var} e $I_{var\,diag}$ para determinar se a variância da saída medida é diferente da saída nominal/nominal diagonal do controlador em malha fechada, pode ser realizada através de um teste de hipóteses. Este teste visa comparar, para dadas duas amostras de um conjunto de populações, a hipótese nula, H_0 , que afirma que as variâncias das n_p populações são homogêneas,

contra a hipótese alternativa, H_1 , que afirma que pelo menos uma variância populacional é diferente das demais (LIM; LOH, 1996):

$$H_0: \sigma_1^2 = \sigma_2^2 = \dots = \sigma_{n_p}^2 \quad (3.5)$$

$$H_1: \exists_{i,j}: \sigma_i^2 \neq \sigma_j^2 \quad (i = 1, \dots, n_p; j = 1, \dots, K_1)$$

onde σ_i^2 o desvio padrão da população i .

O teste de homogeneidade de variâncias chamado F de Levene, de acordo com LIM; LOH (1996), é considerado mais robusto a desvios da normalidade nas amostras utilizadas. A estatística utiliza o teste F baseado na observação j na amostra i definida como $z_{ij} = |x_{ij} - \tilde{x}_i|$, onde \tilde{x}_i é a mediana de $\{x_{ij}: j = 1, \dots, n_p\}$ com graus de liberdade $\nu_1 = n_p - 1$ e $\nu_2 = N_k - n_p$, sendo N_k a dimensão da amostra global ($N_k = K_1 + K_2 + \dots + K_{n_p}$) tal que

$$L = \frac{\sum_{i=1}^{n_p} K_i (\bar{z}_i - \bar{z}_{..})^2 / \nu_1}{\sum_{i=1}^{n_p} \sum_{j=1}^{K_i} (z_{ij} - \bar{z}_i)^2 / \nu_2} \quad (3.6)$$

$$\bar{z}_i = \sum_{j=1}^{K_i} z_{ij} / K_i$$

$$\bar{z}_{..} = \sum_{i=1}^{n_p} \sum_{j=1}^{K_i} z_{ij} / N_k$$

onde \bar{z}_i é a média de z_{ij} na amostra i e $\bar{z}_{..}$ é a media de z_{ij} na amostra global. A hipótese nula é aceita quando o p - value (probabilidade associada à estatística L) for superior ao limite de significância α , conforme a tabela de distribuição F de Fisher-Snedecor. Quando o p - value for inferior a α , rejeita-se a hipótese nula com um nível $100(1 - \alpha)$ de confiança, isto é, as variâncias não são iguais.

O fluxograma exposto na Figura 3.1 mostra o passo-a-passo de como se realizar a auditoria para cada variável controlada y do sistema.

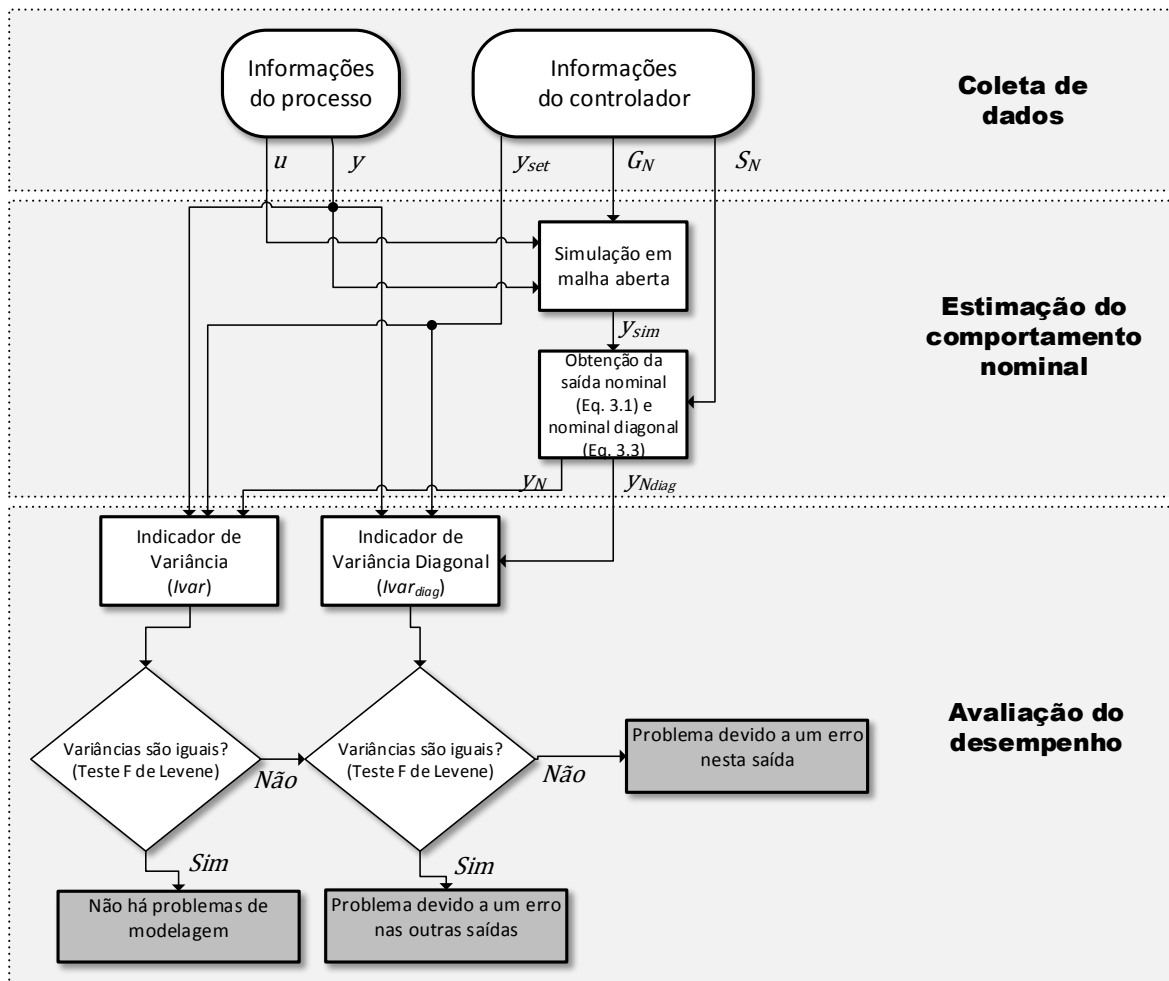


Figura 3.1: Fluxograma do passo-a-passo da etapa de auditoria de controladores preditivos

O método proposto por BOTELHO et al. (2015) é independente de variações de *setpoint*, ao contrário do método de BADWE et al. (2010), que requer padrões específicos de distúrbios e excitação de *setpoints*. Isto porque a saída nominal y_N pode ser determinada a partir da função nominal de sensibilidade, das saídas simuladas do controlador e das variáveis medidas na saída da planta real, que podem ser extraídas de dados rotineiros de operação em malha fechada. Entretanto, devido à complexidade da formulação do MPC, o modelo do controlador, necessário para obtenção da função de sensibilidade, não é explicitamente conhecido (assim como ocorre com estratégias clássicas de controle). Neste caso, torna-se conveniente obter a função de sensibilidade nominal complementar T_N , sendo $S_N = I - T_N$, simulando-se o sistema em malha fechada sem erro de modelagem. Para maiores detalhes sobre a estimação da função de sensibilidade, ver Botelho (2015).

Para obter um diagnóstico completo do controlador e indicar a fonte dominante da degradação de desempenho, BOTELHO; TRIERWEILER; FARENZENA (2016) desenvolveram uma extensão do método, na qual é feita uma comparação entre a saída nominal diagonal, y_{Ndiag} , e o correspondente erro nominal, e_{Ndiag} , ambos calculados com base nos elementos diagonais da função de sensibilidade, para capturar os efeitos dos erros de modelagem desconsiderando-se os efeitos de interações entre canais. O erro nominal do controlador, que representa o efeito dos problemas de modelagem em malha fechada, é dado por:

$$e_N = y_N - y = S_N(y_{sim} - y) \quad (3.7)$$

Analogamente, utilizando-se apenas os elementos diagonais da função de sensibilidade, chega-se ao erro nominal diagonal $e_{N\,diag}$, dado por:

$$e_{N\,diag} = y_{N\,diag} - y = S_{N\,diag}(y_{sim} - y) \quad (3.8)$$

A análise entre $y_{N\,diag}$ e $e_{N\,diag}$ é feita por uma comparação utilizando duas medidas estatísticas, assimetria (skn) e curtose (kts), que caracterizam a forma da distribuição dos elementos da amostra em torno da média. A assimetria é utilizada para se caracterizar a falta de simetria dos dados da distribuição em torno da média, enquanto a curtose busca indicar o grau de achatamento da distribuição de frequências, isto é, altura do pico da curva, em relação a uma distribuição teórica, geralmente sendo a distribuição normal. Assim, temos:

$$skn = K^{-1} \sum_{i=1}^K (Z_i - \bar{Z})^3 / \left(\sqrt{K^{-1} \sum_{i=1}^K (Z_i - \bar{Z})^2} \right)^3 \quad (3.9)$$

$$kts = K^{-1} \sum_{i=1}^K (Z_i - \bar{Z})^4 / \left(K^{-1} \sum_{i=1}^K (Z_i - \bar{Z})^2 \right)^2 \quad (3.10)$$

onde Z é a distribuição para qual as estatísticas de assimetria e curtose serão computadas, ou seja, $y_{N\,diag}$ e $e_{N\,diag}$, e K é o número de elementos da amostra de distribuição.

Para se comparar $y_{N\,diag}$ e $e_{N\,diag}$ e obter a tendência das distribuições dos dados, utiliza-se as derivadas das estatísticas de assimetria e curtose das amostras de interesse ao longo de janelas móveis, que visam garantir que todos os comportamentos dinâmicos que afetam efetivamente o controlador sejam capturados:

$$dskn_{e_{N\,diag}}^{MW} = \frac{d(sk n_{e_{N\,diag}}^{MW})}{dt} \quad (3.11)$$

$$dskn_{y_{N\,diag}}^{MW} = \frac{d(sk n_{y_{N\,diag}}^{MW})}{dt} \quad (3.12)$$

$$dkts_{e_{N\,diag}}^{MW} = \frac{d(kts_{e_{N\,diag}}^{MW})}{dt} \quad (3.13)$$

$$dkts_{y_{Ndiag}}^{MW} = \frac{d(kts_{y_{Ndiag}}^{MW})}{dt} \quad (3.14)$$

onde $skn_{e_{Ndiag}}^{MW}$ e $skn_{y_{Ndiag}}^{MW}$ são as medidas estatísticas de assimetria para as distribuições e_{Ndiag} e y_{Ndiag} para a janela móvel de tamanho MW enquanto que $kts_{e_{Ndiag}}^{MW}$ e $kts_{y_{Ndiag}}^{MW}$ são as medidas estatísticas de curtose para as distribuições e_{Ndiag} e y_{Ndiag} para a janela móvel de tamanho MW . Para o tamanho da janela móvel, os autores sugerem entre $0.5ph$ a $2ph$, sendo ph o tamanho do horizonte de previsão do controlador MPC, o que garante que sejam capturadas apenas as inconsistências na frequência de trabalho do controlador analisado.

Para cada tamanho de janela móvel, MW , utiliza-se a correlação de Pearson para avaliar a correlação entre as distribuições estatísticas de e_{Ndiag} e y_{Ndiag} , tal que:

$$c_Z^{MW} = cov(Z_{e_{Ndiag}}^{MW}, Z_{y_{Ndiag}}^{MW}) / \sqrt{var(Z_{e_{Ndiag}}^{MW}) \cdot var(Z_{y_{Ndiag}}^{MW})} \quad (3.15)$$

onde cov representa a covariância entre os sinais correspondentes, Z é a medida estatística avaliada para a distribuição ($dkts$ ou $dskn$) e c_Z^{MW} é o coeficiente de correlação correspondente à distribuição estatística de Z para um tamanho de janela móvel MW . Por fim, para se avaliar todos os coeficiente obtidos para os diferentes tamanhos de janelas móveis, avalia-se o valor médio, \bar{c}_Z , dos coeficiente de correlação:

$$\bar{c}_Z = \sum_{MW=0.5ph}^{2ph} |c_Z^{MW}| / N_{MW} \quad (3.16)$$

onde N_{MW} é o número de janelas móveis avaliadas.

Para se distinguir a fonte predominante do problema de modelagem, utiliza-se uma estimativa do intervalo de confiança da correlação, CI , definida como:

$$CI = ZC_{\alpha/2} \sigma(\bar{c}_Z) / \sqrt{K} \quad (3.17)$$

onde $ZC_{\alpha/2}$ é o valor crítico de uma variável aleatória de distribuição normal ao nível de significância α , $\sigma(\bar{c}_Z)$ é o desvio padrão do coeficiente médio de correlação \bar{c}_Z e K é o número de dados da amostra. Se o coeficiente médio de correlação \bar{c}_Z baseado em pelo menos uma das estatísticas apresente um valor superior a CI , conclui-se que a correlação entre e_{Ndiag} e y_{Ndiag} é significativa, o que por sua vez indica que o desempenho do controlador está sendo afetado predominantemente por discrepâncias entre modelo e planta. Caso contrário, a fonte predominante da degradação do desempenho é a presença de distúrbio não medidos. O fluxograma exposto na Figura 3.2 mostra o passo-a-passo de como se realizar a diagnóstico para cada variável controlada y do sistema.

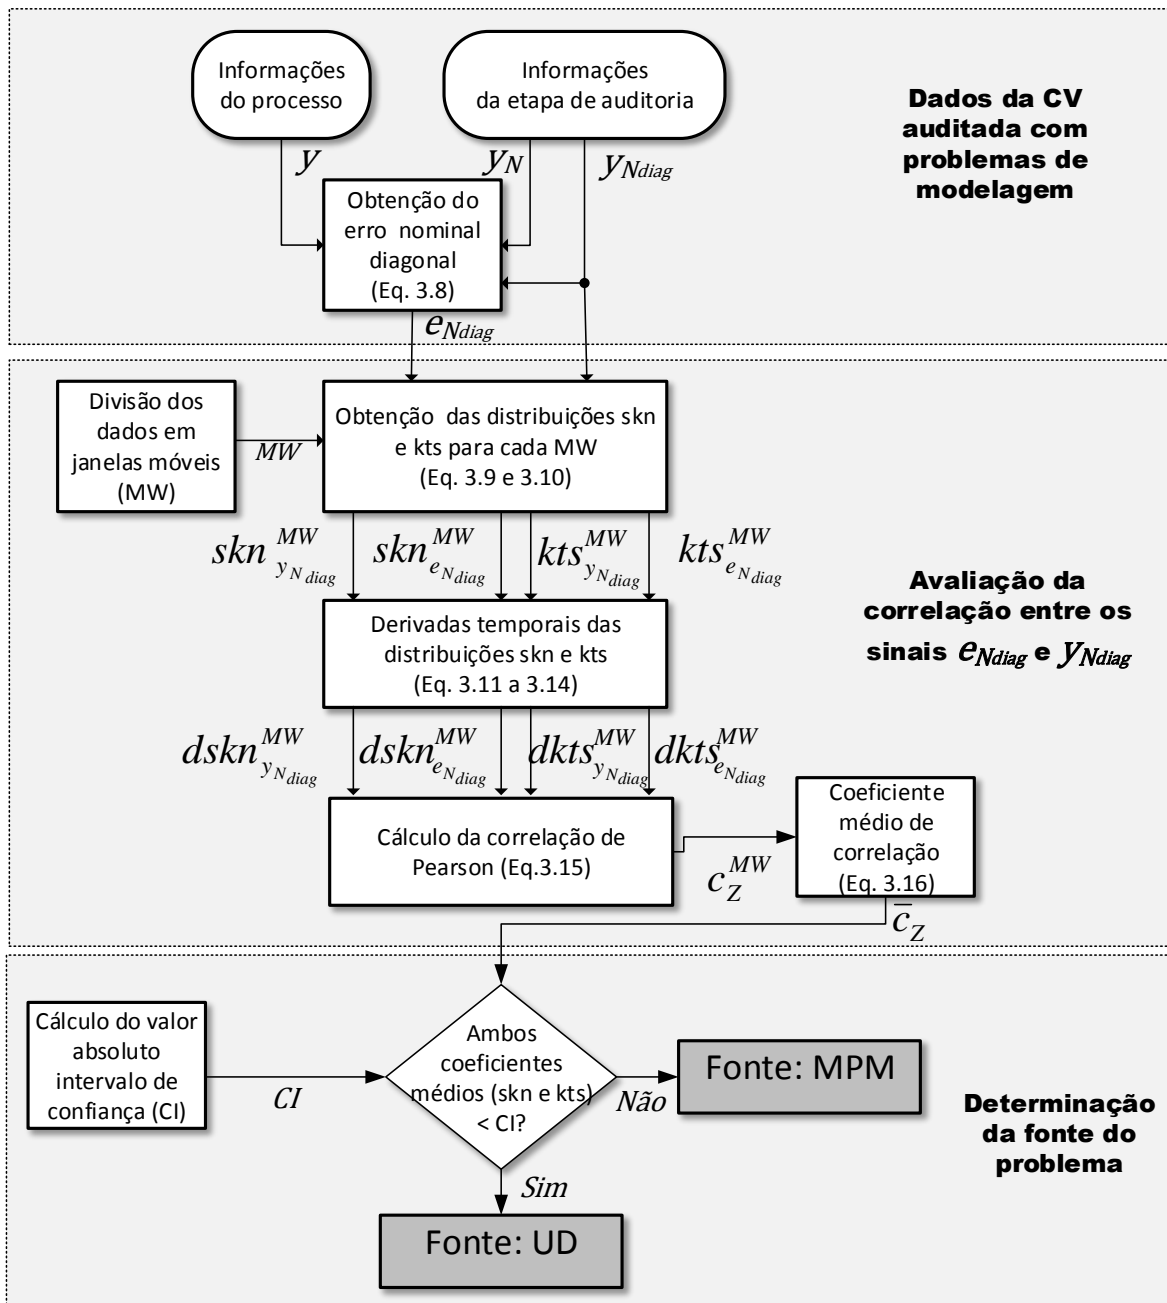


Figura 3.2: Fluxograma do passo-a-passo da etapa de diagnóstico de controladores preditivos

3.2 Localização dos Canais com Discrepância Modelo-Planta

Ainda que as metodologias descritas na seção anterior sejam capazes de indicar as variáveis controladas com problemas de modelagem bem como a distinguir entre MPM e distúrbio, o ideal é que, sendo detectada a presença de um MPM, existam técnicas capazes de apontar os canais (isto é, pares CV x MV) que precisam ser efetivamente reidentificados. Neste contexto, JIANG; LI; SHAH (2006) desenvolveram um método para detectar e isolar a discrepância entre modelo e planta para sistemas multivariáveis que

utiliza o modelo na representação de espaços de estados. A técnica visa identificar quais elementos das matrizes do espaço de estados devem ser reidentificados para se corrigir desvios do caso nominal através de três índices que detectam quais elementos possuem MPM. De maneira similar, o trabalho de WEBBER; GUPTA (2008) estendeu o conceito de encontrar correlações entre resíduos do modelo e as variáveis manipuladas para sistemas MIMO de modo a se identificar qual elemento da matriz de transferência possui MPM significativa.

Analogamente ao trabalho desenvolvido por WEBBER; GUPTA (2008), BADWE et al. (2009) desenvolveram uma metodologia para se identificar o submodelo CV-MV do modelo do MPC que possua uma discrepância significativa com a planta pela análise da correlação entre as variáveis manipuladas e os resíduos do modelo. Devido à característica dinâmica das variáveis de processo, o método utiliza uma análise de correlação parcial dinâmica para eliminar o efeito das demais variáveis manipuladas na análise da correlação.

KANO et al. (2010) propuseram utilizar dados rotineiros de operação em malha fechada em conjunto com a análise estatística pelo método *stepwise*, de modo a se selecionar variáveis explanatórias significativas, isto é, entradas passadas que contribuem fortemente para cada resíduo dos submodelos da matriz de transferência. Se um número grande de dados passados é selecionado, pode-se inferir que o submodelo correspondente possui discrepância significativa com a planta.

SELVANATHAN; TANGIRALA (2010) propuseram uma abordagem para diagnosticar malhas de controle pelo uso de um novo conceito, chamado razão entre planta e modelo (*Plant Model Ratio*, ou PMR), como uma medida, no domínio da frequência, para quantificar a discrepância entre modelo e planta. Os autores mostram que, para cada tipo de discrepância nos modelos, isto é, ganho, constante de tempo e tempo morto, existe uma assinatura única do PMR, o que possibilita indicar, no submodelo com MPM, a fonte da discrepância. YERRAMILLI; TANGIRALA (2016), por sua vez, estenderam o conceito de PMR para sistemas MIMO. Com o uso de densidade espectrais parciais para desacoplar as interações de diferentes frequências provenientes da excitação do sinal de *setpoint*, os conceitos de PMR são então utilizados para detectar os canais saída-entrada que contenham MPM bem como a fonte da discrepância dentro destes canais, isto é, se a discrepância é proveniente do ganho, dinâmica ou tempo morto.

Baseando-se na metodologia de BOTELHO et al. (2015) para diagnóstico de desempenho de controladores MPC, CLARO (2016) desenvolveu um proposta para se isolar o submodelo CV-MV do modelo do MPC previamente diagnosticado com MPM como sendo o problema de modelagem predominante.

A discrepância de modelo da variável de saída é fornecida pelo erro nominal do controlador, e_N , definido pela Equação (3.7). Para encontrar a contribuição de cada canal na discrepância entre modelo e planta. O método proposto por CLARO (2016) é baseado na análise da relação entre o erro nominal e uma estimativa da contribuição de cada canal na saída total da planta.

Para um controlador preditivo do tipo GPC, a estimativa da contribuição de cada canal na saída do controlador pode ser obtida pela aplicação da função de transferência de cada canal às variáveis de entrada do controlador:

$$\hat{y}_{p_{i,j}} = g_{i,j}\check{u}_j \quad (3.18)$$

onde os índices i e j indicam, respectivamente, às variáveis de entrada e de saída do controlador., $\hat{y}_{p_{i,j}}$ é a estimativa da parcela de contribuição do canal ($y_i \rightarrow u_j$) na saída y_i obtida com o modelo do canal, $g_{i,j}$, aplicado ao vetor de entradas descontado de um bias fixo, correspondente ao valor do instante inicial coletado ou à média dos valores da janela de dados empregada:

$$\check{u}(t) = u(t) - u(0) \quad (3.19)$$

Para se analisar a correlação existente entre o erro nominal do controlador e a estimativa da contribuição de cada canal, esta deve conter apenas a parcela da saída da planta que não é atenuada pelo controlador, isto é, deve-se isolar a parte que efetivamente está afetando o desempenho. Conforme a metodologia de BOTELHO et al. (2015) e BOTELHO; TRIERWEILER; FARENZENA (2016), explanada na seção 3.1, isto pode ser obtido ao se filtrar as saídas medidas pela função de sensibilidade. Para isso, filtra-se a estimativa da parcela de contribuição da saída analisada, \hat{y}_p , com o modelo $S_{N_{i,i}}$ correspondente ao elemento diagonal da função de sensibilidade nominal para a variável controlada y_i , obtendo-se então a saída parcial filtrada \hat{y}_{pf} :

$$\hat{y}_{pf_{i,j}} = S_{N_{i,i}}\hat{y}_{p_{i,j}} = S_{N_{i,i}}g_{i,j}\check{u}_j \quad (3.20)$$

A saída parcial filtrada, \hat{y}_{pf} , também pode ser obtida para modelos nulos na matriz dinâmica do controlador. Esta análise é útil para verificar a inclusão de variáveis manipuladas que não estão incluídas no modelo original (portanto sua contribuição no modelo é nula). Neste caso, utiliza-se apenas o filtro $S_{N_{i,i}}$ na Equação (3.20).

Além disso, analogamente à identificação do canal com MPM, pode-se utilizar a mesma abordagem para se avaliar a influência de uma variável externa, como um distúrbio medido, no desempenho do controlador:

$$\hat{y}_{pf}(i, n_{MV} + 1) = S_{N_{i,i}}\check{F}_{ex}, \quad \check{F}_{ex} = \check{u}(n_{MV} + 1) \quad (3.21)$$

Onde n_{MV} é o número de variáveis manipuladas e \check{F}_{ex} é a variável externa, que é dada como uma entrada adicional no controlador e que recebe o mesmo tratamento daquele da Equação (3.19).

Para se identificar se o canal contém erro de modelo, deve-se então analisar a relação existente entre o erro nominal do controlador, e_N , que indica a variável controlada com problemas de modelagem, e a saída parcial filtrada, \hat{y}_{pf} , que indica a variável manipulada com problemas de modelagem. O método utilizado para essa comparação é a análise da correlação cruzada, que mostra uma possível relação causa entre dois sinais e permite comparar uma causa com um efeito defasado no tempo, como é o caso de variáveis controladas e manipuladas em uma malha de controle.

A estimativa da correlação cruzada entre as séries temporais \hat{y}_{pf} e e_N defasadas por λ intervalos de tempo pode ser obtida como:

$$XCF_{\hat{y}_{pf},e_N}(\lambda) = c_{\hat{y}_{pf},e_N}(\lambda) / s_{\hat{y}_{pf},e_N}, \quad \lambda = 0, \pm 1, \pm 2, \dots \quad (3.22)$$

onde $c_{\hat{y}_{pf},e_N}(\lambda)$ corresponde à estimativa do coeficiente de covariância cruzada para cada valor de defasagem λ , computada para amostras das séries temporais.

Para se estimar o intervalo de confiança para a correlação cruzada $XCF_{\hat{y}_{pf},e_N}$, Claro (2016) sugere a estatística ζ de Fisher:

$$\begin{aligned} \zeta &= \frac{1}{2} \ln \left(\frac{1 + XCF_{\hat{y}_{pf},e_N}}{1 - XCF_{\hat{y}_{pf},e_N}} \right) \\ &= \tanh^{-1}(XCF_{\hat{y}_{pf},e_N}) \sim N \left(\tanh^{-1}(XCF'_{\hat{y}_{pf},e_N}), \frac{1}{K-3} \right) \end{aligned} \quad (3.23)$$

onde $XCF'_{\hat{y}_{pf},e_N}$ é o coeficiente de correlação verdadeiro, porém desconhecido, e K é o número de dados nas amostras de \hat{y}_{pf} e e_N . Para se obter o intervalo de confiança para $XCF'_{\hat{y}_{pf},e_N}$, como nível de confiança α , resolve-se a equação:

$$\begin{aligned} \frac{1}{2} \ln \left(\frac{1 + XCF_{\hat{y}_{pf},e_N}}{1 - XCF_{\hat{y}_{pf},e_N}} \right) \pm z \left(1 - \frac{\alpha}{2} \right) \left\{ \frac{1}{K-3} \right\}^{1/2} \\ = \frac{1}{2} \ln \left(\frac{1 + XCF'_{\hat{y}_{pf},e_N}}{1 - XCF'_{\hat{y}_{pf},e_N}} \right) \end{aligned} \quad (3.24)$$

onde $z \left(1 - \frac{\alpha}{2} \right)$ é o valor crítico de uma distribuição normal padrão para o nível de significância α . Ademais, pode-se testar a hipótese nula $H_0: XCF'_{\hat{y}_{pf},e_N} = 0$, contra a hipótese alternativa $H_1: XCF'_{\hat{y}_{pf},e_N} \neq 0$ através de um teste z bicaudal, calculado por:

$$\begin{aligned} z_{cal} &= \sqrt{K-3} \left\{ \frac{1}{2} \ln \left(\frac{1 + XCF_{\hat{y}_{pf},e_N}}{1 - XCF_{\hat{y}_{pf},e_N}} \right) - \frac{1}{2} \ln \left(\frac{1+0}{1-0} \right) \right\} \\ &= \frac{\sqrt{K-3}}{2} \ln \left(\frac{1 + XCF'_{\hat{y}_{pf},e_N}}{1 - XCF'_{\hat{y}_{pf},e_N}} \right) \end{aligned} \quad (3.25)$$

sendo que o valor da estatística z deve ser comparado com o valor crítico referente ao nível de significância α desejado. A hipótese nula deve ser rejeitada se:

$$|z_{cal}| \geq \left| z \left(1 - \frac{\alpha}{2} \right) \right| \quad (3.26)$$

Com o cálculo do intervalo de confiança (ou com a rejeição da hipótese nula), pode-se obter a correlação cruzada $XCF_{\hat{y}_{pf}(i,j),e_N(i)}(\lambda)$ para cada canal e definir o Indicador de Discrepância Modelo (*Model Discrepancy Indicator*, ou MDI) como o valor máximo do módulo da correlação cruzada encontrado para todos os intervalos de defasagem utilizados na análise:

$$MDI_{i,j} = \max \left(\left| XCF_{\hat{y}_{pf}(i,j),e_N(i)}(\lambda) \right| \right) \quad (3.27)$$

onde $MDI_{i,j}$ é o indicador de discrepância modelo para o canal do par $(y_i \rightarrow u_j)$ e \max corresponde ao valor máximo obtido para o módulo da correlação cruzada encontrado

para todos os intervalos de defasagem λ utilizados na análise entre \hat{y}_{pf} e e_N que estão dentro do intervalo de confiança encontrado. De modo a se analisar a correlação cruzada para os diferentes canais analisados, o Indicador de Discrepância Modelo Normalizado (*Normalized Model Discrepancy Indicator*, ou *NMDI*) é definido como:

$$NMDI_{i,j|i} = \frac{(MDI_{i,j|i} - \min(NMDI_{i,j|i}))}{(\max(MDI_{i,j|i}) - \min(NMDI_{i,j|i}))} \quad (3.28)$$

onde $\max(MDI_{i,j|i})$ e $\min(NMDI_{i,j|i})$ correspondem, respectivamente, ao valores máximo e mínimo da correlação obtida para uma mesma variável controlada y_i .

Assim, a análise dos resultados, através do valor do indicador *NMDI*, fornece uma priorização relativa de cada canal em relação ao erro de modelagem para a variável de saída. Logo, o pior modelo corresponde ao canal com valor de *NMDI* unitário, diminuindo, portanto, conforme decresce a contribuição de cada canal no erro de modelagem, chegando a zero para o canal menos correlacionado ao problema de modelagem. O fluxograma exposto na Figura 3.3 mostra o passo-a-passo de como se diagnosticar o canal mais discrepante para cada variável controlada y do sistema.

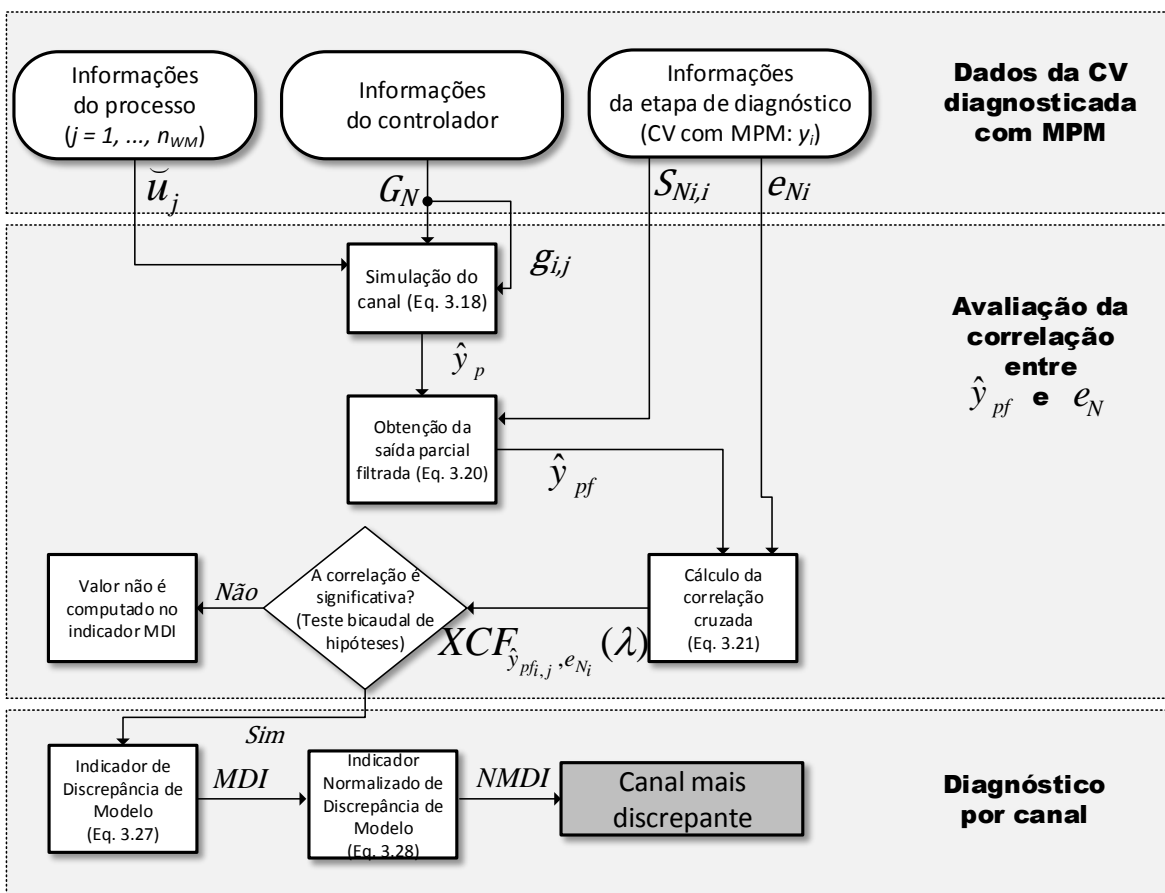


Figura 3.3: Fluxograma do passo-a-passo da etapa de diagnóstico dos canais mais discrepantes do modelo utilizado no controlador

Capítulo 4 – Metodologia

Neste capítulo é proposta uma metodologia para a identificação em malha fechada de canais da matriz dinâmica do controlador. A auditoria dos erros de modelagem presentes no controlador, bem como o diagnóstico dos canais que possuem discrepância entre modelo e planta, ambos descritos no Capítulo 3, são pré-requisitos para a aplicação do método.

A metodologia desenvolvida contempla dois métodos distintos que podem ser utilizados separadamente ou sequencialmente e empregam dados históricos do processo em malha fechada.

O primeiro, denominado método direto compensado, tem como base o método direto de identificação em malha fechada, explanado na seção 2.1.1, e contempla a identificação, para uma dada saída do processo, do canal da matriz dinâmica do modelo que mais afeta o desempenho do controlador, utilizando uma saída medida compensada de modo a se reter apenas a contribuição do canal que se deseja identificar.

O segundo, chamado método do erro nominal, é baseado na definição de saída nominal do processo, explanada na seção 3.1. Por ser uma saída simulada para malha fechada sem erro de modelo ou distúrbio não medido, ela serve como métrica para se quantificar o quão próximo o modelo está do comportamento da planta real. Assim, o método propõe minimizar o erro nominal, isto é, a diferença entre a saída nominal e a saída medida, para se identificar os canais diagnosticados como mais discrepantes na matriz dinâmica completa usada no controlador.

4.1 Método Direto Compensado de Identificação em Malha Fechada

Uma matriz de transferência de dimensão $[n_{CV} \times n_{MV}]$ é composta pela associação dos canais (combinação do par saída e entrada) do modelo, onde cada coluna dessa matriz (n_{CV}), que representa as entradas u , irá interferir de forma diferente nas saída y ,

ou linhas da matriz (n_{MV}). Assim, a representação matricial do cálculo das saídas para modelo lineares é:

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_{n_{CV}} \end{bmatrix} = \begin{bmatrix} g_{1,1}(z) & g_{1,2}(z) & \cdots & g_{1,n_{MV}}(z) \\ g_{2,1}(z) & g_{2,2}(z) & \cdots & g_{2,n_{MV}}(z) \\ \vdots & \vdots & \ddots & \vdots \\ g_{n_{CV},1}(z) & g_{n_{CV},2}(z) & \cdots & g_{n_{CV},n_{MV}}(z) \end{bmatrix} \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_{n_{MV}} \end{bmatrix} \quad (4.1)$$

$$y = G(z)u$$

onde $y = [y_1 \ y_2 \ \cdots \ y_{n_{CV}}]^T$ é a matriz de saídas medidas de dimensão $[n_{CV} \times 1]$, $u = [u_1 \ u_2 \ \cdots \ u_{n_{MV}}]^T$ é a matriz de entradas medidas de dimensão $[n_{MV} \times 1]$, e $G(z)$ é a matriz de transferência, no domínio discreto, de dimensão $n_{CV} \times n_{MV}$. Pelo princípio da superposição para sistemas lineares, cada saída pode ser obtida individualmente como:

$$y_i = \sum_{j=1}^{n_{MV}} g_{i,j} u_j \quad (4.2)$$

onde i representa a saída (CV) e j representa a entrada (MV).

Para se computar cada saída y_i , o controlador utiliza n_{MV} funções de transferência dos canais e as n_{MV} entradas correspondentes. As técnicas de identificação clássicas (no sentido de já serem bem estabelecidas e recorrentes) em malha fechada disponíveis, expostas no Capítulo 2, requerem dados de processo para estimar os parâmetros de uma estrutura pré-selecionada de modelo (ex. ARX). Com o método direto, por exemplo, uma identificação MIMO pode ser realizada utilizando-se os vetores de entrada e saída, respectivamente $U_{n_{CV} \times K}$ e $Y_{n_{MV} \times K}$, onde K é o número de pontos coletados. Assim, a identificação pondera a importância de cada canal e identifica simultaneamente, para cada conjunto de dados $\{u_j, y_i\}$, todas as funções de transferência $g_{i,j}$ que compõem a saída y_i . Para a saída y_1 , por exemplo, o conjunto de dados $\{u_1, y_1\}$ é utilizado para se identificar as n_{MV} funções de transferências de cada canal, ou seja, $g_{1,1}, g_{1,2}, \dots, g_{1,n_{MV}}$.

Como modelos MIMO possuem uma estrutura interna complexa, a estimação simultânea de todos os parâmetros das funções de transferência dos canais não é uma tarefa trivial e resulta na necessidade de se ponderar porções dos sinais utilizados na identificação para estimar cada canal. Entretanto, com o conhecimento exato do canal mais discrepante com a planta, pode-se identificar diretamente apenas aquele canal, não necessitando despendar tempo e esforço na identificação de canais cujos modelos apresentam desempenho satisfatório. A etapa de diagnóstico por canal, que utiliza o indicador $NMDI$, Equação (3.28), fornece um resultado que indica a priorização relativa de cada canal em relação ao erro de modelagem para a variável de saída. Em outras palavras, o pior modelo corresponde ao canal com valor de $NMDI$ unitário, valor este que diminui conforme decresce a contribuição de cada canal no erro de modelagem. Assim, sempre haverá apenas um canal sendo indicado como o mais discrepante e é possível considerar o desempenho dos canais que possuam $NMDI$ diferente da unidade como possuindo um modelo relativamente adequado.

Logo, utilizando a notação i e w para representar, respectivamente, a CV e a MV do canal mais discrepante, o sinal da saída medida da planta pode ser compensado de forma a se isolar apenas a parcela correspondente ao canal que se deseja identificar:

$$y_{i,w} \cong y_i - \sum_{\substack{j=1 \\ j \neq w}}^{n_{MV}} g_{N_{i,j}} u_j \quad (4.3)$$

sendo $y_{i,w}$ é o sinal compensado da saída analisada, correspondente ao canal que cujo modelo é o mais discrepante ($NMDI = 1$), y_i é a saída medida da planta, $g_{N_{i,j}}, j \neq w$, é o modelo dos canais que possuam $NMDI \neq 1$ e u_j é o sinal de entrada da MV correspondente a estes canais.

O sinal obtido $y_{i,w}$, conseqüentemente, pode ser utilizado como sinal de saída em uma identificação SISO. Como a metodologia de diagnóstico por canal já determina qual MV está mais correlacionada com o erro de modelagem, ou seja, u_w , este sinal, por sua vez, pode ser utilizado como sinal de entrada na identificação. A Figura 4.1 apresenta um diagrama para o cálculo do sinal de saída compensado, no qual as linhas contínuas representam o fluxo dos sinais utilizados, enquanto as linhas tracejadas o fluxo de informações proveniente das etapas anteriores de diagnóstico.

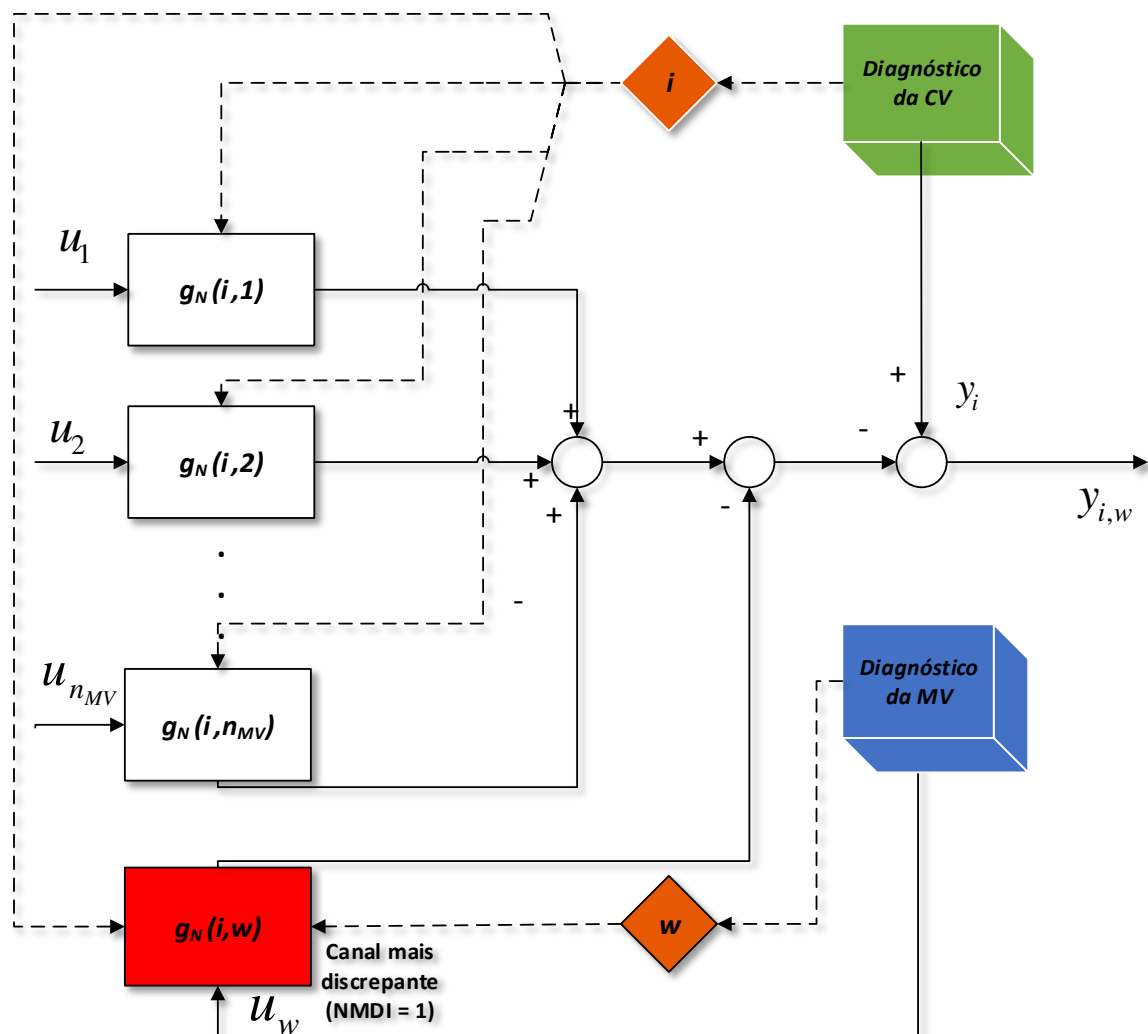


Figura 4.1: Diagrama esquemático do processo de compensação do sinal de saída

Para se identificar efetivamente o modelo do canal discrepante, utiliza-se o método do erro de predição em conjunto com o método direto, descritos no Apêndice A e seção 2.1.1, respectivamente. Para isso, assume-se que a estrutura do modelo para cada um dos canais a serem identificados é dada por:

$$y_{i,w}(t) = g_{i,w}(q, \theta)u_w(t) + h_{i,w}(q, \theta)e(t) \quad (4.4)$$

onde g é o modelo da parte determinística do processo (que será utilizada como modelo final no controlador) e h o modelo da parte estocástica (que auxilia na alocação de polos e zeros de g para se levar em conta a presença de distúrbios). O vetor de parâmetros γ pertence a um conjunto assumido compacto e conectado.

A predição um passo à frente, para a estrutura de modelo indicada pela Equação (4.4), é dada por:

$$\hat{y}_{i,w}(t|\theta) = \frac{g_{i,w}(q, \theta)}{h_{i,w}(q, \theta)}u_w(t) + \left(1 - \frac{1}{h_{i,w}(q, \theta)}\right)y_{i,w}(t) \quad (4.5)$$

onde $\hat{y}_{i,w}(t|\theta)$ é a predição um passo à frente para a saída do canal discrepante.

Assim, para se estimar os parâmetros do modelo, minimiza-se o erro de predição entre a saída compensada do canal $y_{i,w}$ com a predição um passo à frente, $\hat{y}_{i,w}$, tal que:

$$\hat{\theta}_K = \arg \min_{\theta} V_K(\theta, Z^K) \quad (4.6)$$

$$V_K(\theta, Z^K) = \frac{1}{K} \sum_{t=1}^K \varepsilon^T(t, \theta) \varepsilon(t, \theta) \quad (4.7)$$

$$\varepsilon(t, \theta) = y_{i,w}(t) - \hat{y}_{i,w}(t|\theta) \quad (4.8)$$

onde Z^K é o conjunto de dados históricos de entrada e saída do processo, $\varepsilon(t, \theta)$ é o erro de predição.

4.2 Método do erro nominal

Por definição, o erro nominal, discutido na seção 3.1, é o resíduo entre a saída medida do processo e a saída nominal simulada da malha fechada, isto é, a saída do processo no caso onde não há discrepância entre modelo e planta nem distúrbio não medido. Devido à forma como o erro é formulado, o sinal resultante consegue reter apenas a parte da saída do processo que contém efetivamente a discrepância de modelo. Considere os erros nominal e nominal diagonal, definidos pelos conceitos de saída nominal e nominal diagonal descritos na seção 3.1:

$$e_N = y_N - y = S_N(y_{sim} - y) \quad (4.9)$$

$$e_{Ndiag} = y_{Ndiag} - y = S_{Ndiag}(y_{sim} - y) \quad (4.10)$$

onde S_N e y_{sim} dependem do modelo usado no controlador.

O erro nominal atua como uma métrica direta do quão discrepante o modelo usado no controlador, G , é do caso nominal, G_N . Como consequência, se não houvesse discrepância de modelo em G , a saída medida do processo, y , seria equivalente à saída nominal, y_N . Portanto, analogamente à minimização do erro de previsão, Equação (2.11), os parâmetros do modelo podem ser estimados com um problema de minimização utilizando uma função objetivo que englobe o erro nominal tal que

A escolha da função objetivo é feita utilizando o erro nominal e_N ou o erro nominal diagonal e_{Ndiag} , como definidos pelas equações (4.9) e (4.10). Para se eliminar a discrepância nos modelos dos canais de uma dada CV, a função objetivo deve consistir no erro nominal diagonal e_{Ndiag} . Por outro lado, para se eliminar a discrepâncias nos modelos devido à correlação com o erro proveniente dos canais restantes, a função objetivo deve consistir no erro nominal e_N . Logo, temos que

$$\hat{\theta}_K = \min_{\theta} F_{Ndiag}(\theta, Z^K) \quad (4.11)$$

$$F_{Ndiag}(\theta, Z^K) = \frac{1}{K} \sum_{t=1}^K \|e_{Ndiag}\|_{\Lambda} = \frac{1}{K} \sum_{t=1}^K e_{Ndiag}^T(t, \theta) \Lambda^{-1} e_{Ndiag}(t, \theta)$$

$$\hat{\theta}_K = \min_{\theta} F_N(\theta, Z^K) \quad (4.12)$$

$$F_N(\theta, Z^K) = \frac{1}{K} \sum_{t=1}^K \|e_N\|_{\Lambda} = \frac{1}{K} \sum_{t=1}^K e_N^T(t, \theta) \Lambda^{-1} e_N(t, \theta)$$

onde F_{Ndiag} e F_N são as funções objetivo equivalente à minimização, respectivamente, do erro nominal diagonal e erro nominal, $\hat{\theta}_K$ são os parâmetros estimados, Λ é uma matriz de pesos para as saídas e Z^K é o conjuntos de dados em malha fechada utilizados.

Assim, serão estimados, para uma dada CV, apenas os parâmetros dos canais diagnosticados como mais impactantes ($NMDI = 1$). Além disso, os parâmetros do modelo usado no controlador antes de qualquer manutenção, bem como a estrutura de tais modelos (ex. função de transferência de primeira ou segunda ordem), são utilizados como estimativa inicial para a inicialização dos problemas de otimização em (4.11) e (4.12). Com os parâmetros estimados do modelo, $\hat{\theta}_K$, pode-se então atualizar o modelo estimado, $\hat{G}_{N_K}(q, \hat{\theta}_K)$, como o novo modelo nominal utilizado no controlador.

A otimização é realizada com o método *single shooting* ao se simular o processo a cada atualização dos parâmetros dos modelos dos canais. Primeiramente, a malha fechada sem qualquer erro de modelagem (MPM ou UD) é simulada com um distúrbio medido inserido em cada saída, como um degrau unitário, em tempos distintos, visando-se obter dados do processo com o controlador ativo. Assim, S_N pode ser estimada usando qualquer estrutura pré-definida, como modelos paramétricos (LJUNG, 1987). Na sequência, com o modelo G_N da iteração atual, simula-se a malha fechada com o vetor de dados das ações de controle, proveniente dos mesmos dados históricos de processo utilizados nas etapas de auditoria e diagnóstico, para se obter a saída simulada y_{sim} . Em seguida, o valor atual da função objetivo é calculada. Por fim, o processo é repetido até

que a convergência seja atingida. De modo a se diminuir a não-convexidade do problema de otimização, fixa-se a função de sensibilidade S_N como sendo aquela obtida com a simulação da malha fechada com o modelo utilizado no controlador antes de qualquer manutenção, ao invés de estimar uma nova função a cada iteração.

A Figura 4.2 ilustra o fluxograma do processo completo da manutenção de controladores preditivos. Após a estimação do novo modelo nominal, \hat{G}_{N_K} , pode-se realizar uma nova auditoria e diagnóstico visando determinar se o modelo identificado possui desempenho adequado, isto é, se o modelo obtido ainda possui alguma discrepância significativa com o planta nos canais que não foram previamente classificados como mais discrepantes.

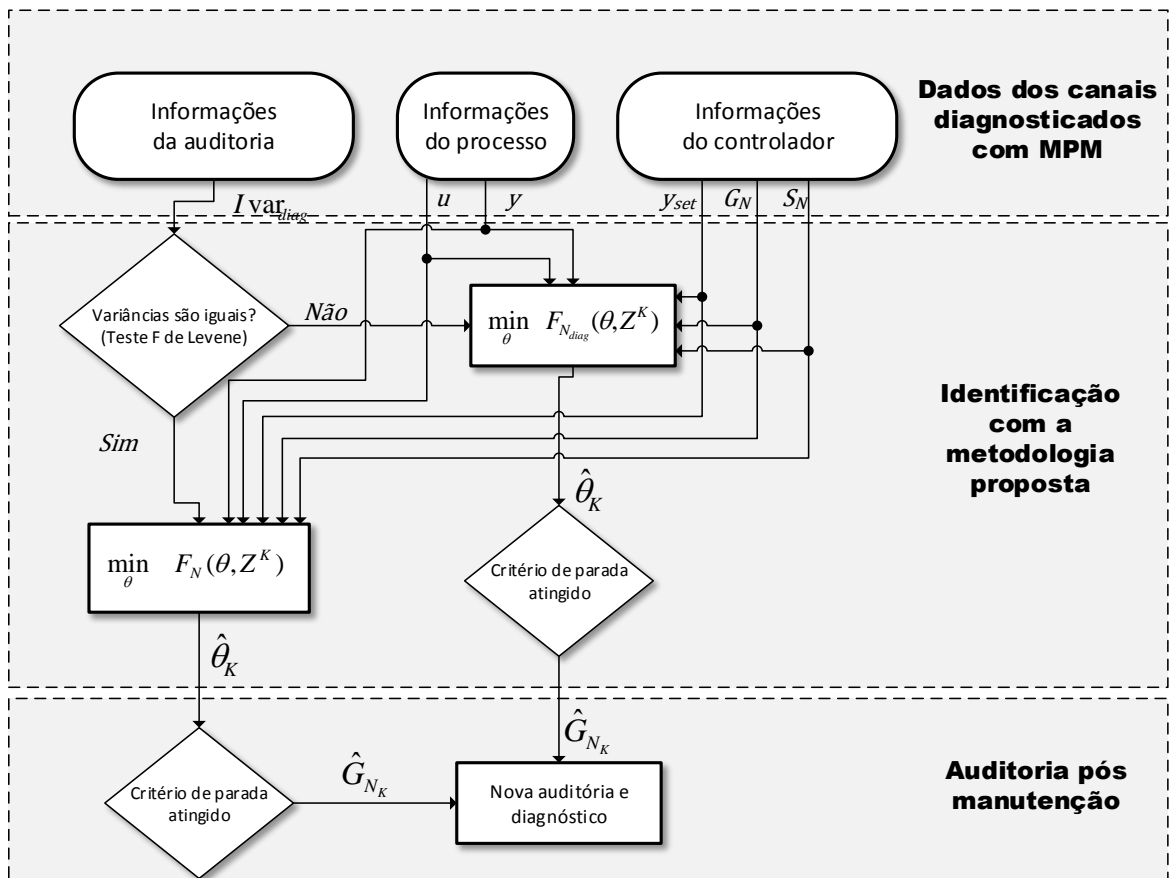


Figura 4.2: Fluxograma do passo-a-passo da etapa de identificação de um novo modelo para controladores preditivos

4.3 Método Sequencial de Identificação em Malha Fechada

Visando-se eliminar a discrepância estrutural do modelo de maneira sistemática, sem a necessidade de estimar vários modelos variando-se a ordem em cada estimação, um método sequencial foi desenvolvido, que une as identificações pelo método direto compensado e pelo método do erro nominal. O MDC possui a vantagem de poder ser realizado com estruturas paramétricas distintas, como espaços de estados ou estruturas

paramétricas (ARX, OE, BJ, entre outros), o que possibilita uma maior flexibilidade quanto a estrutura do modelo. Assim, a ideia básica por trás do método sequencial é usar a flexibilidade do MDC para identificar um modelo inicial para os canais discrepantes, o qual será, posteriormente, usado como estimativa inicial para iniciar o MEN, ao invés de se utilizar o modelo usado no controlador que serviu como base nas etapas de auditoria e diagnóstico.

Assim, os parâmetros usados como estimativa inicial na identificação pelo MEN, bem como a ordem do modelo, serão, portanto, os parâmetros e estrutura dos modelos da matriz de transferência do modelo identificado pelo MDC. A partir deste ponto, o MEN prossegue como exposto na seção 4.2.

Capítulo 5 – Estudo de Caso

Este capítulo apresenta a aplicação da metodologia proposta aplicada a um sistema de quatro tanques cilíndricos (JOHANSSON, 2000). Através deste estudo de caso, serão demonstradas as potencialidades e limitações do método proposto.

A avaliação do sistema de quatro tanques foi dividida em duas partes. Na primeira, avalia-se a eficiência do método para o caso de o sistema ser quadrado (i.e., mesmo número de variáveis controladas e manipuladas), de modo que o objetivo de controle consiste em manter cada CV em um *setpoint*. Nesta etapa, o estudo foi dividido em dois cenários para se avaliar o impacto da localização do canal discrepante no potencial da metodologia.

Uma particularidade na prática industrial é a utilização de *soft-constraints* ao invés de *setpoint*, onde geralmente o número de variáveis controladas pode ser igual ou maior que o número de variáveis manipuladas. Além disso, a utilização de camadas de otimização simplificadas e otimização em tempo real (RTO), que calculam os valores ótimos estacionários para as variáveis manipuladas, também configuram peculiaridades industrialmente utilizadas.

Assim, na segunda parte deste capítulo, o sistema de quatro tanques é definido por faixas, o que significa que o controle atua nas variáveis manipuladas apenas para evitar violações dos limites de operação, em conjunto com uma camada RTO para o cálculo dos movimentos ótimos das MVs.

5.1 Considerações gerais

O potencial e as limitações do método serão avaliados levando em conta as seguintes considerações:

- a. No Matlab® R2012b, o *p-value* para o Teste F de Levene pode ser obtido para dois conjuntos de amostras y_1 e y_2 com o comando:

$$p = \text{vartestn}([y1 \ y2], [], [], 'robust') \quad (5.1)$$

onde '*robust*' representa a escolha do teste F de Levene ao invés do *default* teste F de Bartlett (para amostrar com distribuição normal).

- II. A identificação de modelos utilizando o método direto (seção 2.1.1), método de dois estágio (seção 2.1.3) ou o proposto método direto compensado (seção 4.1), foi feita utilizando as estruturas polinomiais ARX, OE e BJ, tal que (LJUNG, 1987):

$$\begin{aligned} \text{ARX:} \quad y(t) &= \frac{B(q)}{A(q)} u(t - n_k) + \frac{1}{A(q)} e(t) \\ B(q) &= b_1 + b_2 q^{-1} + \dots + b_{n_b} q^{-n_b+1} \\ A(q) &= a_1 + a_2 q^{-1} + \dots + a_{n_a} q^{-n_a} \end{aligned} \quad (5.2)$$

$$\begin{aligned} \text{OE:} \quad y(t) &= \frac{B(q)}{F(q)} u(t - n_k) + e(t) \\ B(q) &= b_1 + b_2 q^{-1} + \dots + b_{n_b} q^{-n_b+1} \\ F(q) &= f_1 + f_2 q^{-1} + \dots + f_{n_f} q^{-n_f} \end{aligned} \quad (5.3)$$

$$\begin{aligned} \text{BJ:} \quad y(t) &= \frac{B(q)}{F(q)} u(t - n_k) + \frac{C(q)}{D(q)} e(t) \\ B(q) &= b_1 + b_2 q^{-1} + \dots + b_{n_b} q^{-n_b+1} \\ F(q) &= f_1 + f_2 q^{-1} + \dots + f_{n_f} q^{-n_f} \\ C(q) &= c_1 + c_2 q^{-1} + \dots + c_{n_c} q^{-n_c} \\ D(q) &= d_1 + d_2 q^{-1} + \dots + d_{n_d} q^{-n_d} \end{aligned} \quad (5.4)$$

onde $y(t)$ e $u(t)$, $k = 1, 2, \dots, K$, tal que K é o número de pontos, são, respectivamente, o vetor de amostragem dos sinais de saída e entrada, $e(t)$ é o erro, $B(q)$, $A(q)$, $F(q)$, $C(q)$ e $D(q)$ são os polinômios do modelo com suas respectivas ordens n_b , n_a , n_f , n_c e n_d , n_k é o atraso e q é o operador de defasagem.

- a. No Matlab®, os comandos utilizados para identificação com os modelo ARX, OE e BJ são:

$$\text{sys} = \text{arx}([u \ y], [n_b \ n_a \ n_k]) \quad (5.5)$$

$$\text{sys} = \text{oe}([u \ y], [n_b \ n_f \ n_k]) \quad (5.6)$$

$$\text{sys} = \text{bj}([u \ y], [n_b \ n_c \ n_d \ n_f \ n_k]) \quad (5.7)$$

onde u e y são, respectivamente, os vetores de entrada e saída, n_b , n_a , n_f , n_c e n_d as ordens dos polinômios e n_k é o atraso. A métrica de qualidade do modelo identificado é calculada com um segundo conjunto de

dados (validação) utilizando o erro quadrático médio normalizado NRMSE (*Normalized Root Mean Square Error*), em porcentagem, tal que:

$$NRMSE = 100 \left(1 - \frac{\|y_{medido} - y_{modelo}\|}{\|y_{medido} - \bar{y}_{medido}\|} \right) \quad (5.8)$$

onde y_{medido} e \bar{y}_{medido} são, respectivamente, a saída medida e a média da saída medida por canal (combinação CV-MV), y_{modelo} é a resposta simulada com o modelo e $\|\cdot\|$ indica a norma 2 do vetor.

5.2 Descrição do sistema de quatro tanques

A unidade a ser estudada é uma planta com quatro tanques cilíndricos interconectados, como proposto por JOHANSSON (2000) e ilustrado na Figura 5.1. O sistema é composto por duas bombas com tensões de alimentação v_1 e v_2 que transportam água para os tanques, cujos níveis são representados por h_1, h_2, h_3 e h_4 . A vazão é dividida por duas válvulas com aberturas x_1 e x_2 , respectivamente.

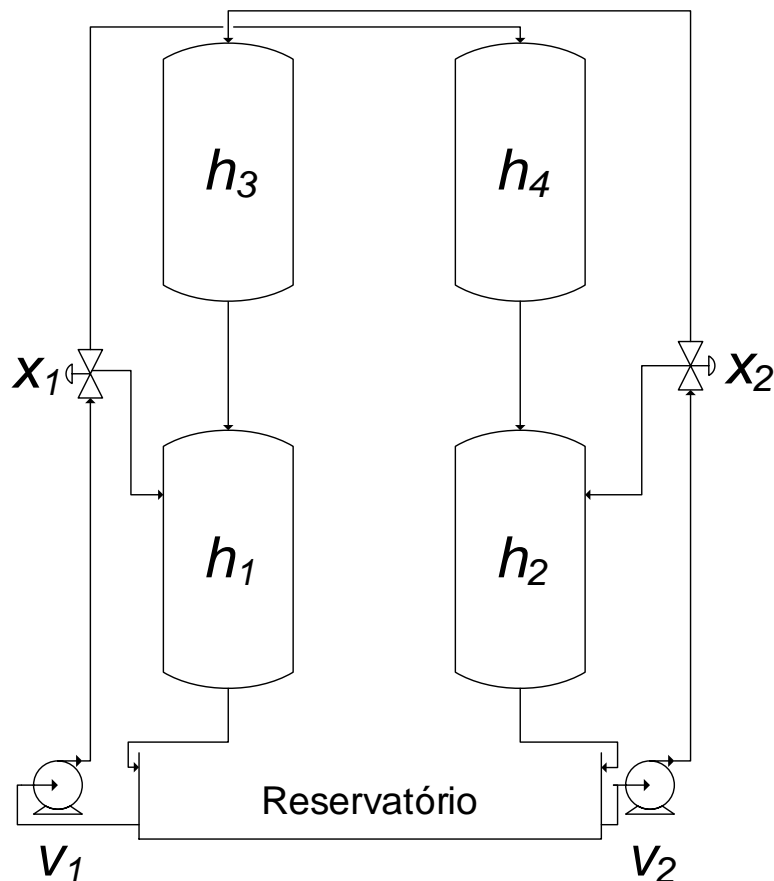


Figura 5.1: Diagrama esquemático do sistema de quatro tanques cilíndricos (Adaptado de JOHANSSON (2000))

A modelagem fenomenológica dessa unidade foi realizada considerando o balanço material em cada tanque, conforme as seguintes equações:

$$\frac{dh_1}{dt} = -\frac{cd_1}{A_1}(h_1)^{exp1} + \frac{cd_3}{A_1}(h_3)^{exp3} + \frac{x_1 k_1 v_1}{A_1} \quad (5.9)$$

$$\frac{dh_2}{dt} = -\frac{cd_2}{A_2}(h_2)^{exp2} + \frac{cd_4}{A_2}(h_4)^{exp4} + \frac{x_2 k_2 v_2}{A_2} \quad (5.10)$$

$$\frac{dh_3}{dt} = -\frac{cd_3}{A_3}(h_3)^{exp3} + \frac{(1-x_2)k_2 v_2}{A_3} \quad (5.11)$$

$$\frac{dh_4}{dt} = -\frac{cd_4}{A_4}(h_4)^{exp4} + \frac{(1-x_1)k_1 v_1}{A_4} \quad (5.12)$$

onde $k_1 v_1$ e $k_2 v_2$ são as vazões das bombas, A_i, cd_i e exp_i , onde $i = 1..4$, são, respectivamente, as áreas das seções transversais, os coeficientes de descarga e o expoente de descarga associado com o tipo de regime de escoamento para cada tanque. Os parâmetros do modelo estão descritos na Tabela 5.1.

Tabela 5.1: Parâmetros originais do sistema de quatro tanques cilíndricos

Parâmetro	Valor	Unidade
A_1	28	cm^2
A_2	28	cm^2
A_3	32	cm^2
A_4	32	cm^2
cd_1	3.145	$cm^{2.5}/s$
cd_2	2.525	$cm^{2.5}/s$
cd_3	3.145	$cm^{2.5}/s$
cd_4	2.525	$cm^{2.5}/s$
k_1	3.14	cm^3/Vs
k_2	3.29	cm^3/Vs
$exp1$	0.5	-
$exp2$	0.5	-
$exp3$	0.5	-
$exp4$	0.5	-

5.2.1 Configuração 1: Modelo 2x2 por setpoint

Para ilustrar a metodologia proposta, dados simulados foram gerados a partir da simulação de um controlador preditivo, cujo objetivo foi controlar os dois primeiros níveis h_1 e h_2 em um dado *setpoint* a partir da manipulação das tensões, v_1 e v_2 . Para representar o processo, o modelo descrito pelas equações de (5.9) a (5.12) foi linearizado no ponto de operação $h_1 = 12,6 \text{ cm}$, $h_2 = 13,0 \text{ cm}$, $v_1 = 3,15 \text{ V}$ e $v_2 = 3,15 \text{ V}$. Para este ponto de operação, o sistema apresenta características de fase não-mínima, isto é, possui um zero de transmissão no semi-plano direito (RHP, do inglês *Right-Half-Plane*) (JOHANSSON, 2000).

$$G = \begin{bmatrix} \frac{2,38 \cdot 10^{-2}}{s + 1,59 \cdot 10^{-2}} & \frac{1,00 \cdot 10^{-3}}{s^2 + 4,16 \cdot 10^{-2}s + 4,07 \cdot 10^{-4}} \\ \frac{4,91 \cdot 10^{-4}}{s^2 + 2,88 \cdot 10^{-4}s + 1,96 \cdot 10^{-4}} & \frac{1,76 \cdot 10^{-2}}{s + 1,10 \cdot 10^{-2}} \end{bmatrix} \quad (5.13)$$

Um MPC do tipo GPC foi configurado no Matlab® R2012b com a ferramenta *Model Predictive Control Toolbox™* para atuar com restrições nas variáveis manipuladas e controladas. A função objetivo do controlador foi definida como na Equação (5.14) e as restrições como na Equação (5.15). Os parâmetros de ajustes do controlador, computados de acordo com a metodologia RPN, *Robust Performance Number* (TRIERWEILER; FARINA, 2003), estão descritos na Tabela 5.2.

$$\min_{\Delta u(k) \dots \Delta u(k+mh)} \left[\sum_{i=1}^{ph} \left[\sum_{j=1}^{ny} W_j \left[y_j(i+k) - y_{set_j}(i+k) \right]^2 + \sum_{i=1}^{nu} MS_i \left[\Delta u_i(i+k) \right]^2 \right] \right] \quad (5.14)$$

sujeito a

$$\begin{aligned} u_{min}^{[mh]} \leq u^{[mh]} \leq u_{max}^{[mh]} \\ y_{min}^{[ph]} \leq y^{[ph]} \leq y_{max}^{[ph]} \end{aligned} \quad (5.15)$$

Tabela 5.2: Parâmetros de ajuste do MPC

Parâmetro	Valor	Unidade
Tempo de amostragem (T_s)	10	s
Horizonte de predição (ph)	48	s
Horizonte de controle (mh)	12	s
Peso das CVs (W)	[10 10]	—
Peso da supressão de movimento (MS)	[50 50]	—
Limite inferior das MVs (u_{min})	[0,1 0,1]	V
Limite superior das MVs (u_{max})	[10 10]	V
Limite inferior das CVs (y_{min})	[0,01 0,01]	cm
Limite superior das CVs (y_{max})	[20 20]	cm

Visando criar um cenário realista com discrepância entre modelo e planta, o modelo utilizado no controlador é diferente daquele descrito pela Equação (5.13). Portanto, para o modelo utilizado no controlador, foram estudados dois cenários: modelo com discrepância na diagonal principal da matriz dinâmica (Cenário 1) e outro com a discrepância inserida fora da diagonal principal (Cenário 2). Os canais com discrepância, criados a partir do modelo da planta, estão descritos na Tabela 5.3, enquanto os demais canais permaneceram iguais aos descritos na Equação (5.13). Os modelos discrepantes

inseridos estão descritos na Tabela 5.3. As Figura 5.2 e Figura 5.3 ilustram a resposta degrau unitário para o modelo utilizado no controlador, G_N , e o modelo da planta, G .

Tabela 5.3: Canais discrepantes no modelo utilizado no controlador

Cenário	1		2	
Canal	(1,1)	(2,2)	(1,2)	(2,1)
Modelo	$G(1,1) \cdot \frac{-2}{50s+1}$	$G(2,2) \cdot \frac{3.2}{1.01 \cdot 10^6 s^2 + 1806s + 1}$	$G(1,2) \cdot \frac{1}{80s+1}$	$G(2,1) \cdot \frac{1}{100s+1}$




Figura 5.2: Respostas degrau dos modelos nominal e da planta para o Cenário 1




Figura 5.3: Respostas degrau dos modelos nominal e da planta para o Cenário 2

A malha fechada também foi simulada com a presença de distúrbios não medidos em ambas variáveis controladas. Os distúrbios foram somados às saídas da planta para formar as saídas medidas da malha fechada. Os distúrbios estão ilustrados na Figura 5.4.




Figura 5.4: Distúrbios não-medidos inseridos nas saídas do processo

A simulação do processo foi feita segundo os seguintes passos:

- Passo 1: a referência para a primeira CV é perturbada com um degrau positivo. Depois que o sinal desta variável atinge o estado estacionário, a referência da segunda CV é também perturbada com um degrau positivo;

- Passo 2: após o sinal da segunda CV atingir o estado estacionário, a referência para a CV1 é retornada ao valor inicial. O mesmo acontece com a CV2 quando a primeira atingi um novo estado estacionário;
- Passo 3: os procedimentos nos passos 1 e 2 são repetidos, mas desta vez utilizando degraus negativos.

A Tabela 5.4 expõe as perturbações realizadas nos *setpoints*.

Tabela 5.4: Percurso de simulação do sistema de quatro tanques

Passo	Instante [s]	Setpoint [cm]	
		CV1	CV2
Valor inicial	0	12,6	13,0
1	1000	17,0	13,0
	2000	17,0	15,0
2	5000	12,6	15,0
	6000	12,6	13,0
	9000	10,0	13,0
3	10000	10,0	11,0
	13000	12,6	11,0
	14000	12,6	13,0
Valor final	16000	12,6	13,0

Com esta forma de geração dos dados, o vetor dos sinais de entrada, saída e referência são divididos de forma a se gerarem dados de calibração e validação para a identificação do modelo pelos métodos direto compensado (seção 4.1) e método indireto em dois estágios (seção 2.1.3). A divisão está descrita na Tabela 5.5.

Tabela 5.5: Divisão dos dados para calibração e validação

Tipo de dados	Período	Número de pontos
Calibração	[0 7000]	701
Validação	[7010 16000]	900

A geração da função nominal de sensibilidade, necessária para etapa inicial de auditoria e diagnóstico, foi realizada conforme recomendando por BOTELHO (2015). Dessa forma, foi realizada a simulação da malha fechada, sem discrepâncias entre o processo e o modelo utilizado no controlador ou presença de distúrbio não medido, visando-se identificar a função nominal de sensibilidade complementar, T_N , com os sinais de referências e saídas medidas. A função nominal de sensibilidade, S_N , foi então obtida a partir de T_N . Tomou-se cuidado para evitar a saturação de variáveis durante os testes para não afetar a identificação da função de sensibilidade pela redução de graus de liberdade.

5.2.2 Configuração 2: Modelo 4x4 por faixas e camada RTO

Para o sistema de 4 tanques cilíndricos atuando por faixas, o objetivo é controlar todos os níveis, isto é, h_1, h_2, h_3 e h_4 , manipulando-se as tensões das bombas e as aberturas das válvulas, ou seja, v_1, v_2, x_1 e x_2 . Para isso, as equações do sistema, Equações (5.9) a (5.12), foram linearizadas no ponto de operação descrito na Tabela 5.6.

Tabela 5.6: Variáveis do controlador e ponto de operação para linearização do sistema de 4 tanques por faixas

Tipo de variável	Variáveis	Unidade	Ponto de operação
Controladas	$y = [h_1 \ h_2 \ h_3 \ h_4]$	[cm cm cm cm]	$y^0 = [12,6 \ 13,0 \ 4,8 \ 4,9]$
Manipuladas	$u = [v_1 \ v_2 \ x_1 \ x_2]$	[V V - -]	$u^0 = [3,15 \ 3,15 \ 0,43 \ 0,34]$

Aplicando-se os valores dos parâmetros, obtém-se a matriz de transferência resultante para a planta real, G , como descrito na Equação (5.16).

$$G(s) = \begin{bmatrix} \frac{0.048}{s + 0.016} & \frac{0.0025}{s^2 + 0.028s + 0.0002} & \frac{0.35}{s + 0.015} & \frac{-0.0096}{s^2 + 0.41s + 0.0004} \\ \frac{0.0009}{s + 0.016} & \frac{0.035}{s + 0.011} & \frac{-0.0055}{s^2 + 0.024s + 0.0002} & \frac{0.323}{s + 0.011} \\ 0 & \frac{0.078}{0.028s + 0.25} & 0 & \frac{-0.37}{s + 0.026} \\ \frac{0.045}{s + 0.018} & 0 & \frac{-0.31}{s + 0.018} & 0 \end{bmatrix} \quad (5.16)$$

Os parâmetros de ajustes do controlador, computados de acordo com a metodologia RPN (TRIERWEILER; FARINA, 2003), estão descritos na Tabela 5.7.

Tabela 5.7: Parâmetros de sintonia do controlador e do otimizador para o sistema de 4 tanques por faixas

Parâmetro	Valor	Unidade
-----------	-------	---------

Tempo de amostragem (T_s)	10	s
Horizonte de predição (ph)	48	s
Horizonte de controle (mh)	12	s
Peso da supressão de movimento (MS)	[50 50 50 50]	—
Peso das CVs (W)	[10 10 10 10]	—
Peso dos targets	[0,1 0,1 0,1 0,1]	
Custo das MVs	[-350 -350 200 200]	cm
Varição máxima para cada CV	[2,5 2,5 0,25 0,25]	cm
Limite inferior das MVs (u_{min})	[0,1 0,1 0,01 0,01]	[V V — —]
Limite superior das MVs (u_{max})	[10 10 1 1]	[V V — —]

O cálculo das metas (*targets*) para as variáveis do otimizador, realizada na camada RTO, é efetuado através de um algoritmo de programação quadrática (QP), implementado pela função *quadprog* do Matlab® que minimiza a função objetivo:

$$J = \min_x \frac{1}{2} x^T M x + f^T x \quad (5.17)$$

onde o termo quadrático (M) corresponde à minimização de movimentos das MVs, enquanto o termo linear corresponde a uma função custo das MVs, configurada através de pesos para essas variáveis (descritos na Tabela 5.7).

Visando criar um cenário realista com discrepância entre modelo e planta, o modelo utilizado no controlador é diferente daquele descrito pela Equação (5.16). Os canais com discrepância, criados a partir do modelo da planta, estão descritos na Tabela 5.8, enquanto os demais canais permaneceram iguais aos descritos na Equação (5.16). Os modelos discrepantes inseridos estão descritos na Tabela 5.8. A Figura 5.5 ilustra a resposta degrau unitário para os canais discrepantes do modelo utilizado no controlador, G_N , e o modelo da planta, G .

Tabela 5.8: Discrepância inseridas no modelo da planta para o sistema de 4 tanques por faixas

	Discrepância inserida		
Modelo	$G(1,1) \cdot \frac{2}{400s + 1}$	$G(2,2) \cdot \frac{2}{200s + 1}$	$G(4,3) \cdot \frac{1}{150s + 1}$




Figura 5.5: Respostas degrau dos modelos nominal e da planta para o sistema de 4 tanques por faixas

A malha fechada também foi simulada com a presença de um distúrbio não medido nas CVs 2 e 3, como ilustrado na Figura 5.6. Os distúrbios foram somados às saídas da planta para formar as saídas medidas da malha fechada.




Figura 5.6: Distúrbios não-medidos inseridos nas saídas h_2 e h_3 do processo

A simulação da malha consistiu dos seguintes passos:

- Passo 1: a faixa superior da restrição flexível, y_{soft} , para a primeira CV é perturbada com um degrau negativo. Depois que o sinal desta variável atinge o estado estacionário, a faixa superior da restrição flexível da CV2 é também

perturbada com um degrau negativo. Da maneira análoga, o mesmo se repete para as CV3 e 4;

- Passo 2: após o sinal da segunda CV atingir o estado estacionário, a faixa superior da restrição flexível para a CV1 é retornada ao valor inicial. O mesmo acontece com a CV2 quando a primeira atingi um novo estado estacionário. De maneira análoga, o mesmo se repete para as CV3 e 4.

A Tabela 5.9 expõe os valores utilizados no passo a passo para geração de dados referentes ao instante de amostragem no qual uma alteração é feita na faixa flexível superior bem como o valor desta alteração.

Tabela 5.9: Percurso de simulação do sistema de 4 tanques por faixas

Passo	Instante [s]	y_{soft} [cm]			
		CV1	CV2	CV3	CV4
Valor inicial	0	12,6	13,0	5,0	5,0
1	1500	10,0	13,0	5,0	5,0
	3500	10,0	10,0	5,0	5,0
	4000	10,0	10,0	3,0	5,0
	4500	10,0	10,0	3,0	3,0
	5000	12,6	10,0	3,0	3,0
2	6500	12,6	13,0	3,0	3,0
	7500	12,6	13,0	5,0	3,0
	8500	12,6	13,0	5,0	5,0
Final	9500	12,6	13,0	5,0	5,0

Com esta forma de geração dos dados, os vetores de entrada, saída e restrições flexíveis foram divididos de forma a se gerarem dados de calibração e validação para a identificação do modelo pelos métodos direto (seção 2.1.1) e direto compensado (seção 4.1). A divisão está descrita na Tabela 5.10.

Tabela 5.10: Divisão dos dados para calibração e validação para o sistema de 4 tanques por faixas

Tipo de dados	Período	Número de pontos
---------------	---------	------------------

Calibração	[0 5000]	501
Validação	[5010 9500]	449

A geração da função nominal de sensibilidade, necessária para etapa inicial de auditoria e diagnóstico, foi realizada conforme recomendando por BOTELHO (2015). Dessa forma, a simulação da malha fechada, sem discrepâncias entre o processo e o modelo do controlador ou presença de distúrbio não medido, visando-se identificar a função nominal de sensibilidade complementar, T_N , com os sinais de referências e saídas medidas. A função nominal de sensibilidade, S_N , foi então obtida a partir de T_N . Tomou-se cuidado para evitar a saturação de variáveis durante os testes para não afetar a identificação da função de sensibilidade pela redução de graus de liberdade.

5.3 Resultados

5.3.1 Sistema 2x2: discrepância na diagonal principal da matriz de transferência

Dados foram gerados a partir da simulação do processo considerando as discrepâncias já discutidas na seção 5.2.1. As entradas e saídas do processo estão ilustradas na Figura 5.7.




Figura 5.7: Sinais das variáveis controladas e manipuladas para o cenário 1 do sistema 2x2

Inicialmente, os dados da malha fechada foram utilizados para se quantificar o impacto do erro de modelagem pelo cálculo dos indicadores de variância e variância diagonal, conforme descrito na seção 3.1. A Figura 5.8 mostra os resultados da avaliação dos modelos do controlador. A linha vermelha tracejada corresponde ao valor unitário para os indicadores I_{var} e $I_{var_{diag}}$, correspondente à homogeneidade ou igualdade entre as variâncias de y e y_N e entre y e $y_{N_{diag}}$. Para ambos indicadores, o resultado indica o aumento da variância na saída do controlador.




Figura 5.8: Auditoria de erros de modelagem para o cenário 1 do sistema 2x2

A Tabela 5.11 apresenta os resultados do teste F de Levene para igualdade de variâncias. Para um nível de significância $\alpha = 5\%$, rejeita-se a hipótese nula (de que as variâncias são iguais) para valores de $p - value$ inferiores a 0,05.

Tabela 5.11: Resultados do teste F de Levene para igualdade de variâncias para o cenário 1 do sistema 2x2

Variável	I_{var}	p	$I_{var_{diag}}$	p
h_1	3,3461	$1,1499 \cdot 10^{-8}$	5,1252	$2,1802 \cdot 10^{-7}$
h_2	1,0841	$2,1802 \cdot 10^{-7}$	3,9253	$1,7301 \cdot 10^{-12}$

De acordo com a Tabela 5.11, os valores de I_{var} encontram-se abaixo de 0,05 para ambas as saídas, ou seja, rejeita-se a hipótese nula (de igualdade de variâncias) para um nível de significância de $\alpha = 5\%$. A não-homogeneidade de variâncias ($I_{var} \neq 1$) mostra que a variância na saída analisada é significativamente maior que a saída para o caso nominal. Portanto, considera-se que ambas variáveis apresentam, de fato, erro de modelagem.

Em relação ao indicador $I_{var_{diag}}$, os resultados do $p - value$ também estão abaixo de 0,05. Isto indica que, novamente, rejeita-se a hipótese nula de que as variâncias são iguais. Logo, comprova-se que o erro de modelagem é majoritariamente oriundo do erro contido na própria CV, resultado o qual está de acordo como a discrepância de modelo inserida para o Cenário 1, pois cada saída possui um dos canais tendo MPM em seu modelo.

Visto que ambas saídas foram dadas como possuindo erro de modelagem, a etapa de diagnóstico por CV foi realizado tanto para h_1 quanto para h_2 . A Figura 5.9 apresenta os coeficiente médios de correlação para as distribuições de curtose e assimetria dos sinais y_{Ndiag} e e_{Ndiag} . Observa-se que os coeficiente médios de correlação para ambas saída (e ambas distribuições) ultrapassam o limite definido pelo intervalo de confiança CI (indicado pela linha vermelha tracejada), obtido pela Equação (3.17). Assim, conclui-se que a fonte predominante dos erros de modelagem é MPM para ambas variáveis.




Figura 5.9: Diagnóstico da fonte dos erros de modelagem para o cenário 1 do sistema 2x2

Com o diagnóstico predominante de discrepância entre modelo e planta, o próximo passo consiste em localizar a MV mais relacionada ao erro de modelo, o que é feito através da correlação cruzada entre o erro nominal diagonal, e_{Ndiag} , e saída parcial filtrada, \hat{y}_{pf} com o cálculo do indicador MDI (ou $NMDI$), de acordo com a metodologia descrita na seção 3.2. A Tabela 5.12 mostra os valores encontrados do indicador MDI e a Figura 5.10 no gráfico de barras para o indicador $NMDI$. De acordo com valores encontrados, as variáveis manipuladas mais relacionadas à discrepância de modelo para a CV1 e CV2 são, respectivamente, a MV1 e a MV2, pois possuem os maiores valores de MDI . Logo, os canais diagnosticados como mais discrepantes são (h_1xv_1) e (h_2xv_2) .

Tabela 5.12: Indicadores MDI do diagnóstico por canal para o cenário 1 do sistema 2x2

Variável	MDI	
	v_1	v_2
MV		
CV		
h_1	0,8088	0,5840
h_2	0.5421	0,8837

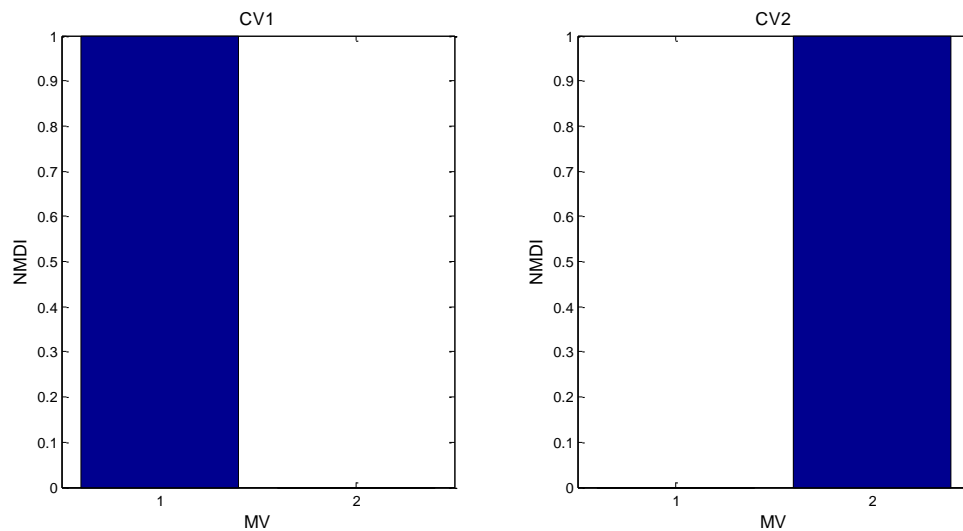


Figura 5.10: Localização da MV mais relacionada à discrepância de modelo para o cenário 1 do sistema 2x2 para (a) a variável h_1 (b) a variável h_2

Como o indicador $NMDI$ indica o canal mais afetado pela MPM para uma dada saída ($NMDI = 1$), a metodologia para reidentificação de modelos foi realizada apenas para corrigir tais canais.

Primeiramente, realizou-se a identificação com o método direto compensado, como descrito na seção 4.1. Para tal, utilizou-se a ferramenta *System Identification Toolbox* do Matlab® R2012b com os ajustes polinomiais ARX, OE e BJ, variando-se as ordens dos polinômios no intervalo de dois a seis. A Tabela 5.13 apresenta os valores correspondentes ao NRMSE, conforme Equação (5.8), para os canais identificados.

Tabela 5.13: Ordem e valores NRMSE dos modelos estimados pelo método direto compensado para o cenário 1 do sistema 2x2

	Ordem	2	3	4	5	6
ARX	$(h_1 \times v_1)$	-7.6717	75,5432	76,9069	81,1401	87,8232
	$(h_2 \times v_2)$	74,4861	93,7471	93,9861	93,4201	93,5247
OE	$(h_1 \times v_1)$	94,3131	95,0956	95,1845	95,4608	96,6897
	$(h_2 \times v_2)$	94,0771	94,4917	94,5610	94,6226	-96,9020
BJ	$(h_1 \times v_1)$	95,1549	95,8707	95,9343	96,3301	97,2443
	$(h_2 \times v_2)$	94,4854	94,5046	94,8640	94,9836	-96,9020

De acordo com a Tabela 5.13, os melhores valores de NRMSE foram obtidos para os modelos dos canais $(h_1 \times v_1)$ e $(h_2 \times v_2)$ com ordem, respectivamente, 6 e 4 para a estrutura ARX, 6 e 5 para a estrutura OE e 6 e 5 para a estrutura BJ. Para facilitar a análise dos modelos, uma nova identificação foi realizada para se obter modelos de menores

ordens. Para isso, realizou-se uma perturbação degrau unitário (sinal de entrada da identificação) para se obter o sinal da resposta degrau (sinal de saída da identificação) dos melhores modelos anteriormente descritos (Tabela 5.13). Em seguida, um modelo de função de transferência foi identificado, utilizando a função *tfest* do *System Identification Toolbox*, variando a ordem dos modelos de 1 a 3. A Tabela 5.14 apresenta os valores NRMSE dos modelos para cada ordem da função de transferência (Ordem FT).

Tabela 5.14: Ordem e valores NRMSE da redução de ordem os modelos estimados pelo método direto compensado para o cenário 1 do sistema 2x2

Canal	Ordem FT	1	2	3
	ARX	$(h_1 \times v_1)$	68,3424	73,5133
$(h_2 \times v_2)$		94,2449	93,9764	93,1446
OE	$(h_1 \times v_1)$	81,0863	81,3713	87,0267
	$(h_2 \times v_2)$	79,5956	81,0661	80,0938
BJ	$(h_1 \times v_1)$	81,0863	81,3713	87,0267
	$(h_2 \times v_2)$	79,5956	81,0661	80,0938

De acordo com a Tabela 5.14, a melhor ordem das funções de transferência estimadas para os canais $(h_1 \times v_1)$ e $(h_2 \times v_2)$ foram, respectivamente, 2 e 1 para o modelo original ARX, 3 e 4 para o modelo original OE e 3 e 4 para o modelo original BJ. A resposta degrau unitário dos modelos identificado bem como da planta real está ilustrada na Figura 5.11.




Figura 5.11: Resposta degrau dos modelos identificados pelo método direto compensado para o cenário 1 do sistema 2x2

Na sequência, realizou-se a identificação com o método do erro nominal, como descrito na seção 4.2. A metodologia foi realizada com o algoritmo sem restrições Nelder-

Mead utilizando a função *fminsearch* no Matlab® R2102b. A matriz peso da função objetivo foi escolhida como sendo uma matriz identidade de ordem igual àquela do erro nominal. Variou-se a ordem dos modelos de estrutura função de transferência entre 1 e 4. Em vista de o modelo identificado ser usado para fins de controle, a prioridade da estimação é encontrar um modelo cuja dinâmica seja compatível com o comportamento real da planta, uma vez que erros de *bias* no modelo serão corrigidos pela retroalimentação do controlador, como já relatado anteriormente. Portanto, o erro quadrático médio (RMSE, *Root Mean Square Error*) entre as respostas degrau dos modelos da planta e identificados foi calculado para se comparar as curvas na região do tempo de subida da resposta degrau da planta, isto é, entre 5 e 95% do valor do estado estacionário.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_{5-95\%}(i) - \hat{y}_{5-95\%}(i))^2} \quad (5.18)$$

onde y é resposta degrau do modelo da planta e \hat{y} é resposta degrau do modelo estimado, sendo N o número de pontos dos vetores.

Assim, a Tabela 5.15 apresenta os valores de RMSE calculados no tempo de subida entre as respostas degrau da planta e das funções de transferência estimadas para cada ordem (Ordem FT).

Tabela 5.15: Ordem e valores RMSE entre a resposta degrau dos modelos estimados pelo método do erro nominal e da planta para o cenário 1 do sistema 2x2

Ordem FT Canal	RMSE			
	1	2	3	4
$(h_1 \times v_1)$	0,0013	0,0015	0,0107	0,7780
$(h_2 \times v_2)$	0,0059	0,0061	0,0199	0,6578

De acordo com a Tabela 5.15, os menores valores de RMSE foram obtidos para uma função de primeira ordem para ambos os canais $(h_1 \times v_1)$ e $(h_2 \times v_2)$. A resposta degrau dos modelos identificados está ilustrada na Figura 5.12. O modelo identificado pelo método do erro nominal está representado por G_N .




Figura 5.12: Resposta degrau dos modelos identificados pelo MEN para o cenário 1 do sistema 2x2

Como o método do erro nominal tem semelhanças com o método indireto de dois estágios (*two-stage method*), explanado na seção 2.1.3, o modelo da planta também foi identificado com este método para fins de comparação. Para tal, utilizou-se a ferramenta *System Identification Toolbox* do Matlab® R2012b com os ajustes polinomiais OE, BJ e ARX, variando-se as ordens dos polinômios no range entre quatro e oito, para estimar a função de sensibilidade, e entre dois e quatro, para estimar o modelo da planta. A Tabela 5.16 apresenta a ordem dos melhores modelos estimados e seus respectivos NRMSE.

Tabela 5.16: Ordem e valores NRMSE das funções de sensibilidade estimados pelo método indireto de dois estágios para o cenário 1 do sistema 2x2

Ordem Estrutura	NRMSE				
	6	7	8	9	10
ARX	84,0293	89,2134	89,9373	89,9056	89,9189
OE	74,4262	69,2188	60,7502	58,6519	69,3560
BJ	76,0734	76,5029	60,7502	61,2717	73,261

De acordo com a Tabela 5.16, os maiores valores de NRMSE na estimação da função de sensibilidade foram obtidos para os modelos ARX, OE e BJ com ordem igual a, respectivamente, 8, 6 e 7. Utilizando estes modelos da função de sensibilidade para gerar um novo sinal como entrada na identificação do modelo da planta, como na Eq. (2.20), o modelo da planta foi identificado também com estruturas ARX, OE e BJ, variando-se as ordens dos polinômios entre 2 e 6, com ordem do tempo morto igual a 1. A Tabela 5.17 apresenta os valores de NRMSE obtidos para os modelos estimados.

Tabela 5.17: Ordem e valores NRMSE dos modelos da planta estimados pelo método indireto de dois estágios para o cenário 1 do sistema 2x2

Ordem Estrutura	NRMSE				
	2	3	4	5	6
ARX	48,7326	60,3839	65,7043	72,2999	78,1094
OE	77,5399	78,1728	78,5610	81,5870	79,4339
BJ	72,0959	79,0820	78,5769	79,5974	78,3854

Como pode ser observado na Tabela 5.17, os maiores valores de NRMSE foram obtidos para os modelos ARX, OE e BJ com ordem igual a, respectivamente, 6, 5 e 5. A Figura 5.13 ilustra a resposta degrau dos modelos identificados bem como da planta.




Figura 5.13: Resposta degrau dos modelos identificados pelo método dos dois estágios para o cenário 1 do sistema 2x2

Como ilustra a Figura 5.13, bem como a Tabela 5.17, o modelo OE de quinta ordem foi a estimação mais em acordo com a planta real. Assim, uma redução de ordem foi realizada utilizando este modelo, visando obter uma estrutura similar àquelas obtidas para o método direto compensado e do erro nominal. Inicialmente, uma perturbação degrau unitário foi feita no modelo OE de quinta ordem para se obter o sinal de saída a ser utilizado na redução de ordem. Em seguida, um modelo de função de transferência foi identificado, utilizando a função *tfest* do *System Identification Toolbox*, variando a ordem dos modelos de 1 a 3. A Tabela 5.18: Ordem e valores NRMSE da redução de ordem do

modelo da planta estimado pelo método indireto de dois estágios apresenta os valores NRMSE dos modelos para cada ordem da função de transferência (Ordem FT).

Tabela 5.18: Ordem e valores NRMSE da redução de ordem do modelo da planta estimado pelo método indireto de dois estágios para o cenário 1 do sistema 2x2

Canal Ordem FT	NRMSE			
	$(h_1 \times v_1)$	$(h_1 \times v_2)$	$(h_2 \times v_1)$	$(h_2 \times v_2)$
1	71,6246	94,7454	88,8087	80,0607
2	33,4106	95,7446	89,657	86,5616
3	87,2765	96,2201	93,3854	89,8771

Para comparar os modelos identificados com as metodologias utilizadas (MDC, MEN e Dois estágios) foi feita uma análise do zero da transmissão para cada modelo MIMO obtido. Como discutido na seção 5.2.1, o ponto de operação no qual se linearizou as equações do modelo, (5.9) a (5.12) faz com o modelo linearizado resultante, usado para representar a planta, seja de fase não-mínima, ou seja, possui um zero de transmissão. Os zeros de um sistema podem surgir quando os efeitos de competição no sistema são tais que a saída é zero mesmo enquanto as entradas (e os estados) não são iguais a zero. A noção de zeros de um sistema multivariável geralmente adotado é o conceito de zeros de transmissão, ou seja, z é uma transmissão zero ou simplesmente zero de $G(s)$ se o posto de $G(z)$ for menor do que o padrão normal da função de transferência matriz $G(s)$. SKOGESTAD; POSTLETHWAITE (2005) apresentam uma discussão detalhada sobre zeros de transmissão. Um zero no semi-plano direito (RHP-zero) de $G(s)$ limita a largura de banda alcançável da malha fechada. Portanto, o RHP-zero limita o desempenho alcançável da malha fechada. Quanto mais próximo da origem for o RHP-zero, mais restritivo será seu efeito no desempenho da malha fechada. Uma bom modelo multivariável deve capturar não apenas a localização do RHP-zero, mas também a direção de saída correspondente (y_z) e a direção de entrada (u_z). A Tabela 5.19 mostra o RHP-zero e as correspondentes direções de entrada e saída dos modelos identificados em comparação com a planta real.

Tabela 5.19: Zero de transmissão e suas direções de saída e entrada para os modelos identificados para o cenário 1 do sistema 2x2

Modelo	Planta	MDC	MEN	Dois estágios	
RHP-zero	0,0130	0,0151	0.0131	0,1740	
Direção					
MV1	y_z	-0,6264	-0,5939	-0,6252	-0.6584
	u_z	0,7417	0,7218	0,7412	0,9664
MV2	y_z	0,7794	0,8045	0,7803	0,7565
	u_z	-0,6707	-0,6921	-0,6712	-0,2561

Como pode ser observado na Tabela 5.19, ambas as metodologias propostas foram capazes de capturar o comportamento dos zeros de transmissão compatível com o processo. O MEN se mostrou ligeiramente superior ao MDC. O método clássico de dois estágios para identificação em malha fechada, por sua vez, encontrou um valor de RHP-zero diferente daquela da planta (bem como as direções de saída e entrada), mostrando que, embora o valor do NRMSE seja adequado, o modelo é incapaz de capturar características fundamentais para o bom desempenho do sistema de controle.

Outra maneira de se verificar a qualidade do modelo, sob o ponto de vista de controle de processos, é o *Relative Gain Array* (RGA) (SKOGESTAD; POSTLETHWAITE, 2005). Este indicador mede a interação no estado estacionário para o emparelhamento de entrada e saída visando um projeto eficiente de um controlador descentralizado. Os elementos RGA λ_{ij} perto de 1 implicam que o ganho entre a variável de entrada u_j e a variável de saída y_j não é afetado ao fechar as outras malhas. Em outras palavras, λ_{ij} próximo a 1 indica pequena interação do sistema. Nesse sentido, o RGA também é usado como uma ferramenta de seleção de emparelhamento dependente da frequência, através do RGA dinâmico. Assim, o RGA dinâmico também é uma excelente ferramenta para analisar a qualidade do modelo para o controle multivariável, pois captura os efeitos relativamente combinados dos ganhos de todos os canais, em vez de analisar um efeito separadamente.

A Figura 5.14 ilustra o elemento dominante λ_{ij} do RGA dinâmico da planta e dos modelos identificados. Pode-se observar como o modelo identificado pelo método do erro nominal captura o comportamento do RGA da planta em todas as frequências avaliadas. O método direto compensando possui uma pequena discrepância para baixas frequências, mas captura o RGA dinâmico da planta para o restante do range. Por outro lado, o modelo identificado pelo método de dois estágios apresenta grandes discrepâncias no range de frequências intermediárias e altas, demonstrando uma eminente deterioração da qualidade do modelo para fins de controle, especialmente para o caso de um ajuste mais agressivo do controlador (ex.: pequeno peso de supressão de movimento).



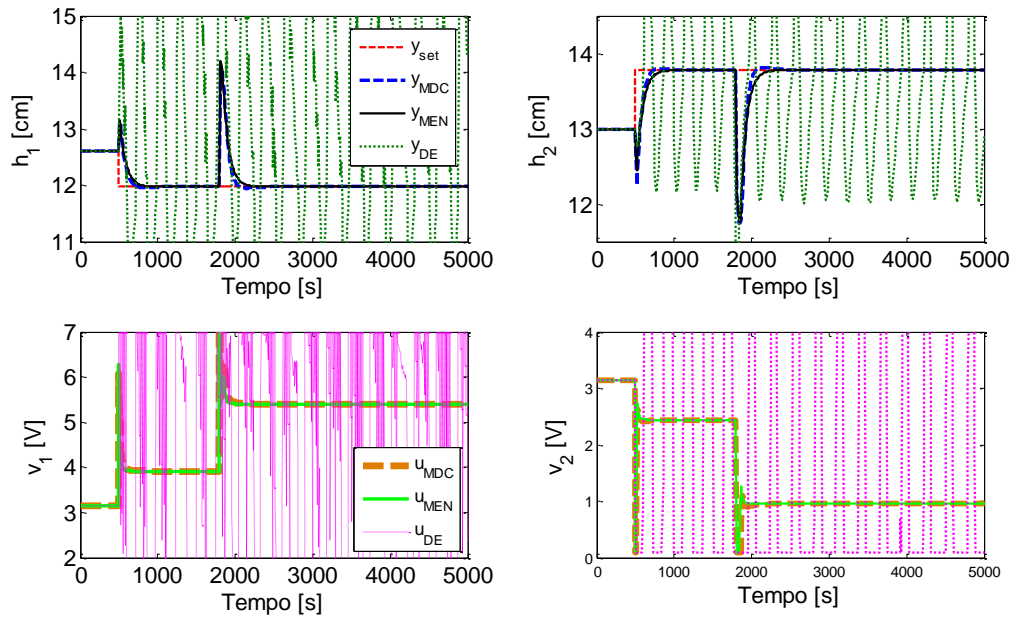


Figura 5.14: Elemento dominante λ_{ij} do RGA dinâmico dos modelos identificados e da planta para o cenário 1 do sistema 2x2

Para ilustrar o impacto da determinação correta das direções de saída e entrada de zero, os modelos identificados foram usados no controlador para simular a malha fechada com duas perturbações: uma variação de *setpoint* na direção $y_z = [-0,6264, 0,7794]$ e uma perturbação de carga em na direção $u_z = [0,7417, -0,6707]$. Estas direções correspondem, respectivamente, às direções de saída e entrada do zero de transmissão do modelo da planta, como mostrado na Tabela 5.19. Além disso, a simulação foi realizada para um ajuste brando do MPC, com matriz de supressão de movimento $MS = [50 \ 50]$, e um ajuste agressivo, com $MS = [0 \ 0]$. A Figura 5.15 ilustra as entradas e saídas da planta para os ajustes brando (a) e agressivo (b) do controlador.



(a)



(b)

Figura 5.15: Entradas e saída da malha fechada com os modelos identificados para o cenário 1 do sistema 2x2 para um (a) ajuste brando do controlador (b) ajuste agressivo do controlador

Conforme observado na Figura 5.15, para o ajuste agressivo do controlador, o sistema com o modelo identificado em dois estágios se tornou instável. Devido ao ajuste agressivo, a frequência de atuação do controlador entra na faixa das frequências intermediárias, como explicado na Figura 5.14, onde o modelo identificado com o método de dois estágios demonstra deterioração na qualidade, uma vez que as direções da mudança de *setpoint* e perturbação de carga ocorrem nas direções de saída e entrada do zero da planta. Por outro lado, como os modelos identificados com as metodologias proposta capturaram a direção correta do zero da planta, os modelos foram adequados com os ajustes brando e agressivo do controlador, tanto para as mudanças de setpoint como de carga na direção do zero, inclusive para o método direto compensado, cujo modelo identificado apresentou pequena discrepância no valor do zero. Isto ocorre devido à característica da função de sensibilidade nominal de isolar a parte do sinal de saída medida referente ao erro de modelo. Com isso, a minimização do erro nominal consegue eliminar essa discrepância sem sofrer influências da magnitude do distúrbio não medido presente na malha. Isto não ocorre para o método de dois estágios, que não consegue distinguir, no sinal de saída do processo, o que é dinâmica da planta e o que é dinâmica do distúrbio, englobando esta última ao modelo identificado.

5.3.2 Sistema 2x2: discrepância fora da diagonal principal da matriz de transferência

Dados foram gerados a partir da simulação do processo considerando as discrepâncias já discutidas na seção 5.2.2. As entradas e saídas do processo estão ilustradas na Figura 5.16.




Figura 5.16: Sinais das variáveis controladas e manipuladas para o cenário 2 do sistema 2x2

A Figura 5.17 mostra os indicadores de variância e variância diagonal obtidos na auditoria. A linha vermelha tracejada corresponde ao valor unitário para os indicadores I_{var} e $I_{var_{diag}}$, correspondente à homogeneidade ou igualdade entre as variâncias de y e y_N e entre y e $y_{N_{diag}}$. Ao contrário do cenário apresentado na seção 5.3.1 (Figura 5.8), os indicadores neste cenário foram todos menores que a unidade, o que indicaria que a variância na saída medida é menor do que no caso nominal. Entretanto, para se comprovar se as variâncias são, de fato, diferentes, realizou-se o teste F de Levene.




Figura 5.17: Auditoria de erros de modelagem para o cenário 2 do sistema 2x2

A Tabela 5.20 apresenta os resultados do teste F de Levene para igualdade de variâncias. Para um nível de significância $\alpha = 5\%$, rejeita-se a hipótese nula (de que as variâncias são iguais) para valores de $p - value$ inferiores a 0,05.

Tabela 5.20: Resultados do teste F de Levene para igualdade de variâncias para o cenário 2 do sistema 2x2

Variável	I_{var}	p	$I_{var_{diag}}$	p
h_1	0,6602	$6,9701 \cdot 10^{-5}$	0,8459	0,5588
h_2	0,5916	$1,7491 \cdot 10^{-7}$	0,4430	0,0765

De acordo com a Tabela 5.20, os valores de I_{var} encontram-se abaixo de 0,05 para ambas as saídas, ou seja, rejeita-se a hipótese de que as variâncias são iguais. Portanto, considera-se que ambas variáveis apresentam, de fato, erro de modelagem.

Em relação ao indicador $I_{var_{diag}}$, os resultados do $p - value$ estão acima de 0,05. Isto indica que a hipótese nula de igualdade das variâncias é aceita, ou seja, a variância na saída medida é a igual à variância da saída nominal. Neste caso, o erro de modelagem é majoritariamente oriundo da correlação existente com o erro em outras variáveis do que na própria saída, o que está de acordo com a discrepância inserida (erro de modelo fora da diagonal principal da matriz dinâmica do modelo).

Visto que ambas saídas foram dadas como possuindo erro de modelagem, a etapa de diagnóstico por CV foi realizado tanto para h_1 quanto para h_2 . A Figura 5.18 apresenta os

coeficiente médios de correlação para as distribuições de curtose e assimetria, Equação (3.15), dos sinais $y_{N_{diag}}$ e $e_{N_{diag}}$. Observa-se que os coeficientes médios de correlação para saída h_1 ultrapassam o limite definido pelo intervalo de confiança CI (indicado pela linha vermelha tracejada). Para a saída h_2 , apenas o coeficiente médio de correlação para a distribuição de assimetria ultrapassou o limite de confiança, o que segundo o autor (Botelho et al., 2016), já é suficiente para o diagnóstico de MPM. Assim, conclui-se que a fonte predominante dos erros de modelagem é MPM para ambas variáveis.




Figura 5.18: Diagnóstico da fonte dos erros de modelagem para o cenário 2 do sistema 2x2

Com o diagnóstico predominante de discrepância entre modelo e planta, o próximo passo consiste em localizar a MV mais relacionada ao erro de modelo, o que é feito através da correlação cruzada entre o erro nominal diagonal, $e_{N_{diag}}$, e saída parcial filtrada, \hat{y}_{pf} com o cálculo do indicador $NMDI$. A Figura 5.19 mostra o gráfico de barras para o indicador $NMDI$. De acordo com valores encontrados, as variáveis manipuladas mais relacionadas à discrepância de modelo para a CV1 e CV2 são, respectivamente, a MV2 e a MV1, pois possuem $NMDI$ igual a um. Logo, os canais diagnosticados como mais discrepantes são (h_1xv_2) e (h_2xv_1) .




Figura 5.19: Localização da MV mais relacionada à discrepância de modelo para o cenário 2 do sistema 2x2 para (a) a variável h_1 (b) a variável h_2

Como o indicador *MDI* indica o canal mais afetado pela MPM para uma dada saída, a metodologia para reidentificação de modelos foi realizada apenas para corrigir tais canais.

Primeiramente, realizou-se a identificação com o método direto compensado, como descrito na seção 4.1. Para tal, utilizou-se a ferramenta *System Identification Toolbox* do Matlab® R2012b com os ajustes polinomiais ARX, OE e BJ, variando-se as ordens dos polinômios no intervalo de dois a seis. A Tabela 5.21 apresenta os valores correspondentes

Tabela 5.21: Ordem e valores NRMSE dos modelos estimados pelo método direto compensado para o cenário 2 do sistema 2x2

Canal		Ordem	2	3	4	5	6
		ARX	$(h_1 \times v_2)$	30,6571	59,1845	75,5167	78,2112
	$(h_2 \times v_1)$	6,3816	37,4707	46,0557	46,9125	40,8627	
OE	$(h_1 \times v_2)$	59,7288	96,0313	96,2287	96,6494	96,8279	
	$(h_2 \times v_1)$	89,31	91,5971	91,7748	88,5009	85,7210	
BJ	$(h_1 \times v_2)$	59,7288	96,6706	96,9312	97,2945	97,5169	
	$(h_2 \times v_1)$	89,6015	91,6055	92,4207	88,5991	85,8477	

De acordo com a Tabela 5.21, os melhores valores de NRMSE foram obtidos para os modelos dos canais $(h_1 \times v_2)$ e $(h_2 \times v_1)$ com ordem, respectivamente, 5 e 5 para a estrutura ARX, 6 e 4 para a estrutura OE e 6 e 4 para a estrutura BJ. Analogamente ao que foi feito no cenário descrito na seção 5.3.1, obteve-se modelos de menores ordens através de uma nova identificação. Assim, um modelo de função de transferência foi identificado, utilizando a função *tfest* do *System Identification Toolbox*, variando a ordem dos modelos de 1 a 3. A Tabela 5.22 apresenta os valores NRMSE dos modelos para cada ordem da função de transferência (Ordem FT).

Tabela 5.22: Ordem e valores NRMSE da redução de ordem os modelos estimados pelo método direto compensado para o cenário 2 do sistema 2x2

Canal		Ordem FT	1	2	3
ARX	$(h_1 \times v_2)$		71,4949	42,5338	86,8068
	$(h_2 \times v_1)$		90,2427	24,4769	99,2774
OE	$(h_1 \times v_2)$		86,3013	92,0001	91,9840
	$(h_2 \times v_1)$		51,7864	52,5011	82,289
BJ	$(h_1 \times v_2)$		86,3013	92,0001	91,984
	$(h_2 \times v_1)$		90,2427	24,4769	99,2774

De acordo com a Tabela 5.22, a melhor ordem das funções de transferência estimadas para os canais $(h_1 \times v_2)$ e $(h_2 \times v_1)$ foram, respectivamente, 3 e 3 para o modelo original ARX, 2 e 3 para o modelo original OE e 2 e 3 para o modelo original BJ. A resposta degrau unitário dos modelos identificado bem como da planta real está ilustrada na Figura 5.20.




Figura 5.20: Resposta degrau dos modelos identificados pelo método direto compensado para o cenário 2 do sistema 2x2

Na sequência, realizou-se a identificação com o método do erro nominal analogamente à forma com a qual ele foi configurado e descrito na seção 5.3.1. Variou-se a ordem dos modelos de estrutura função de transferência entre 1 e 4. A Tabela 5.23 apresenta os valores de RMSE calculados no tempo de subida entre as respostas degrau da planta e das funções de transferência estimadas para cada ordem (Ordem FT).

Tabela 5.23: Ordem e valores RMSE entre a resposta degrau dos modelos estimados pelo método do erro nominal e da planta para o cenário 2 do sistema 2x2

Ordem FT Canal	RMSE			
	1	2	3	4
$(h_1 \times v_2)$	0,1412	0,0535	0,0548	0,5639
$(h_2 \times v_1)$	0,2080	0,0781	0,0858	0,3008

De acordo com a Tabela 5.23, os menores valores de RMSE foram obtidos para uma função de segunda ordem para ambos os canais $(h_1 \times v_2)$ e $(h_2 \times v_1)$. A resposta degrau dos modelos identificados está ilustrada na Figura 5.21. O modelo identificado pelo método do erro nominal está representado por G_N .




Figura 5.21: Resposta degrau dos modelos identificados pelo MEN para o cenário 2 do sistema 2x2

Em seguida, o modelo da planta também foi identificado com o método indireto de dois estágios, analogamente à forma com a qual ele foi configurado e descrito na seção

5.3.1, para fins de comparação. A Tabela 5.24 apresenta a ordem dos melhores modelos estimados e seus respectivos NRMSE.

Tabela 5.24: Ordem e valores NRMSE das funções de sensibilidade estimados pelo método indireto de dois estágios para o cenário 2 do sistema 2x2

Ordem Estrutura	<i>NRMSE</i>				
	6	7	8	9	10
ARX	96,5079	97,5111	97,7341	97,9798	98,0662
OE	91,1461	91,1216	94,5584	86,8339	85,6650
BJ	91,1461	91,1612	94,8136	87,8431	87,9341

De acordo com a Tabela 5.24, os maiores valores de NRMSE na estimação da função de sensibilidade foram obtidos para os modelos ARX, OE e BJ com ordem igual a, respectivamente, 10, 8 e 8. Utilizando estes modelos da função de sensibilidade para gerar um novo sinal como entrada na identificação do modelo da planta, como na Eq. (2.20), o modelo da planta foi identificado também com estruturas ARX, OE e BJ, variando-se as ordens dos polinômios entre 2 e 6, com ordem do tempo morto igual a 1. A Tabela 5.25 apresenta os valores de NRMSE obtidos para os modelos estimados.

Tabela 5.25: Ordem e valores NRMSE dos modelos da planta estimados pelo método indireto de dois estágios para o cenário 2 do sistema 2x2

Ordem Estrutura	<i>NRMSE</i>				
	2	3	4	5	6
ARX	85,2353	62,7917	78,0033	74,0886	77,0525
OE	61,5752	97,0862	97,9037	91,1266	90,2582
BJ	67,3997	67,3895	97,9521	91,5788	94,4954

Como pode ser observado na Tabela 5.25, os maiores valores de NRMSE foram obtidos para os modelos ARX, OE e BJ com ordem igual a 4 para as três estruturas. A Figura 5.22 ilustra a resposta degrau dos modelos identificados bem como da planta.




Figura 5.22: Resposta degrau dos modelos identificados pelo método dos dois estágios para o cenário 2 do sistema 2x2

Como ilustra a Figura 5.22, os modelos OE e BJ de quinta ordem identificados são equivalentes. Assim, uma redução de ordem foi realizada utilizando apenas o modelo BJ, visando obter uma estrutura similar àquelas obtidas para o método direto compensado e do erro nominal. Um modelo de função de transferência foi identificado, utilizando a função *tfest* do *System Identification Toolbox*, variando a ordem dos modelos de 1 a 3. A Tabela 5.26 apresenta os valores NRMSE dos modelos para cada ordem da função de transferência (Ordem FT).

Tabela 5.26: Ordem e valores NRMSE da redução de ordem do modelo da planta estimado pelo método indireto de dois estágios para o cenário 2 do sistema 2x2

Canal Ordem	NRMSE			
	$(h_1 \times v_1)$	$(h_1 \times v_2)$	$(h_2 \times v_1)$	$(h_2 \times v_2)$
1	62,5611	77,8577	62,1177	88,8472
2	82,4103	83,6109	94,6758	89,5688
3	90,5539	93,2293	95,4674	95,5884

Para comparar os modelos identificados com as metodologias utilizadas (MDC, MEN e Dois estágios) foi feita uma análise do zero da transmissão para cada modelo MIMO obtido. A Tabela 5.27 mostra o RHP-zero e as correspondentes direções de entrada (u_z) e saída (y_z) dos modelos identificados em comparação com a planta real.

Tabela 5.27: Zero de transmissão e suas direções de saída e entrada para os modelos identificados para o cenário 2 do sistema 2x2

Modelo	Planta	MDC	MEN	Dois estágios		
RHP-zero	0,0130	0,0189	0,0127	0,0212+0,0285i	0,0212-0,0285i	
Direção						
MV1	y_z	-0,6264	-0,6181	-0,6096	0,5337	0,5337
	u_z	0,7417	-0,7311	0,7569	-0,6943	-0,6943
MV2	y_z	0,7794	0,7860	0,7927	-0,3089	-0,3089
	u_z	-0,6707	0,6757	-0,6535	0,5917	0,5917

Como pode ser observado na Tabela 5.27, entre os dois métodos propostos, o método do erro nominal obteve maior acurácia na captura do zero de transmissão (2,31% de erro relativo ao zero da planta) e suas direções de saída e entrada, enquanto o método direto compensando obteve um valor de zero superior (45,38% de erro relativo) ao da planta. O método de dois estágios, por sua vez, divergiu no valor do zero, encontrando um valor correspondente a números complexos conjugados, discordando tanto na magnitude quanto na direção de saída e entrada do zero. Devido à presença do distúrbio, o método não consegue distinguir se a dinâmica presente no sinal das saídas medidas é de fato proveniente da dinâmica da planta ou devido ao distúrbio, como explanado por LJUNG (1987). O mesmo aconteceu para o método direto compensando, por este ser um aplicação específica do método direto focada apenas no canal mais discrepante, mas com menor discrepância com o zero da planta devido a compensação do sinal de saída, que elimina parte da interferência do distúrbio não medido.

A Figura 5.23 ilustra o elemento dominante λ_{ij} do RGA dinâmico da planta e dos modelos identificados. Pode-se observar como o modelo identificado pelo método do erro nominal captura o comportamento do RGA da planta em todas as frequências avaliadas, possuindo um pequeno *bias* para o range de baixas frequências. O método direto compensando possui discrepância no range de frequências intermediárias, mas captura o RGA dinâmico da planta para o restante do range. Por outro lado, o modelo identificado pelo método de dois estágios apresenta grandes discrepâncias em todo o espectro de frequências, demonstrando uma eminente deterioração da qualidade do modelo para fins de controle, especialmente para o caso de um ajuste mais agressivo do controlador (ex.: pequeno peso de supressão de movimento), que altera a frequência do controlador para o range intermediário.





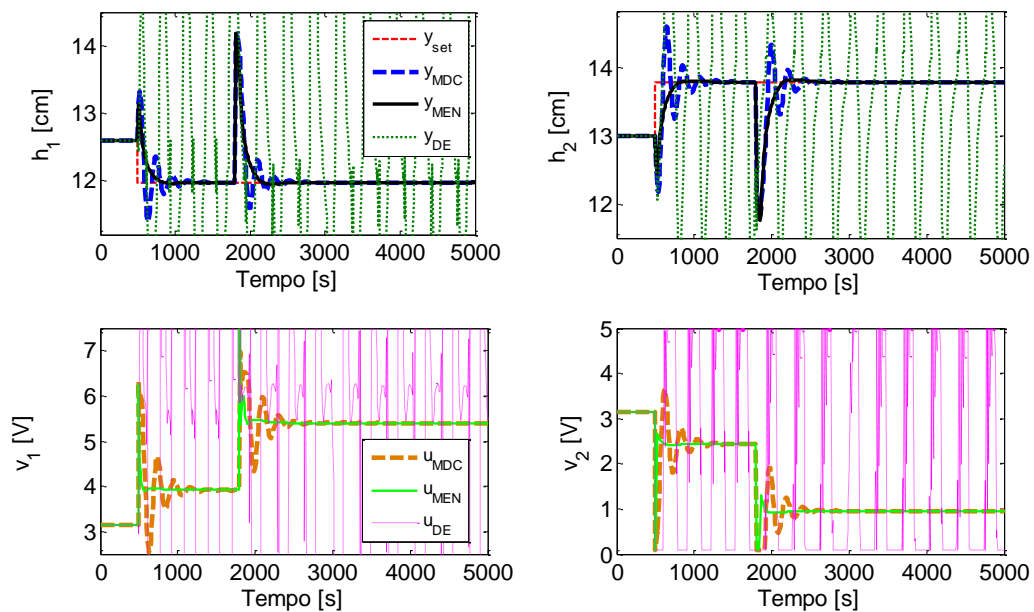
Figura 5.23: Elemento dominante λ_{ij} do RGA dinâmico dos modelos identificados e da planta para o cenário 2 do sistema 2x2

Como exposto por JOHANSSON (2000), o RGA para o sistema de quatro tanques é puramente dependente das aberturas das válvulas do sistema, cujos valores foram utilizados para linearizar o modelo não-linear, equações de (5.9) a (5.12). No caso de fase não-mínima, que foi utilizada nesta dissertação com o modelo da Equação (5.13), a análise do RGA sugere que a melhor configuração entrada-saída é dada pelos elementos fora da diagonal principal, ou seja, h_1 controlado por v_2 e h_2 controlado por v_1 . Assim, esses canais possuem maior influência no controle do sistema, o que justifica que uma discrepância de modelo dos mesmos tem maior peso na deterioração da degradação do desempenho do que aquela apresentada no cenário 1 (seção 5.3.1).

Para ilustrar o impacto da determinação correta das direções de saída e entrada do zero, os modelos identificados foram usados no controlador para simular a malha fechada com duas perturbações: uma variação de *setpoint* na direção $y_z = [-0,6264, 0,7794]$ e uma perturbação de carga na direção $u_z = [0,7417, -0,6707]$. Estas direções correspondem, respectivamente, às direções de saída e entrada do zero de transmissão do modelo da planta, como mostrado na Tabela 5.19. Além disso, a simulação foi realizada para um ajuste brando do MPC, com matriz de supressão de movimento $MS = [50 \ 50]$, e um ajuste agressivo, com $MS = [0 \ 0]$. A Figura 5.24 ilustra as entradas e saídas da planta para os ajustes brando (a) e agressivo (b) do controlador.



(a)



(b)

Figura 5.24: Entradas e saída da malha fechada com os modelos identificados para o cenário 2 do sistema 2x2 para um (a) ajuste brando do controlador (b) ajuste agressivo do controlador

Conforme observado na Figura 5.24, para o ajuste agressivo do controlador, o sistema com o modelo identificado em dois estágios se tornou instável. Devido ao ajuste agressivo, a frequência de atuação do controlador entra na faixa das frequências intermediárias, como explicado na Figura 5.23, onde o modelo identificado com o método de dois estágios demonstra deterioração na qualidade, uma vez que as direções da mudança de *setpoint* e perturbação de carga ocorrem nas direções de saída e entrada do

zero da planta. Por outro lado, como os modelos identificados com as metodologias proposta capturaram a direção correta do zero da planta, os modelos foram capazes de lidar com os ajustes brando e agressivo do controlador, sendo a resposta do modelo identificado pelo método direto compensado mais oscilatória devido à discrepância no valor do zero de transmissão em relação ao zero da planta.

5.3.3 Sistema 4x4 por faixas

Dados foram gerados a partir da simulação do processo considerando as discrepâncias já discutidas na seção 5.2.2. As entradas e saídas do processo estão ilustradas nas Figura 5.25 e Figura 5.26.




Figura 5.25: Sinais das variáveis controladas para o sistema 4x4 por faixas




Figura 5.26: Sinais das variáveis manipuladas e *target* para o sistema 4x4 por faixas

A Figura 5.27 mostra os indicadores de variância e variância diagonal obtidos na auditoria. A linha vermelha tracejada corresponde ao valor unitário para os indicadores I_{var} e $I_{var_{diag}}$, correspondente à homogeneidade ou igualdade entre as variâncias de y e y_N e entre y e $y_{N_{diag}}$. Para ambos indicadores, o resultado indica o aumento da variância na saída do controlador.




Figura 5.27: Auditoria e diagnóstico por CV para o sistema 4x4 por faixas

A Tabela 5.28 apresenta os resultados do teste F de Levene para igualdade de variâncias. Para um nível de significância $\alpha = 5\%$, rejeita-se a hipótese nula (de que as variâncias são iguais) para valores de $p - value$ inferiores a 0,05.

Tabela 5.28: Resultados do teste F de Levene para igualdade de variâncias para o sistema de quatro tanques por faixas

Variável	I_{var}	$p - value$	$I_{var\ diag}$	$p - value$
h_1	1,2498	0,0028	1,2011	0,0069
h_2	1,1264	0,0310	1,1065	0,0009
h_3	1,0423	0,7046	1,0467	0,9584
h_4	1,3342	0,0025	1,0561	0,0934

De acordo com a Tabela 5.28, os resultados de $p - value$ para os indicadores I_{var} e $I_{var\ diag}$ encontram-se acima de 0,05 para a saída h_3 , ou seja, aceita-se a hipótese nula (de igualdade de variâncias) para um nível de significância de $\alpha = 5\%$. As saídas h_1 e h_2 , por sua vez, apresentou os resultados do $p - value$ para os indicadores I_{var} e $I_{var\ diag}$ abaixo de 0,05, ou seja, as variância não são iguais para um nível de significância de $\alpha = 5\%$. A saída h_4 também possui algum erro de modelagem, pois o resultado do $p - value$ para o indicador I_{var} está abaixo de 0,05 e suas variâncias são maiores que suas respectivas saídas para o caso nominal ($I_{var} > 1$). Este erro de modelagem, entretanto, não ocorre devido ao erro presente no modelo da própria variável (mas sim devido ao erro presente nas demais), pois o resultado do $p - value$ para o indicador $I_{var\ diag}$ encontra-se acima de 0,05.

A etapa de diagnóstico por CV foi realizado na sequência. A Figura 5.28 apresenta os coeficiente médios de correlação para as distribuições de curtose e assimetria dos sinais $y_{N\ diag}$ e $e_{N\ diag}$. Observa-se que, para as saídas diagnosticadas com erro de modelagem (h_1, h_2 e h_4), os coeficiente médios de correlação, para ambas as distribuições (curtose e assimetria) ultrapassam o limite definido pelo intervalo de confiança CI (indicado pela linha vermelha tracejada), obtido pela Equação (3.17). Assim, conclui-se que a fonte predominante dos erros de modelagem para estas saídas. é MPM




Figura 5.28: Diagnóstico da fonte dos erros de modelagem para o sistema 4x4 por faixas

Com o diagnóstico predominante de discrepância entre modelo e planta, o próximo passo consiste em localizar a MV mais relacionada ao erro de modelo. A Tabela 5.29 mostra os valores encontrados do indicador *MDI* e a Figura 5.29 o gráfico de barras para o indicador *NMDI*. De acordo com valores encontrados, as variáveis manipuladas mais relacionadas à discrepância de modelo para a CVs 1, 2 e 4 são, respectivamente, as MVs 1, 2 e 3. Logo, os canais diagnosticados como mais discrepantes são: $(h_1 \times v_1)$, $(h_2 \times v_2)$ e $(h_4 \times x_1)$.

Tabela 5.29: Indicador *MDI* para o sistema de quatro tanques por faixas

Variável	<i>MDI</i>			
	v_1	v_2	x_1	x_2
MV				
CV				
h_1	0,8702	0,3380	0,4119	0,3413
h_2	0,4068	0,5578	0,1591	0,3164
h_4	0,2951	0,2435	0,7020	0,3313

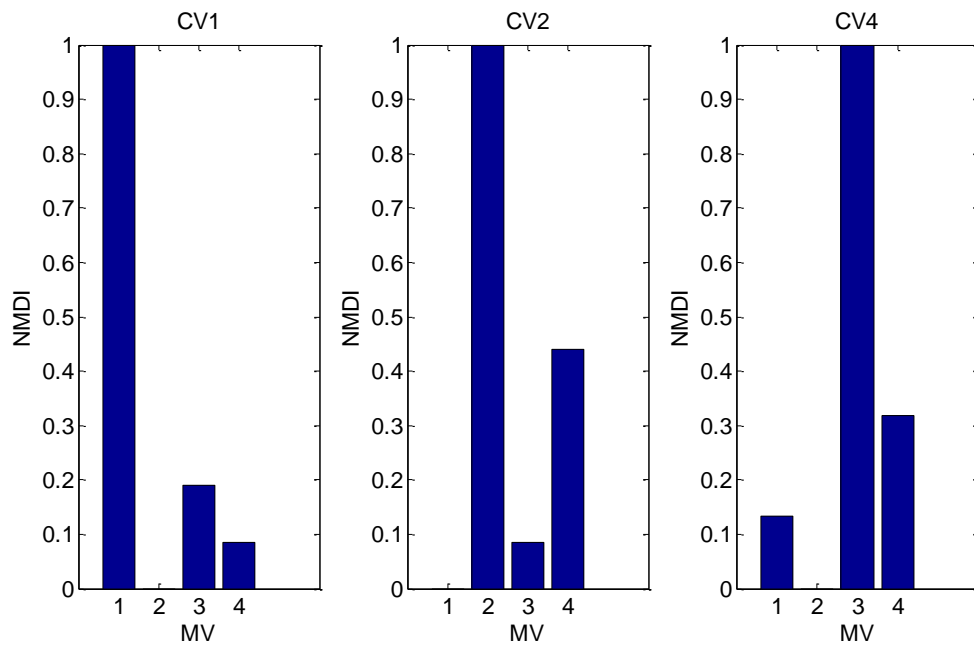


Figura 5.29: Localização da MV mais relacionada à discrepância de modelo para o sistema 4x4 por faixas para (a) a variável h_2 (b) a variável h_3 (c) a variável h_4

Como o indicador *MDI* indica o canal mais afetado pela MPM para uma dada saída, a metodologia para reidentificação de modelos foi realizada apenas para corrigir tais canais.

Primeiramente, realizou-se a identificação com o método direto compensado, como descrito na seção 4.1. A Tabela 5.30 apresenta a ordem dos melhores modelos estimados e o correspondente erro quadrático médio normalizado NRMSE para os canais identificados.

Tabela 5.30: Ordem e valores NRMSE dos modelos estimados pelo método direto compensado para o sistema 4x4 por faixas

Canal	Ordem	2	3	4	5	6
ARX	$(h_1 \times v_1)$	87,7665	87,1484	87,6014	88,0144	88,2745
	$(h_2 \times v_2)$	15,1737	55,7289	38,8694	42,17752	36,1759
	$(h_4 \times x_1)$	50,3360	-63,1654	39,6280	26,1256	31,8648
OE	$(h_1 \times v_1)$	93,0336	93,1984	-25,9122	93,2751	93,2269
	$(h_2 \times v_2)$	88,5666	88,8864	88,9929	89,0366	89,0344
	$(h_4 \times x_1)$	97,9546	98,0074	98,0041	98,0120	97,9934
BJ	$(h_1 \times v_1)$	93,0659	93,2033	-25,9122	93,2306	93,2871
	$(h_2 \times v_2)$	88,5992	88,9291	89,5529	89,1581	89,4616

$(h_4 \times x_1)$	97,9547	98,0076	98,0041	98,0169	98,0113
--------------------	---------	---------	---------	----------------	---------

De acordo com a Tabela 5.30, os melhores valores de NRMSE foram obtidos para os modelos dos canais $(h_1 \times v_1)$, $(h_2 \times v_2)$ e $(h_4 \times x_1)$ com ordem, respectivamente, 6, 3 e 2 para a estrutura ARX, 5, 5 e 5 para a estrutura OE e 6, 4 e 5 para a estrutura BJ. Analogamente ao que foi feito nas seções 5.3.1 e 5.3.2, obteve-se modelos de menores ordens através de uma nova identificação. Assim, um modelo de função de transferência foi identificado, utilizando a função *tfest* do *System Identification Toolbox*, variando a ordem dos modelos de 1 a 3. A Tabela 5.31 apresenta os valores NRMSE dos modelos para cada ordem da função de transferência (Ordem FT).

Tabela 5.31: Ordem e valores NRMSE da redução de ordem os modelos estimados pelo método direto compensado para o sistema 4x4 por faixas

Ordem FT		1	2	3
Canal				
ARX	$(h_1 \times v_1)$	86,1127	97,7303	87,6566
	$(h_2 \times v_2)$	94,8990	97,7867	98,8347
	$(h_4 \times x_1)$	96,4251	99,72540	2,2130
OE	$(h_1 \times v_1)$	95,2910	94,0191	94,3557
	$(h_2 \times v_2)$	77,6197	77,5993	82,0296
	$(h_4 \times x_1)$	99,4683	99,7876	99,7838
BJ	$(h_1 \times v_1)$	94,2910	95,0191	94,2557
	$(h_2 \times v_2)$	77,6683	96,7447	95,8952
	$(h_4 \times x_1)$	99,7825	99,46837	99,7838

De acordo com a Tabela 5.31, a melhor ordem das funções de transferência estimadas para os canais $(h_1 \times v_1)$, $(h_2 \times v_2)$ e $(h_4 \times x_1)$ foram, respectivamente, 2, 3 e 2 para o modelo original ARX, 1, 3 e 2 para o modelo original OE e 2, 2 e 1 para o modelo original BJ. A resposta degrau unitário dos modelos identificado bem como da planta real está ilustrada na Figura 5.30.




Figura 5.30: Resposta degrau dos modelos identificados pelo método direto compensado para o sistema 4x4 por faixas

Na sequência, realizou-se a identificação utilizando o método sequencial, como descrito na seção 4.3. A metodologia foi realizada com o algoritmo sem restrições Nelder-Mead utilizando a função *fminsearch* no Matlab® R2102b. A matriz peso da função objetivo foi escolhida como sendo uma matriz identidade de ordem igual àquela do erro nominal. O modelos dos canais $(h_1 \times v_1)$, $(h_2 \times v_2)$ e $(h_4 \times x_1)$ utilizados como estimativa inicial foram os obtidos na etapa de redução de ordem para o modelo BJ obtido pelo método direto compensado. A Tabela 5.32 apresenta os valores de RMSE calculados no tempo de subida entre as respostas degrau da planta e do modelo estimado. A resposta degrau do modelo identificado está ilustrada na Figura 5.31.

Tabela 5.32: RMSE entre a resposta degrau dos modelos estimados pelo método sequencial e da planta para o sistema 4x4 por faixas

Canal	RMSE
$(h_1 \times v_1)$	0,0187
$(h_2 \times v_2)$	0,1091
$(h_4 \times x_1)$	0,2643




Figura 5.31: Resposta degrau dos modelos identificados pelo método sequencial para o sistema 4x4 por faixas

Para fins de comparação, utilizou-se o método direto completo, encontrado na literatura (LJUNG, 1987) e discutido na seção 2.1.1, para identificar o modelo da planta, uma vez que o método é mais adequado para sistemas que trabalham por restrições flexíveis do que o método de dois estágios (que necessita estimar a função de sensibilidade usando um sinal de *setpoint*). Para tal, utilizou-se a ferramenta *System Identification Toolbox* do Matlab® R2012b com os ajustes polinomiais OE e BJ, variando-se as ordens dos polinômios no range entre dois e seis para estimar o modelo da planta, mantendo a ordem do termo de tempo mortal igual a 1. A Tabela 5.33 apresenta os valores de NRMSE para os modelos obtidos.

Tabela 5.33: Ordem e valores NRMSE dos modelos da planta estimados pelo método direto completo para o sistema 4x4 por faixas

Ordem Estrutura	NRMSE				
	2	3	4	5	6
OE	93,5264	60,1489	84,6742	98,6519	94,1456
BJ	93,551	72,2775	96,4329	99,1533	99,6869

De acordo com a Tabela 5.33, os maiores valores de NRMSE foram obtidos para os modelos de ordem para a estrutura OE e BJ, respectivamente. As respostas degrau unitário dos modelos identificados e da planta real estão ilustradas na Figura 5.32. Para se compara a adereção do modelo com a planta real para diferentes frequências, o diagrama de Bode de magnitude, em dB, por frequência, em rad/s, para os canais $(h_1 \times v_1)$, $(h_2 \times v_2)$ e $(h_4 \times x_1)$ estão ilustrados na Figura 5.33.

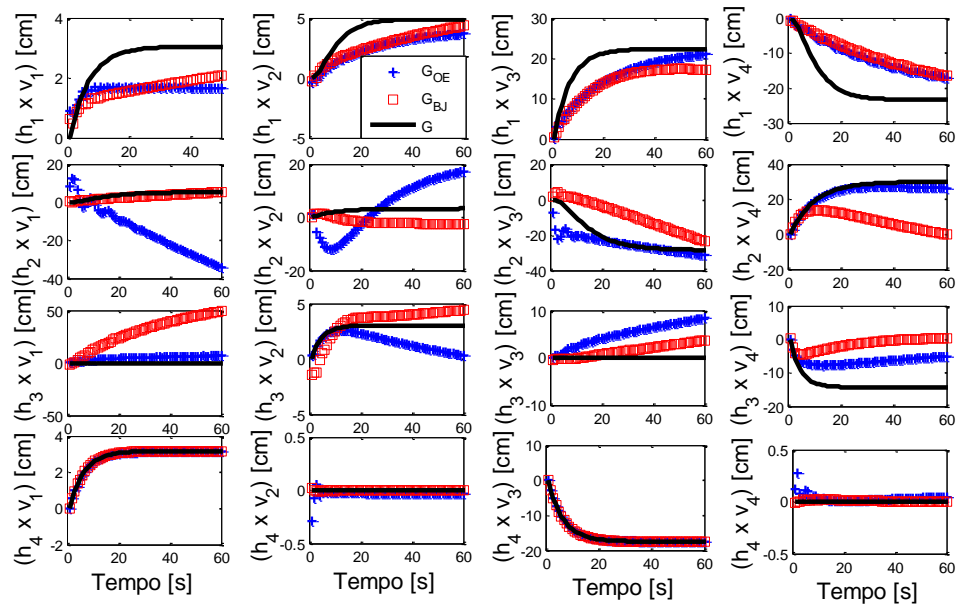


Figura 5.32: Respostas degrau dos modelos da planta e identificados pelo método direto para o sistema 4x4 por faixas




Figura 5.33: Diagrama de Bode Magnitude (Db) versus Frequência [rad/s] para os modelos identificados e da planta para o sistema 4x4 por faixas

Como pode ser observado na Figura 5.33, o método sequencial foi capaz de capturar a magnitude do modelo da planta em todo o range de frequência para os três canais identificados. O método direto, por sua vez, diverge para altas frequências nos modelos de $(h_1 \times v_1)$ e $(h_2 \times v_2)$. Além disso, como pode ser observado na Figura 5.32, o método

direto, que identifica o modelo por completo, não foi capaz de estimar corretamente todos os canais do modelo.

Para ilustrar a qualidade das estimações, os modelos identificados foram usados no controlador para simular a malha fechada com uma perturbação na faixa superior flexível e uma perturbação de carga. A Figura 5.34 e a Figura 5.35 ilustram as entradas e saídas da planta, respectivamente, utilizando os modelos identificados pelo método direto compensando (MDC), método sequencial (MS) e o método direto (Direto).

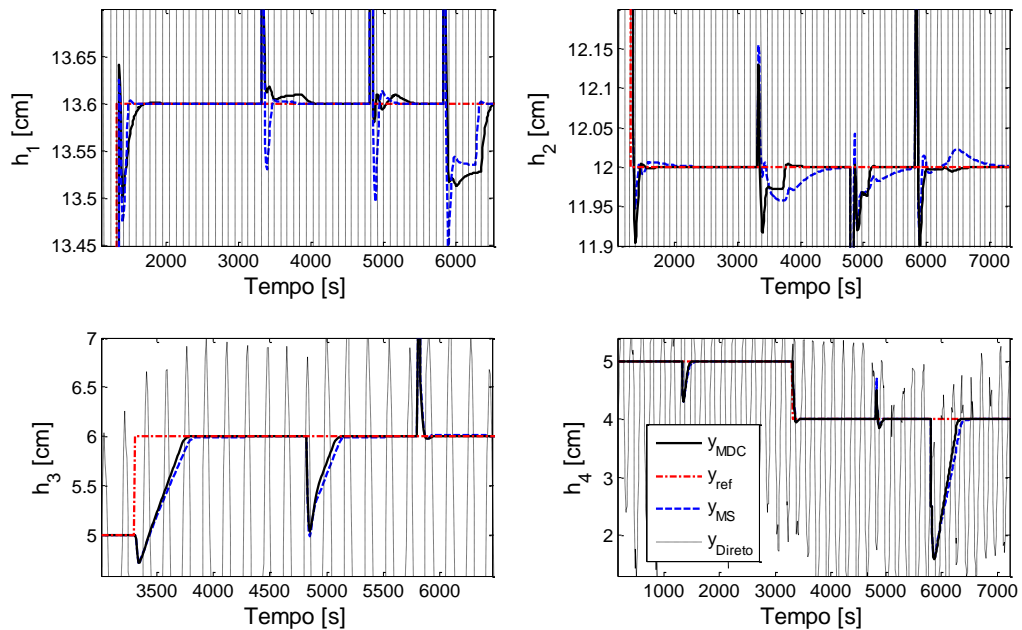


Figura 5.34: Saídas da malha fechada com os modelos identificados para o sistema 4x4 por faixas

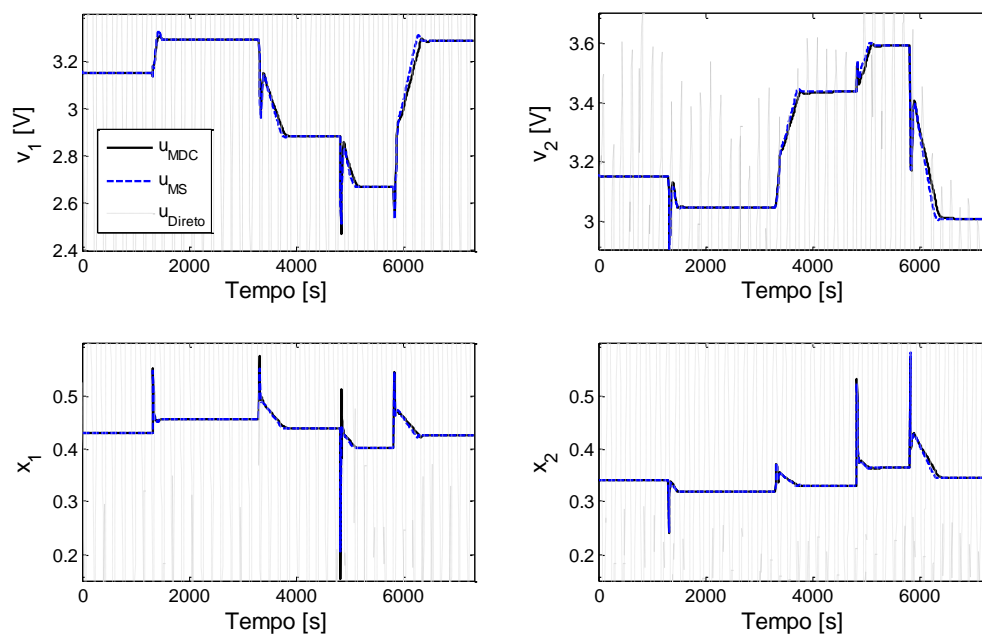


Figura 5.35: Entradas da malha fechada com os modelos identificados para o sistema 4x4 por faixas

Como pode ser observado na Figura 5.34 e na Figura 5.35, o modelo identificado pelo método sequencial foi o que apresentou menores ações de controle para atenuar as perturbações no sinal de referência (limite superior flexível) e de carga. Para o modelo identificado pelo método direto completo, por sua vez, não houve saturação das MVs assim como para os outros dois modelos, mas o sistema não é capaz de se estabilizar o limite superior da restrição flexível, causando uma oscilação constante a partir da primeira perturbação (no sinal de referência). Mesmo que a planta real não apresentou um zero de transmissão, o método direto ainda é influenciado pela presença do distúrbio não medido. Com isso, o método não consegue distinguir se a dinâmica presente no sinal das saídas medidas é de fato proveniente da dinâmica da planta ou devido ao distúrbio, como explanado por LJUNG (1987), agregando a dinâmica do distúrbio no modelo identificado. O método sequencial, por sua vez, utiliza a função de sensibilidade para isolar a parcela do sinal da saída medida que contém o erro de modelagem. Ao isolar esta parcela, o método é capaz de realizar a identificação do modelo sem perder qualidade devido ao distúrbio não medido, pois este também é isolado pela filtração com a função de sensibilidade nominal, o que leva a minimização do erro de modelo sem agregar a dinâmica do distúrbio no modelo identificado.

Capítulo 6 – Conclusões e Trabalhos Futuros

6.1 Principais conclusões

O desempenho de controladores preditivos está fortemente atrelado com a qualidade do modelo do processo. Logo, os métodos utilizados para identificar um novo modelo devem ser capazes de capturar a dinâmica da planta sem sofrer grandes perdas de qualidade devido, por exemplo, à presença de distúrbios não medidos, que são a principal fonte de erros nas técnicas de identificação de sistema. Além disso, o método deve ser capaz de identificar um modelo robusto que possa atuar em diferentes ranges de frequências, uma vez que, ao se alterar o ajuste do controlador, a frequência de atuação do sistema também se altera.

Neste trabalho foram sugeridas duas metodologias para identificação de modelos discrepantes em MPCs. As principais vantagens da metodologia proposta frente às metodologias clássicas de identificação em malha fechada são:

- Não necessita de testes na planta, pois utiliza dados históricos de processo.
- Foco na identificação apenas na parcela do modelo que efetivamente está afetando o desempenho do controlador, tornando o processo de identificação mais rápido e menos complexo
- Minimização do tempo do controlador com desempenho insatisfatório, tanto pelo fato da menor carga de trabalho para identificar apenas os modelos discrepantes, quanto pela maior facilidade de implementação dos modelos identificados no processo real, que necessita substituir apenas poucos canais ao invés de toda a matriz dinâmica do processo.
- Isolamento da parcela do sinal das saídas medidas da planta que representa a discrepância de modelo, o que leva à uma identificação da dinâmica da planta sem agregar a dinâmica de possíveis distúrbios presentes na malha;

Para avaliar as metodologias propostas foram considerados estudos de caso simulados referente ao sistema de quatro tanques cilíndricos (JOHANSSON, 2000), considerando diferentes estruturas de controle. Os estudos de caso apresentados contemplam o diagnóstico completo do modelo, o qual vai desde a detecção de problemas de modelagem até a correção do modelo. Para isso, a metodologia proposta foi associada aos métodos de auditoria e diagnóstico propostos por BOTELHO et al. (2015) e BOTELHO; TRIERWEILER; FARENZENA (2016) e CLARO (2016). Para fins comparativos, utilizou-se os métodos direto e indireto em dois estágios, ambas as quais são abordadas na literatura (FORSSELL; LJUNG, 1999; LJUNG, 1987) para identificação em malha fechada.

No estudo de caso do sistema de quatro tanques cilíndricos trabalhando por *setpoint*, as metodologias apresentaram resultados superiores aqueles obtidos com o método indireto de identificação em dois estágios. O método indireto de dois estágios teve sua eficácia prejudicada pelo distúrbio não medido presente nos sinais utilizados na identificação. O mesmo ocorreu para o método direto compensado, por este ser uma modificação do método direto de identificação em malha fechada para se identificar apenas os canais que foram previamente diagnosticados como contendo erro de modelo. Entretanto, devido à compensação do sinal de saída com a simulação dos canais acusados como possuindo modelo adequado, o sinal resultante consegue eliminar parte da interferência do distúrbio, identificando assim um modelo mais apropriado com a dinâmica da planta real. O método do erro nominal, por sua vez, teve resultados superiores em ambos os cenários (discrepância dentro ou fora da diagonal principal da matriz de transferência), pois a função de sensibilidade filtra a saída da planta e isola a parte do sinal que é proveniente da discrepância de modelo, o que possibilitou que a discrepância fosse minimizada. Para o cenário 1 (discrepância na diagonal principal), as metodologias propostas encontram um modelo cujo zero de transmissão possuía baixo erro relativo em relação ao zero da planta, além de que os modelos identificados tiveram RGA dinâmico do elemento dominante, ou seja, fora da diagonal principal, que capturaram o RGA da planta em todo o range de frequências avaliado. Como a configuração de pareamento fora da diagonal principal apresenta maior potencial para controle do sistema 2x2 em fase não mínima, foi observado, no cenário 2 (discrepância fora da diagonal principal), que quando estes são os modelos discrepantes, a metodologia apresenta maior dificuldade na identificação de novos modelos. Entretanto, o método do erro nominal foi capaz de identificar um modelo com baixo erro relativo no zero de transmissão, enquanto o método direto apresentou erro relativo significativo no valor de zero de transmissão do modelo identificado.

No estudo de caso do sistema de quatro tanques cilíndricos trabalhando por faixas, as metodologias também apresentaram resultados superiores à metodologia utilizado como comparação, o método direto de identificação em malha fechada. Novamente, o método concorrente sofreu fortes influências da presença do distúrbio não medido, não eliminado corretamente a discrepância entre o modelo da planta e o utilizado no controlador. O método direto compensado, por sua vez, conseguiu amenizar esta discrepância, o que garantiu um modelo adequado para ser utilizado como estimativa inicial no método do erro nominal. Assim, o método sequencial foi capaz de identificar modelos cuja resposta degrau se sobreponha à resposta da planta, além de identificar o

ganho adequado no range de frequências avaliado, como foi mostrado pelo diagrama de Bode.

Por fim, com base nos estudos de casos realizados, recomendam-se as seguintes práticas para obtenção de bons resultados na utilização da metodologia:

- Com relação a etapa de auditoria e localização dos canais mais discrepantes, selecionar vários cenários de operação do controlador (planta operando a alta capacidade, planta operando a baixa capacidade, etc.) para avaliar o desempenho dos modelos em diferentes cenários. Isto garante que o modelo indicado a ser identificado é discrepante o bastante, de modo que, ao se identificar um novo modelo, este será abrangente caso as condições de operação se alterem;
- Na janela de dados escolhida para auditoria, realizar um tratamento para eliminação de estacionários antes da aplicação do teste F de Levene para se comprovar (ou refutar) a igualdade de variâncias para os indicadores I_{var} e $Ivar_{diag}$. Devido a sensibilidade desta análise estatística, é necessário garantir que a variância que se deseja comparar é relativa aos dados que indiquem a dinâmica da planta, pois é neste período que a presença de erros de modelagem estará explícita;
- Definir um ponto de corte para priorizar a revisão dos modelos com maiores discrepâncias, levando em conta não só o indicador MDI (ou $NMDI$), mas outros fatores que indiquem a magnitude da discrepância (como as variáveis que apresentem $Ivar_{diag}$ acima de 1,5);
- Dentre os dados históricos de processo disponíveis, selecionar os dados visando obter janelas de tempo nas quais todas as variáveis manipuladas estão disponíveis e sendo otimizadas (isto é, ações de controle estão sendo tomadas). Além disso, priorizar as janelas que contenham diferentes variações no *setpoint* (ou na faixa flexível) para as CVs, de modo que os dados sejam ricos na dinâmica da planta (por exemplo, degrau negativo e positivo nestes sinais de referências);
- Para bom funcionamento do método direto compensado, garantir que a obtenção do sinal de saída compensado seja feita para uma janela de dados na qual houve variação na saída analisada (ver item anterior). Além disso, deve-se usar os modelos dos demais canais desta saída (ou seja, todos menos o canal dado como mais discrepante) que eram utilizados no período de tempo referente à janela de dados que utilizará para a auditoria e identificação. Caso uma mudança de modelos já tenha sido efetuado, recomenda-se refazer a seleção de janelas de dados para um período que contenha a atuação já com os novos modelos;
- Para uma estimativa mais rápida do modelo de um canal, pode-se utilizar o método do erro nominal utilizando a matriz S_0 inicial que foi obtida para auditoria dos modelos. Para isto, é necessário que esta matriz seja obtida em um ambiente nativo do controlador para capturar o efeito da sintonia do controlador, penalidades consideração no otimizador, etc.. Se não houveram grandes mudanças no ajuste do controlador e nas condições de atuação do

mesmo (mudanças de limites rígidos para as variáveis, etc.), a estimativa inicial de S_0 não sofrerá grandes alterações para a mudança do modelo, não necessitando, portanto, de uma atualização desta a cada iteração do método do erro nominal;

- Se algum conhecimento sobre a estrutura do modelo da planta estiver disponível (como possíveis valores de constante de tempo ou tempo morto), este conhecimento pode ser utilizado para uma estimativa inicial do modelo que se quer identificar para se inicializar os métodos propostos. Desta forma, será possível garantir uma maior eficácia do método na eliminação de discrepâncias estruturais;
- Após a implementação dos modelos identificados no controlador real, se sugere realizar a avaliação da qualidade destes novos modelos com uma nova auditoria, pois ela não só fornecerá uma referência de desempenho do controlador que poderá ser útil para comparação com as auditorias realizadas ao longo do seu ciclo de vida, mas também garante um novo diagnóstico se existem outros modelos, antes não dados como os mas discrepantes, que possam vir a afetar o desempenho do controlador.

6.2 Sugestões para trabalhos futuros

Com base no trabalho desenvolvido, recomendam-se os seguintes temas como trabalhos futuros para aprofundar e complementar os trabalhos de auditoria e identificação de modelos de controladores preditivos industriais:

- Desenvolver um método padronizado para escolha da janela de dados dos sinais y , y_N e $y_{N_{diag}}$ para realização do teste F de Levene sobre a igualdade de variâncias. Esta etapa deve levar em conta perturbações nestes sinais em períodos dinâmicos (não-estacionários) devido a diferentes fontes, como oriundas de uma perturbação no *setpoint* da própria variável analisada ou em outra variável (que acaba influenciando as outras, devido à característica intrínseca de sistemas MIMO de correlação entre as diversas variáveis);
- Avaliar um método automático de seleção das janelas de dados para períodos em que a variável controlada esteja otimizada e ações de controle estão sendo tomadas, além de incluir uma análise se a excitação presente nestes sinais é suficiente rica para fins de identificação;
- Aumentar a abrangência do método para utilizar estruturas não paramétricas como modelos para os canais que se deseja identificar. Desta forma, os métodos não ficarão restritos a eliminar somente discrepâncias paramétricas dos modelos, além de reduzir a necessidade de se saber a ordem do modelo antes da identificação propriamente dita;

-
- Estender o método para controladores descentralizados, visando-se identificar modelos para os canais nulos da matriz dinâmica deste tipo de arranje de controladores, e para controladores não-lineares.

-

Referências

AGUIERO, J. C.; GOODWIN, G. C.; VAN DEN HOF, P. M. J. A virtual closed loop method for closed loop identification. **Automatica**, v. 47, n. 8, p. 1626–1637, 2011.

BADWE, A. S. et al. Detection of model-plant mismatch in MPC applications. **Journal of Process Control**, v. 19, n. 8, p. 1305–1313, 2009.

BADWE, A. S. et al. Quantifying the impact of model-plant mismatch on controller performance. **Journal of Process Control**, v. 20, n. 4, p. 408–425, 2010.

BADWE, A. S.; PATWARDHAN, S. C.; GUDI, R. D. Closed-loop identification using direct approach and high order ARX/GOBF-ARX models. **Journal of Process Control**, v. 21, n. 7, p. 1056–1071, 2011.

BOTELHO, V. et al. Methodology for Detecting Model–Plant Mismatches Affecting Model Predictive Control Performance. **Industrial & Engineering Chemistry Research**, v. 54, n. 48, p. 12072–12085, 2015.

BOTELHO, V. R. **Auditoria e Diagnóstico de Modelos para Controladores Preditivos Industriais**. [s.l.: s.n.].

BOTELHO, V.; TRIERWEILER, J. O.; FARENZENA, M. Diagnosis of Poor Performance in Model Predictive Controllers: Unmeasured Disturbance versus Model–Plant Mismatch. **Industrial & Engineering Chemistry Research**, p. acs.iecr.6b00907, 2016.

CAMPOS, M. C. M. M.; GOMES, M. V. DE C.; PEREZ, J. M. G. T. **Controle Avançado e Otimização na Indústria do Petróleo.pdf**. [s.l.] Editora Interciência, 2013.

CLARO, E. R. P. **Localização de canais afetando o desempenho de controladores preditivos baseados em modelo**. [s.l.] Universidade Federal do Rio Grande do Sul, 2016.

DOMA, M. J.; TAYLOR, P. A.; VERMEER, P. J. Closed loop identification of MPC models for MIMO processes using genetic algorithms and dithering one variable at a time: Application to an industrial distillation tower. **Computers & Chemical Engineering**, v. 20, n. 96, p. S1035–S1040, 1996.

- FERRAMOSCA, A et al. Model predictive control suitable for closed-loop re-identification. **2013 American Control Conference**, v. 69, n. 1, p. 1709–1714, 2013.
- FORBES, M. G. et al. Model Predictive Control in Industry Challenges and Opportunities. **IFAC-PapersOnLine**, v. 48, n. 8, p. 531–538, 2015.
- FORSSELL, U.; LJUNG, L. Closed-loop identification revisited. **Automatica**, v. 35, p. 1215–1241, 1999.
- HUANG, B.; SHAH, S. **Performance Assessment of Control Loops**. [s.l.: s.n.].
- JI, G.; ZHANG, K.; ZHU, Y. A method of MPC model error detection. **Journal of Process Control**, v. 22, n. 3, p. 635–642, 2012.
- JIANG, H.; LI, W.; SHAH, S. L. **Detection and Isolation of Model-Plant Mismatch for Multivariate Dynamic Systems**. [s.l.] IFAC, 2006. v. 39
- JOHANSSON, K. H. The Quadruple-Tank Process : A Multivariable Laboratory Process with an Adjustable Zero. v. 8, n. 3, p. 456–465, 2000.
- KAMMER, L. C.; GORINEVSKY, D.; DUMONT, G. A. Semi-intrusive multivariable model invalidation. **Automatica**, v. 39, n. 8, p. 1461–1467, 2003.
- KANO, M. et al. **Detection of significant model-plant mismatch from routine operation data of model predictive control system**. [s.l.] IFAC, 2010. v. 9
- LIM, T. S.; LOH, W. Y. A comparison of tests of equality of variances. **Computational Statistics and Data Analysis**, v. 22, n. 3, p. 287–301, 1996.
- LJUNG, L. **Ljung L System Identification Theory for User.pdfPTR Prentice Hall Upper Saddle River NJ**, 1987. Disponível em:
<<http://linkinghub.elsevier.com/retrieve/pii/0005109889900198>>
- MACIEJOWSKI, J. M. **Predictive Control With Constraints**. 1. ed. [s.l.] Prentice Hall, 2002.
- QIN, S. J.; BADGWELL, T. A. A survey of industrial model predictive control technology. **Control Engineering Practice**, v. 11, n. 7, p. 733–764, 2003.
- SEER, Q. H.; NANDONG, J. Stabilization and PID tuning algorithms for second-order unstable processes with time-delays. **ISA Transactions**, v. 67, p. 233–245, 2017.
- SELVANATHAN, S.; TANGIRALA, A. K. Diagnosis of poor control loop performance due to model-plant mismatch. **Industrial and Engineering Chemistry Research**, v. 49, n. 9, p. 4210–4229, 2010.
- SKOGESTAD, S.; POSTLETHWAITE, I. Multivariable feedback control: analysis and design. **International Journal of Robust and Nonlinear Control**, v. 8, n. 14, p. 575, 2005.
- SUN, Z. et al. Performance monitoring of model-predictive controllers via model residual assessment. **Journal of Process Control**, v. 23, n. 4, p. 473–482, 2013.

TANGIRALA, A. K. **Principles of System Identification: Theory and Practice**. New York: CRC Press, 2015.

TRIERWEILER, J. O.; FARINA, L. A. RPN tuning strategy for model predictive control. v. 13, p. 591–598, 2003.

VILANOV, R.; ALFARO, V. M. Control PID robusto: Una vision panoramica. **RIAI - Revista Iberoamericana de Automatica e Informatica Industrial**, v. 8, n. 3, p. 141–158, 2011.

WEBBER, J. R.; GUPTA, Y. P. A closed-loop cross-correlation method for detecting model mismatch in MIMO model-based controllers. **ISA Transactions**, v. 47, n. 4, p. 395–400, 2008.

YERRAMILI, S.; TANGIRALA, A. K. Detection and diagnosis of model-plant mismatch in MIMO systems using plant-model ratio. **IFAC-PapersOnLine**, v. 49, n. 1, p. 266–271, 2016.

Apêndice A – Método do Erro de Predição

O método do erro de predição, PEM (do inglês, *Prediction Error Method*), visa encontrar um modelo com boa capacidade preditiva ao se minimizar o erro de predição, isto é, a diferença entre a sinal medido da saída do processo e o sinal predito com o modelo identificado. Seja uma estrutura genérica do modelo tal que

$$y(k) = G(q, \theta)u(k) + H(q, \theta)e(k) \quad (\text{A.1})$$

onde θ é o vetor de parâmetros desconhecidos pertencentes a um conjunto Θ_M compacto e conectado. Para tal, a predição um passo à frente, como descrita por LJUNG (1987), é dada por:

$$\hat{y}(k|k-1, \theta) = H^{-1}(q, \theta)G(q, \theta)u(k) + (I - H^{-1}(q, \theta))y(k) \quad (\text{A.2})$$

onde $\hat{y}(k|k-1, \theta)$ é a predição da saída $y(k)$ baseada nos dados até o momento $k-1$ e nos parâmetros θ do modelo M . Com isso, o erro de predição é:

$$\varepsilon(k, \theta) = y(k) - \hat{y}(k|k-1, \theta) = H^{-1}(q, \theta)(y(k) - G(q, \theta)u(k)) \quad (\text{A.3})$$

onde $\varepsilon(k, \theta)$ é o erro de predição. Assim, os parâmetros do modelo podem ser estimados tal que:

$$\hat{\theta}_N = \min_{\theta \in \Theta_M} V_N(\theta, Z^N) \quad (\text{A.4})$$

$$V_N(\theta, Z^N) = \frac{1}{N} \sum_{k=1}^N \|\varepsilon(k, \theta)\|_{\Lambda} = \frac{1}{N} \sum_{k=1}^N \varepsilon^T(k, \theta) \Lambda^{-1} \varepsilon(k, \theta) \quad (\text{A.5})$$

onde $\|\cdot\|_W$ representa a norma quadrática ponderada por uma matriz simétrica e positiva definida Λ , que é escolhida de acordo com a importância que se deseja para cada saída do sistema MIMO que se deseja identificar. O sistema real é dito contido no conjunto

possível de modelos se, para algum vetor θ_0 contendo os parâmetros verdadeiros do modelo da planta, termos:

$$G(q, \theta_0) = G_0(q) \quad H(q, \theta_0) = H_0(q) \quad (\text{A.6})$$

onde $G_0(q)$ e $H_0(q)$ representam a parte determinística e estocástica do modelo real da planta.

Para facilitar a notação, o símbolo \bar{E} , para uma função genérica $f(k), k = 1, 2, \dots, N$, é introduzido como:

$$\bar{E}f(k) = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{k=1}^N Ef(k) \quad (\text{A.7})$$

com a implicação de assumir que o limite exista quando o símbolo for utilizado. Assim, definindo-se o critério de convergência $\bar{V}(\theta)$ como:

$$\bar{V}(\theta) = \bar{E} \varepsilon(k, \theta) \Lambda^{-1} \varepsilon^T(k, \theta) \quad (\text{A.8})$$

$$\hat{\theta}_N \rightarrow D_c = \min_{\theta \in \Theta_M} \bar{V}(\theta) \text{ com probabilidade 1 conforme } N \rightarrow \infty \quad (\text{A.9})$$

onde D_c é o argumento que minimiza o critério de convergência. Pela definição de transformada discreta inversa de Fourier (FORSSELL; LJUNG, 1999), o critério de convergência também pode ser escrito como:

$$\bar{V}(\theta) = \bar{E} \text{tr}[\Lambda^{-1} \varepsilon(k, \theta) \varepsilon^T(k, \theta)] = \frac{1}{2\pi} \int_{-\pi}^{\pi} \text{tr}[\Lambda^{-1} \Phi_{\varepsilon}(\omega)] d\omega \quad (\text{A.10})$$

onde $\text{tr}[-]$ é a soma dos elementos diagonais de uma matriz e $\Phi_{\varepsilon}(\omega)$ é a densidade espectral do erro de predição. Assim, pode ser visto que a convergência do PEM depende apenas das propriedades de segunda ordem do espectro do erro de predição $\Phi_{\varepsilon}(\omega)$ (FORSSELL; LJUNG, 1999).

Com o sistema real representado pela equação

$$y(k) = G_0(q)u(k) + v(k) = G_0(q)u(k) + H_0(q)e(k) \quad (\text{A.11})$$

e tomando a densidade espectral do erro de predição, sendo G_{θ} e H_{θ} , respectivamente, abreviação de $G(e^{i\omega}, \theta)$ e $H(e^{i\omega}, \theta)$, temos:

$$D_c = \min_{\theta \in \Theta_M} \int_{-\pi}^{\pi} \left(\text{tr}[(G_0 - G_{\theta}) (H_0 - H_{\theta})] \Phi_{\chi_0} \right) d\omega \quad (\text{A.12})$$

$$x \begin{bmatrix} (G_0 - G_{\theta})^* \\ (H_0 - H_{\theta})^* \end{bmatrix} (H_{\theta} \Lambda H_{\theta}^*)^{-1}$$

onde $\chi_0 = [u^T(k) \ e^T(k)]^T$, com densidade espectral $\Phi_{\chi_0}(\omega)$ dada por:

$$\Phi_{\chi_0}(\omega) = \begin{bmatrix} \Phi_u(\omega) & \Phi_{ue}(\omega) \\ \Phi_{eu}(\omega) & \Lambda_0 \end{bmatrix} \quad (\text{A.13})$$

Em (A.13), Φ_u é o espectro de densidade do sinal de entradas da planta, Φ_{ue} e Φ_{eu} são os espectros de densidade cruzada entre u e e e Λ_0 é a matriz de covariância do ruído branco $e(k)$. Logo, fatorando $\Phi_{\chi_0}(\omega)$ e assumindo $\Phi_u(\omega) > 0$ e $\Lambda_0 > 0$, temos (suprimindo-se o símbolo ω quando não houver risco de confusão):

$$\Phi_{\chi_0} = \begin{bmatrix} I & \Phi_{ue}\Lambda_0^{-1} \\ 0 & I \end{bmatrix} \begin{bmatrix} \Phi_u^r & 0 \\ 0 & \Lambda_0 \end{bmatrix} \begin{bmatrix} I & 0 \\ \Lambda_0^{-1}\Phi_{eu} & I \end{bmatrix} \quad (\text{A.14})$$

$$= \begin{bmatrix} I & 0 \\ \Phi_{eu}\Phi_u^{-1} & I \end{bmatrix} \begin{bmatrix} \Phi_u & 0 \\ 0 & \Phi_e^r \end{bmatrix} \begin{bmatrix} I & \Phi_u^{-1}\Phi_{ue} \\ 0 & I \end{bmatrix} \quad (\text{A.15})$$

Onde

$$\Phi_u^r = \Phi_u - \Phi_{ue}\Lambda_0^{-1}\Phi_{eu} \quad (\text{A.16})$$

$$\Phi_e^r = \Lambda_0 - \Phi_{eu}\Phi_u^{-1}\Phi_{ue} \quad (\text{A.17})$$

Assim, a Equação (A.13) pode ser reescrita como:

$$\Phi_{\chi_0} = \Phi_{\chi_0}^r + \Phi_{\chi_0}^e, \quad \Phi_{\chi_0}^r = \begin{bmatrix} \Phi_u^r & 0 \\ 0 & 0 \end{bmatrix}, \quad \Phi_{\chi_0}^e = \begin{bmatrix} \Phi_u^e & \Phi_{ue} \\ \Phi_{eu} & \Lambda_0 \end{bmatrix} \quad (\text{A.18})$$

$$\Phi_u^e = \Phi_u - \Phi_u^r = \Phi_{ue}\Lambda_0^{-1}\Phi_{eu} \quad (\text{A.19})$$

A matriz Φ_u^r pode ser vista como a porção do espectro do sinal de entrada $u(k)$ que se origina do sinal da referência $r(k)$, bem como a matriz Φ_u^e como a parte do espectro do sinal de entrada $u(k)$ que se origina do ruído $e(k)$.

Este resultado é aplicável independente da forma do controlador, seja ele linear ou não-linear. Assim, com uma parametrização suficiente de G e H , conclui-se que:

- O método do erro de predição resultará em boas estimativas G_0 e H_0 para experimentos informativos, ou seja, com a condição de que Φ_{χ_0} seja uma matriz positiva definida, o que ocorre desde que a densidade espectral Φ_u^r seja positiva definida. Para isso, a relação entre $y(k)$ e $u(k)$ não deve ser linear, invariante no tempo e livre de ruído, condição a qual é automaticamente satisfeita com um sinal de referência externo;
- Para garantir que Φ_u^r seja positiva definida, também pode-se alterar entre diferentes tipos de controladores lineares, ou usar um controlador não linear, como acontece com controladores preditivos, que mesmo com modelos linearizados da planta, pode se tornar não-lineares.
- O método também pode convergir quando o controlador é linear, pois se pode observar que Φ_u^r será uma matriz positiva definida desde que a matriz Φ_r também seja, o que ocorre apenas quando o sinal de referência for persistentemente excitado (LJUNG, 1987).
- O método também atinge convergência quando Φ_{χ_0} é uma matriz positiva semi-definida, se a condição de que $[(G_0 - G_\theta) \quad (H_0 - H_\theta)]$ não se encontre no espaço nulo do espectro do erro de predição também for satisfeita (LJUNG, 1987)

