

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

LOCALIZAÇÃO DE CANAIS AFETANDO O DESEMPENHO DE
CONTROLADORES PREDITIVOS BASEADOS EM MODELOS

DISSERTAÇÃO DE MESTRADO

Érica Rejane Pereira Claro

Porto Alegre

2016

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

LOCALIZAÇÃO DE CANAIS AFETANDO O DESEMPENHO DE
CONTROLADORES PREDITIVOS BASEADOS EM MODELOS

Érica Rejane Pereira Claro

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: Engenharia de
Sistemas: Projeto, Simulação, Controle e
Otimização.

Orientadores:
Prof. Dr. Jorge Otávio Trierweiler
Prof. Dr. Marcelo Farenzena

Porto Alegre

2016

CIP - Catalogação na Publicação

Claro, Érica Rejane Pereira

Localização de canais afetando o desempenho de controladores preditivos baseados em modelos / Érica Rejane Pereira Claro. -- 2016.

124 f.

Orientador: Jorge Otávio Trierweiler.

Coorientador: Marcelo Farenzena.

Dissertação (Mestrado) -- Universidade Federal do Rio Grande do Sul, Escola de Engenharia, Programa de Pós-Graduação em Engenharia Química, Porto Alegre, BR-RS, 2016.

1. auditoria de desempenho de controladores multivariáveis. 2. controladores preditivos baseados em modelos. 3. MPC. I. Trierweiler, Jorge Otávio, orient. II. Farenzena, Marcelo, coorient. III. Título.

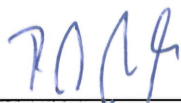
UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA QUÍMICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA

A Comissão Examinadora, abaixo assinada, aprova a Dissertação Localização de Canais Afetando o Desempenho de Controladores Preditivos Baseados em Modelos, elaborada por Érica Rejane Pereira Claro, como requisito parcial para obtenção do Grau de Mestre em Engenharia.

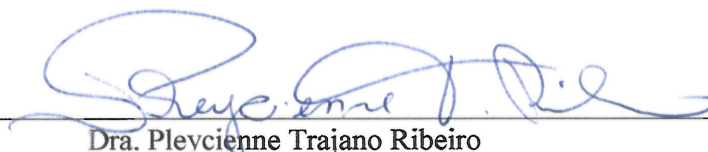
Comissão Examinadora:



Prof. Dr. Marcio Schwaab



Prof. Dr. Pedro Rafael Bolognese Fernandes



Dra. Pleycienne Trajano Ribeiro

AGRADECIMENTOS

A Deus, pela proteção e oportunizar os desafios e caminhos para superá-los.

À minha família, em especial aos meus pais Angelo e Jurema, que sempre lutaram para que os filhos tivessem a oportunidade de estudar e trilhar seus próprios caminhos, desenvolvendo todo o seu potencial. Ao meu esposo, Angelo, amigo e companheiro de todos os momentos, que me apoiou e incentivou durante todas as etapas do mestrado. Ao meu filho, Fernando, que ilumina a minha vida e me faz buscar ser alguém melhor.

Aos Prof. Dr. Jorge e Prof. Dr. Farenzena, pelos ensinamentos e orientação para que este trabalho fosse focado e produtivo. À Dra. Viviane, pela paciência, exemplo e contribuições no desenvolvimento do trabalho.

Aos colegas da Braskem, em especial ao Leandro Dariva, que se dispôs a ler e comentar os artigos escritos ao longo do trabalho. Aos líderes Rogério Kirst e Nilson Burger Jr., que apoiaram a dedicação de tempo para conseguir conduzir o mestrado em paralelo ao trabalho na Braskem.

Aos amigos e familiares que me apoiaram e entenderam as ausências para conseguir conciliar o mestrado com o trabalho e a vida pessoal.

À Universidade Federal do Rio Grande do Sul e ao Departamento de Engenharia Química, pela possibilidade da realização desse trabalho.

Muito obrigada!

“To achieve great things, two things are needed;
a plan, and not quite enough time”.

(Leonard Bernstein)

RESUMO

O escopo desta dissertação é o desenvolvimento de um método para detectar os modelos da matriz dinâmica que estejam degradando o desempenho de controladores preditivos baseados em modelos. O método proposto se baseia na análise de correlação cruzada entre o erro nominal do controlador em malha fechada e a uma estimativa da contribuição de cada canal para o cálculo da saída, filtrada pela função de sensibilidade do controlador. Esse método pode ser empregado na auditoria de controladores com variáveis controladas em *setpoints* e/ou com variáveis que operem entre faixas, como é usual de se encontrar na indústria. Esta dissertação apresenta os resultados da aplicação bem sucedida do método no sistema de quatro tanques (JOHANSSON, 2000), para o qual três cenários foram avaliados. No primeiro cenário, o método localizou corretamente discrepâncias de ganho e de dinâmica de modelos de um controlador preditivo baseado em modelos (*Model-based Predictive Controller*, ou controlador MPC). No segundo, o método foi utilizado para avaliar a influência de uma variável externa para melhorar o desempenho de um controlador afetado por distúrbios não medidos. No terceiro cenário, o método localizou canais com modelos nulos que deveriam ser incluídos na matriz de controle de um controlador MPC de estrutura descentralizada. Os resultados deste estudo de caso foram comparados com aqueles obtidos pelo método proposto por BADWE, GUDI e PATWARDHAN (2009), constatando-se que o método proposto é mais robusto que o método usado na comparação, não demandando ajustes de parâmetros por parte do usuário para fornecer bons resultados. A dissertação inclui também um estudo de caso da aplicação industrial do método na auditoria de desempenho de um controlador preditivo linear de estrutura descentralizada, com doze variáveis controladas, oito manipuladas e quatro distúrbios não medidos, aplicado a um sistema de fracionamento de propano e propano em uma indústria petroquímica. A auditoria permitiu reduzir o escopo de revisão do controlador a dezenove canais da matriz, sendo que quatorze destes correspondiam a canais com modelos nulos que deveriam ser incluídos na matriz. A eficácia do método foi comprovada repetindo-se a avaliação da qualidade de modelo para todas as variáveis controladas.

PALAVRAS-CHAVE: auditoria de desempenho de controladores multivariáveis, controladores preditivos baseados em modelos, MPC.

ABSTRACT

The scope of this dissertation is the development of a method to detect the models of the dynamic matrix that are affecting the performance of model-based predictive controllers. The proposed method is based on the cross correlation analysis between the nominal controller error and an estimate of the contribution of each channel to the controller output, filtered by the controller nominal sensitivity function. The method can be used in the performance assessment of controllers employing variables controlled at the setpoint and/or those controlled within ranges. This dissertation presents the results of the successful application of the method to the quadruple-tank process (JOHANSSON, 2000), for which three scenarios were evaluated. In the first scenario, the method correctly located gain and dynamic mismatches on a model-based predictive controller (MPC controller). In the second one, the method was used to evaluate the influence of an external variable to improve the performance of a controller affected by unmeasured disturbances. In the third scenario, the method located null models that should be included in the dynamic matrix of a decentralized MPC controller. The results of the three scenarios were compared with the ones obtained through the method proposed by BADWE, GUDI e PATWARDHAN (2009). The proposed method was considered more robust than the reference one for not requiring parameters estimation performed by the user to provide good results. This dissertation also includes a case study about the application of the method on the performance assessment of an industrial linear predictive controller of decentralized structure. The controller has twelve controlled variables, eight manipulated variables, and four unmeasured disturbances and is applied to a propylene-propane fractionation system of a petrochemical industry. The performance assessment allowed reducing the scope of the controller revision to nineteen channels of the models matrix, fourteen of which were null models that should be included in the controller. The efficacy of the proposed method was confirmed by repeating the model quality evaluation for all the controlled variables.

KEYWORDS: multivariable controller performance assessment, model-based predictive controllers, MPC.

LISTA DE FIGURAS

Figura 1.1: Ciclo de vida de um sistema de controle avançado. (CAMPOS, GOMES e PEREZ, 2013).....	2
Figura 2.1: Abordagem de horizonte móvel do controle preditivo baseado em modelos. Adaptado de GARCÍA, PRETT e MORARI (1989).....	7
Figura 2.2: Genealogia aproximada dos controladores MPC lineares. Adaptado de QIN e BADGEWELL (2003).....	11
Figura 2.3: Camadas utilizadas para organizar as tecnologias de controle de processo (FARENZENA e TRIERWEILER, 2007).	12
Figura 2.4: Causas de degradação de desempenho de um controlador MPC. Adaptado de TIAN, CHEN, G. e CHEN, S. (2011).	13
Figura 3.1: Diagrama de blocos de uma malha de controle genérica monovariável. Adaptado de ÅSTROM e MURRAY (2002).....	23
Figura 3.2: Exemplo de função de correlação cruzada entre amostras de duas séries temporais.....	25
Figura 3.3: Fluxograma para aplicação da metodologia NMDI.....	31
Figura 4.1: Esquema do sistema de quatro tanques. Adaptado de JOHANSSON (2000).	37
Figura 4.2: Resposta da função de sensibilidade de saída nominal, S_o , à função degrau.	40
Figura 4.3: Processo de análise utilizado na auditoria de controladores para o estudo de caso do Sistema de Quatro Tanques.	42
Figura 4.4: Simulação de processo do caso nominal do controlador, considerando a dinâmica da planta igual aos modelos do controlador. As variáveis medidas estão plotadas em azul, os limites de controle em linhas vermelhas tracejadas e as metas de controle calculadas pelo otimizador, em verde.	45
Figura 4.5: Simulação do Cenário 1. Variáveis medidas exibidas em azul e as metas otimizadas do controlador em laranja.....	46
Figura 4.6: Avaliação da qualidade dos modelos para o Cenário 1.	46
Figura 4.7: Diagnóstico da causa predominante de discrepância de modelo. (a) para a variável h_2 ; (b) para a variável h_3	48
Figura 4.8: Localização da MV mais relacionada à discrepância de modelo. (a) para a variável h_2 ; (b) para a variável h_3	48
Figura 4.9: Resultados da análise de correlação parcial entre o erro de predição e as variáveis de entrada do controlador (BADWE, GUDI e PATWARDHAN, 2009): (a) Para a variável h_2 ; (b) Para a variável h_3	49
Figura 4.10: Resultados obtidos para a aplicação do método proposto por BADWE, GUDI e PATWARDHAN (2009) para a variável h_3 . (a) modelos OE ordem 3 ($n_b = n_f = 3$); (b) modelos OE ordem 4 ($n_b = n_f = 4$); (c) modelos OE ordem 5 ($n_b = n_f = 5$); (d) modelos OE ordem $n_b = 5$; $n_f = 3$	50
Figura 4.11: Simulação do cenário após correção do modelo referente ao par $(v_1 - h_2)$	51
Figura 4.12: Avaliação da qualidade dos modelos para o Cenário 1 após correção da variável h_2	51
Figura 4.13: Esquema do sistema de quatro tanques com uma vazão adicional ao Tanque 1, F_{ex1}	53
Figura 4.14: Gráfico do distúrbio inserido no sistema de quatro tanques através da variável F_{ex1}	54
Figura 4.15: Simulação do Cenário 3. Variável medida plotada em azul e valores-alvo em laranja.....	55

Figura 4.16: (a) Indicadores $Ivar$ apontando discrepância de modelo significativa para a variável h_1 . (b) diagnóstico da fonte predominante de discrepância de modelo para a variável h_1 .	56
Figura 4.17: Resultados da metodologia NMDI para o Cenário 2.	56
Figura 4.18: Resultados da metodologia proposta por BADWE, GUDI e PATWARDHAN (2009) para o Cenário 2.	57
Figura 4.19: Resposta da função de sensibilidade nominal do controlador multi-SISO, S_0 , à função degrau.	58
Figura 4.20: Simulação do controlador Multi-SISO atuando sobre o modelo de planta nominal. Variáveis controladas plotadas em azul, limites inferior e superior de operação em linhas vermelhas tracejadas e metas ótimas do controlador em verde.	59
Figura 4.21: Simulação do controlador Multi-SISO atuando sobre o a planta do cenário 3. Variáveis controladas plotadas em azul, e metas ótimas do controlador em laranja.	60
Figura 4.22: Avaliação da qualidade de modelo para o Cenário 3.	61
Figura 4.23: Diagnóstico da causa predominante de problema de modelagem. (a) para a variável h_1 . (b) para a variável h_2 .	62
Figura 4.24: Localização da variável de entrada do controlador mais relacionada à discrepância de modelo da variável controlada pela metodologia NMDI. (a) para a variável h_1 . (b) para a variável h_2 .	62
Figura 4.25: Resultados obtidos para a aplicação do método proposto por BADWE, GUDI e PATWARDHAN (2009). (a) para a variável h_1 ; (b) para a variável h_2 .	63
Figura 4.26: Resultados obtidos para a aplicação do método proposto por BADWE, GUDI e PATWARDHAN (2009) para a variável h_2 . (a) modelos OE ordem $n_b=n_f=3$; (b) modelos OE ordem $n_b=n_f=4$; (c) modelos OE ordem $n_b=n_f=5$.	63
Figura 5.1: Esquema simplificado dos objetivos da aplicação de controle avançado.	65
Figura 5.2: Diagrama simplificado da estrutura do MPC aplicado ao processo de fracionamento de propeno/propano. As variáveis manipuladas estão indicadas em azul, variáveis distúrbio em rosa e variáveis controladas estão indicadas em amarelo.	66
Figura 5.3: Representação matriz dinâmica do controlador, exibindo os canais modelados (em azul) e o agrupamento das variáveis controladas por subcontroladores (SUBs 1, 2 e 3).	68
Figura 5.4: Fluxo de trabalho utilizada na auditoria e revisão do controlador, integrando os métodos propostos por BOTELHO, TRIERWEILER <i>et al.</i> (2015 a,b,2016) com a metodologia NMDI proposta.	69
Figura 5.5: Comportamento das variáveis de saída no primeiro período de avaliação do controlador	72
Figura 5.6: Comportamento das variáveis de entrada (variáveis manipuladas e variáveis-distúrbio) no primeiro período de avaliação do controlador	72
Figura 5.7: Comportamento das variáveis de saída no segundo período de avaliação do controlador	73
Figura 5.8: Comportamento das variáveis de entrada (variáveis manipuladas e variáveis-distúrbio) no segundo período de avaliação do controlador	73
Figura 5.9: Comportamento das variáveis de saída no terceiro período de avaliação do controlador	74

Figura 5.10: Comportamento das variáveis de entrada do controlador (variáveis manipuladas e variáveis-distúrbio) no terceiro período de avaliação do controlador.	74
Figura 5.11: Indicador <i>Ivar</i> , resultado da auditoria da qualidade de modelo por CV para cada um dos períodos auditados.	76
Figura 5.12: Indicador <i>Ivardiag</i>, resultado da auditoria da qualidade de modelo por variável controlada para cada um dos períodos auditados.	77
Figura 5.13: Resultados de correlação máxima entre y_0 e e_0 com base nas estatísticas de curtose e assimetria para as variáveis controladas.	78
Figura 5.14: Resumo dos canais da matriz que mais afetando no desempenho do controlador para os Períodos (I, II e III) avaliados.	79
Figura 5.15: Representação da atriz dinâmica do controlador após trabalho de identificação de variáveis.	81
Figura 5.16: Comparação entre o indicador médio <i>Ivardiag</i> obtido: na auditoria do controlador, com o controlador revisado utilizando os próprios dados da auditoria e com o controlador revisado em operação.	82
Figura 5.17: Comparação entre os modelos original (a) e novos (b) para a variável AI04 (CV10). Fonte: (CLARO, BOTELHO, <i>et al.</i>, 2016).....	83
Figura 5.18: Sistema de fracionamento de propeno incluindo a variável TI01.	84
Figura 5.19: Gráfico de tendência das duas variáveis AI04 e TI01.....	84
Figura 5.20: Resultados da metodologia NMDI para avaliar a correlação da variável externa TI01 com a incerteza de modelo da variável AI04	85

LISTA DE TABELAS

Tabela 3.1: Exemplo de resultados de indicadores de discrepância de modelo, MDI, obtidos para um controlador MPC hipotético com quatro variáveis de entrada (u_1 a u_4), para o qual o método NMDI foi aplicado para as cinco variáveis controladas (y_1 a y_4).	33
Tabela 3.2: Resultados dos Indicadores NMDI correspondentes aos exemplos fornecidos na Tabela 3.1 ..	34
Tabela 4.1: Parâmetros do processo do sistema de quatro tanques (JOHANSSON, 2000)	38
Tabela 4.2: Variáveis do controlador e ponto de operação para linearização do sistema.	38
Tabela 4.3: Parâmetros de sintonia do controlador e do otimizador	40
Tabela 4.4: Discrepâncias entre modelo e planta introduzidas para o Cenário 1.....	45
Tabela 4.5: Resultados do teste F de Levene para igualdade de variâncias para o Cenário 1.....	47
Tabela 4.6: Resultados do teste F de Levene para igualdade de variâncias após correção da variável h_2 . .	52
Tabela 4.7: Resultados do teste de hipótese de Levene para igualdade de variâncias para o Cenário 2.	56
Tabela 4.8: Resultados do teste F de Levene para igualdade de variâncias para o Cenário 3.....	61
Tabela 4.9: Ajuste dos dados nos modelos da etapa de decorrelação para a variável h_3	64
Tabela 5.1: Descrição das variáveis do controlador MPC	67
Tabela 5.2: Classificação das variáveis controladas por período.	75
Tabela 5.3: Resultados da probabilidade (p-value) do teste F de Levene para as variáveis controladas	77
Tabela 5.4: Resumo das identificações executadas por variável.	80

NOTAÇÃO E SIMBOLOGIA

A	Vetor de Área transversal dos tanques
a	Vetor de Área transversal do bocal de saída do tanque
ARX	Modelo auto regressivo com entradas exógenas (<i>Auto Regressive with Exogenous Inputs</i>)
B	Polinômio do modelo OE
bounds	Matriz que retorna as estimativas de intervalo de confiança (função crosscorr)
C	Bloco lógico representando o controlador por retroalimentação em uma malha de controle genérica
c^j	Matrizes de constantes na formulação do DMC
$C_{u_t}^j$	Matrizes de constantes na formulação do DMC
$C_{y_t}^j$	Matrizes de constantes na formulação do DMC
$c_{d\ max}$	Coefficiente de correlação máximo baseado na derivada
$c_{d\ kts}$	Coefficiente de correlação médio baseado na derivada da estatística de curtose
$c_{d\ skn}$	Coefficiente de correlação médio baseado na derivada da estatística de assimetria
$\bar{c}_{kts\ I}$	Coefficiente de correlação médio baseado na estatística de curtose
\bar{c}_{skn}	Coefficiente de correlação médio baseado na estatística de assimetria
CI	Intervalo de confiança (<i>Confidence interval</i>)
cm	Centímetro
Connoisseur	Pacote comercial para desenvolvimento de controladores MPC
Corte C3	Corrente composta predominantemente por componentes com três moléculas de carbono, tais como propano, propeno, propadieno e metil-acetileno
cov	Covariância
crosscorr	Função do MATLAB TM para cálculo da estimativa da correlação cruzada entre amostras de séries temporais
CV	Variável controlada (de saída) do controlador MPC (<i>Controlled Variable</i>)
$c_{y_1 y_2}$	Estimativa da covariância cruzada entre as amostras das séries temporais y_1 e y_2
$\hat{d}(k + l k)$	Valor dos distúrbios previstos no instante $k + l$ com base nas informações do instante k
D	Transformada de Laplace da variável d
d	Distúrbios na carga

dkts	Derivada em relação ao tempo da estatística de curtose de uma distribuição estatística
DMC	Controlador por matrizes dinâmica (<i>Dynamic Matrix Controller</i>)
DMC+	Pacote comercial para desenvolvimento de controladores MPC
DRTO	Otimização em tempo real dinâmica (<i>Dynamic Real Time Optimization</i>)
DSI	Índice de Sensibilidade Projetada (<i>Designed Sensitivity Index</i>)
dskn	Derivada em relação ao tempo da estatística de assimetria de uma distribuição estatística
DV	Variável distúrbio ou distúrbio medido (<i>Disturbance variable</i>)
e	Erro de modelo (ou de predição??)
ECE	Matrizes para ponderação de erros relativos das variáveis de saída (<i>Equal Concern Errors</i>)
$e_{0_{diag}}$	Erro nominal do controlador calculado com base nos elementos diagonais da função de sensibilidade, S_0
e_0	Erro nominal do controlador
F	Polinômio do modelo OE
F	Bloco lógico representando filtro do setpoint
f	Termo linear da função objetivo
F_{cal}	Estatística calculada para o teste F de Levene
F_{ex}	Variável externa ao controlador
\tilde{F}_{ex}	Vetor de entradas do controlador descontado do valor inicial (variável desvio em relação ao valor inicial)
FIR	Modelos de resposta ao impulso finita (<i>Finite Impulse Response</i>)
G	Matriz de funções de transferência do controlador MPC
g	Aceleração da gravidade
G_0	Matriz nominal de funções de transferência da planta
G_i	Coefficientes da matriz de resposta à função degrau
G_{ij}	Modelo da matriz dinâmica G entre a variável de entrada i e a saída j
G_p	Matriz de funções de transferência da Planta. O mesmo que P.
$-G_{un}$	Função de sensibilidade ao ruído de medição
G_{yd}	Função de sensibilidade ao distúrbio de carga
h	Vetor de níveis dos quatro tanques

H_{e_j}	Modelo entre e_j e as demais MVs
H_{u_i}	Modelo entre \hat{u}_i^r e as demais MVs
HIECON	Pacote comercial para desenvolvimento de controladores MPC
H_0	Hipótese nula
H_1	Hipótese alternativa
i	Índice associado à linha de uma matriz
IDCOM	Pacote comercial para desenvolvimento de controladores MPC
IDCOM-M	Pacote comercial para desenvolvimento de controladores MPC
$Ivar$	Índice de variância relativa (<i>Relative Variance Index</i>) calculado a partir de S_0
$Ivar_{diag}$	Índice de variância relativa (<i>Relative Variance Index</i>) calculado com base nos elementos diagonais da função de sensibilidade
J	Função objetivo
j	Índice associado à coluna de uma matriz
K	Número de dados da amostras
k	Instante de tempo discretizado
k_f	Vetor de fatores de conversão de Voltagem a vazão da bomba
KPI	Índice chave de desempenho (<i>Key Performance Index</i>)
kts	Estimativa da curtose para amostra de uma população
l	Instante futuro dentro do horizonte de predição
lags	Vetor que retorna as defasagens de tempo utilizadas no cálculo (função crosscorr)
LQG	Controlador gaussiano quadrático linear (<i>linear quadratic Gaussian controller</i>)
M	Matriz de ponderação de peso dos movimentos na função objetivo
m	Horizonte de controle
MDI	Indicador de Discrepância de modelos
MIMO	Estratégia de controle multivariável com múltiplas variáveis de entrada e de saída (<i>Multiple Input, Multiple Output</i>)
MPC	Controle preditivo baseado em modelos (<i>Model Predictive Control</i>)
MPM	Discrepância entre modelo e dinâmica da planta (<i>model-plant mismatch</i>)
MQI	Índice de Qualidade do Modelo (<i>Model Quality Index</i>)
Multi SISO	Estratégia de controle multivariável em que se controlam múltiplas saídas, mas cada saída possui modelo com uma única entrada (<i>multi Single Input, Single Output</i>)

MV	Variável Manipulada (<i>Manipulated variable</i>)
MW	Tamanho da janela móvel
N	Transformada de Laplace da variável n
n	Ruído de medição
N_k	Número total de amostras
n_b	Ordem do polinômio B
n_c	Número de restrições
n_f	Ordem do polinômio F
n_k	Número de atrasos
n_p	Número de populações
n_s	Número de amostras
NMDI	Indicador normalizado de discrepância de modelos (<i>Normalized Model Discrepancy Index</i>)
N_{MV}	Número de variáveis de entrada do controlador
N_{MW}	Número de janelas móveis
numSTD	número de desvios padrão (parâmetro da função crosscorr)
OE	Método do no erro na saída (<i>Output Error</i>)
P	Bloco lógico que representa o processo em uma malha de controle genérica.
p	Horizonte de predição
PCT	Pacote comercial para desenvolvimento de controladores MPC
PEM	Métodos de identificação baseado no erro de predição (<i>Prediction error method</i>)
PFC	Pacote comercial para desenvolvimento de controladores MPC
PID	Algoritmo de controle do tipo proporcional, integral e derivativo
PLC	Controlador lógico programável (<i>Programmable Logic Controller</i>)
q	Operador de avanço
QDMC	Pacote comercial para desenvolvimento de controladores MPC
QP	Programação Quadrática (<i>Quadratic Programming</i>)
quadprog	Função do MATLAB TM para cálculo de programação quadrática
R	Transformada de Laplace da variável r

r	Vetor de <i>setpoints</i> das variáveis controladas
RMPC	Pacote comercial para desenvolvimento de controladores MPC
RMPCT	Pacote comercial para desenvolvimento de controladores MPC
RTO	Otimização em tempo real (<i>Real Time Optimization</i>)
s	Segundos
S	Função de sensibilidade do controlador
S_0	Função de sensibilidade nominal do controlador
$S_{0_{diag}}$	Matriz contendo apenas os elementos diagonais de S_0
sawtooth	Função dente de serra do MATLAB™
SDCD	Sistema digital de controle distribuído (<i>Distributed Control System</i>)
SISO	Estratégia de controle entre uma única variável de entrada e uma única variável de saída (<i>Single Input, Single Output</i>)
skn	Estimativa da estatística de assimetria para uma amostra de população
SMCA	Pacote comercial para desenvolvimento de controladores MPC
SMOC	Pacote comercial para desenvolvimento de controladores MPC
SRI	Índice de Sensibilidade Relativa (<i>Sensitivity Relative Index</i>)
\hat{S}_{ru}	Função de sensibilidade das entradas em relação aos <i>setpoints</i>
SUB	Subcontrolador
SVD	Técnica de decomposição em valores singulares (<i>Singular Value Decomposition</i>)
SVT	Técnica de limitação do valor singular (<i>Singular Value Thresholding</i>)
s_y	Estimativa do desvio padrão de amostras da série temporal y
t	Tempo
T_0	Função Complementar de sensibilidade Nominal
$T01$	Coluna de destilação 01
$T02$	Coluna de destilação 02
$T03$	Coluna de destilação 03
t_f	Tempo final da simulação
T_s	Tempo de amostragem
u	Variáveis de entrada do controlador (manipuladas e distúrbios)

\tilde{u}	Vetor de entradas do controlador descontado do valor inicial (variável desvio em relação ao valor inicial)
U	Transformada de Laplace da variável u
u^0	Vetor de entradas do controlador correspondentes ao ponto operacional de linearização
\tilde{u}^r	Vetor que contém todas as MVs, exceto \hat{u}_i^r
\hat{u}^r	Estimativa do componente variáveis de entrada considerando apenas o efeito dos <i>setpoints</i>
u^r	Componente das variáveis de entrada considerando apenas o efeito dos <i>setpoints</i>
UD	Distúrbio não medido (<i>Unmeasured disturbance</i>)
v	Voltagem bomba
V	Volts
V01	Vaso acumulador da coluna T01
V02	Vaso acumulador da coluna T02
V03	Vaso acumulador da coluna T03
var	Variância
VR	Relação de variabilidade (<i>Variability Ratio</i>)
w	Variável de processo que se deseja controlar
W	Transformada de Laplace da variável w
x	Movimento das variáveis manipuladas
x_1	Fração de abertura de válvula para o Tanque 1 de três vias (Sistema de Quatro Tanques)
x_2	Fração de abertura de válvula para o Tanque 2 de três vias (Sistema de Quatro Tanques)
$XCF_{y_1y_2}$	Correlação cruzada calculada a partir de amostras das séries temporais y_1 e y_2
XCF'	Correlação cruzada verdadeira
xcorr	Função do MATLAB TM para cálculo da correlação cruzada
y	Variável medida (saída do controlador), CV
Y	Transformada de Laplace da variável y
\bar{y}	Valor médio das amostras de y
y_0	Saída nominal do controlador em malha fechada
$\hat{y}(k)$	Valor de predição de y no instante k

$y_{0\text{diag}}$	Saída nominal do controlador em malha fechada calculada a partir de $S_{0\text{diag}}$
\bar{y}_0	Valor médio das amostras de y_0
$\bar{y}_{0\text{diag}}$	Valor médio das amostras de $y_{0\text{diag}}$
y^0	Vetor das saídas do controlador correspondentes ao ponto operacional de linearização
y_1	Exemplo de série temporal
y_2	Exemplo de série temporal
$(y_j - u_j)$	Par de variáveis do controlador: entrada u_j e saída y_i .
\hat{y}_p	saída parcial
\hat{y}_{pf}	saída parcial filtrada
y_{set}	Setpoint da variável controlada y
y_{sim}	Simulação da saída do controlador utilizando o modelo G
z	Estatística z
z_{cal}	Estatística z calculada para a amostra
Z	Distribuição estatística
$ZC_{\alpha/2}$	Fator crítico de limite de confiança
α	Nível de significância
B_1	Matriz de ponderação
Γ_1	Matriz de ponderação
ΔG	Discrepância entre o modelo da planta e o do controlador
Δu	Variação das variáveis de entrada entre dois intervalos de amostragem $(k+1)$ e k
$\Delta \hat{y}$	Variação da predição de y entre dois intervalos de amostragem $(k+1)$ e k
$\epsilon_{e_{ij}}$	Componente de ϵ_{u_i} de que não está correlacionado às demais MVs
ϵ_{u_i}	Componente de \hat{u}_i^r que não está correlacionado às demais MVs
$\hat{\epsilon}_{e_j}$	Valor calculado de $\epsilon_{e_{ij}}$
$\hat{\epsilon}_{u_i}$	Valor calculado de ϵ_{u_i}
ζ	Estatística de Fisher
η	Ordem de truncamento

λ	Defasagem entre dois sinais expressa em número de intervalos de amostragem
\mathcal{A}	Número total de defasagens
ν_i	Graus de liberdade do teste de Levene
σ	Desvio padrão

SUMÁRIO

1. INTRODUÇÃO.....	1
1.1 OBJETIVOS DO TRABALHO.....	4
1.2 ESTRUTURA DA DISSERTAÇÃO.....	4
2. REVISÃO BIBLIOGRÁFICA	7
2.1 CONTROLE PREDITIVO BASEADO EM MODELOS (MPC).....	7
2.2 GESTÃO DAS APLICAÇÕES DE MPC	12
2.3 AUDITORIA DE DESEMPENHO DE CONTROLADORES MPC.	14
3. METODOLOGIA PROPOSTA	23
3.1 CONCEITOS FUNDAMENTAIS	23
3.1.1 Propriedades fundamentais de uma malha de controle	23
3.1.2 Correlação cruzada entre séries temporais	24
3.2 METODOLOGIA	26
4. ESTUDO DE CASO: O SISTEMA DE QUATRO TANQUES 37	
4.1 DESCRIÇÃO DO PROCESSO.....	37
4.2 DESCRIÇÃO DO CONTROLADOR MPC	39
4.3 RESULTADOS E DISCUSSÃO DOS CENÁRIOS.....	41
4.3.1 Roteiro de análise	41
4.3.2 Premissas.....	43
4.3.3 Cenário 1: Detecção de discrepância entre modelo e planta em um controlador MPC MIMO (<i>Multiple Input, Multiple Output</i>).....	44
4.3.4 Cenário 2: Avaliação de variáveis para recuperar o desempenho de um sistema afetado por distúrbios não medidos.....	52
4.3.5 Cenário 3: Detecção de MPM em um controlador MPC de estrutura descentralizada.....	57
5. ESTUDO DE CASO EM CONTROLADOR INDUSTRIAL ... 65	
5.1 DESCRIÇÃO DA PLANTA INDUSTRIAL	65
5.2 DESCRIÇÃO DA ESTRATÉGIA DE CONTROLE DE PROCESSOS	66
5.3 RESULTADOS E DISCUSSÃO.....	68
5.3.1 Roteiro de aplicação do método	68
5.3.2 Auditoria do Controlador	71

6. CONSIDERAÇÕES FINAIS.....	87
6.1 CONTRIBUIÇÕES	87
6.2 SUGESTÕES PARA TRABALHOS FUTUROS	89
7. REFERÊNCIAS.....	91

1. INTRODUÇÃO

A tecnologia de controle preditivo baseado em modelos (*Model Predictive Control*, ou MPC) é atualmente considerada a abordagem padrão na indústria para aplicações de controle multivariável sujeito a restrições (DARBY e NIKOLAOU, 2012), sendo aplicada para controlar especificações de produtos de alta pureza, diminuir a variabilidade do processo e reduzir a geração de resíduos ao meio-ambiente em diversas áreas de indústrias de processos. A superioridade desse tipo de tecnologia em relação a outras técnicas de controle está muito relacionada à sua capacidade de lidar com restrições nas variáveis de entrada e à utilização da predição dos modelos para realizar controle ótimo de processos com tempos mortos significativos (TSAI, GOPALUNI, *et al.*, 2015).

Esses controladores utilizam modelos explícitos do processo para levar a planta de um estado estacionário a outro mais rentável considerando as restrições ativas de processo e de equipamentos, de forma que a obtenção de bons modelos relacionando as variáveis de entrada do controlador (variáveis manipuladas, ou MVs, e variáveis distúrbio, também conhecidas por distúrbios medidos, ou DVs) e as variáveis de saída (variáveis controladas, ou CVs) é fundamental para o sucesso de uma aplicação de controle preditivo baseado em modelos. Porém, o processo de identificação do controlador é uma atividade que pode levar semanas (CONNER e SEBORG, 2005), constituindo uma etapa dispendiosa de tempo e recursos humanos do projeto de um controlador.

A Figura 1.1 apresenta a variação dos benefícios (ganhos) econômicos ao longo do ciclo de vida de um controlador preditivo baseado em modelos. 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 e os operadores estão capacitados para a utilização das ferramentas. Esse patamar de benefícios é sustentado por um certo período, durante o qual o controle efetuado é adequado ao processo.

Porém, a dinâmica de processos industriais é variante no tempo, o que faz com que um modelo que retrate bem a relação entre as variáveis em um período inicial possa apresentar uma defasagem significativa após um certo período de operação. Essa mudança de comportamento dinâmico é resultado da ação de diversos fatores, tais como alterações na qualidade e composição da matéria-prima, sujamento de equipamentos como, por exemplo, trocadores e

pratos de coluna de destilação ao longo da campanha operacional, e mudanças nas condições operacionais, entre outras possíveis causas.

Quando o processo varia significativamente, os modelos dinâmicos identificados, os quais são empíricos na maioria das vezes, podem não ser mais adequados àquela planta, afetando o desempenho do controlador. Caso não haja um trabalho de engenharia para revisar o controlador, retornando ao patamar de operação desejado, o controle não adequado ao processo coloca o controlador em risco de desativação, encerrando seu ciclo de vida.

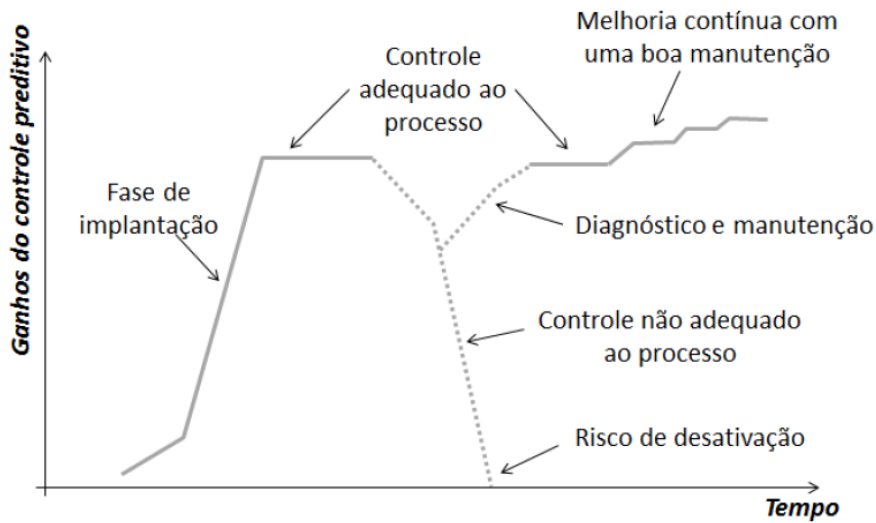


Figura 1.1: Ciclo de vida de um sistema de controle avançado. (CAMPOS, GOMES e PEREZ, 2013).

Assim, é necessário um processo de trabalho contínuo e sistemático de suporte à operação e manutenção dos controladores para manter o patamar de benefícios de projeto e permitir alavancar ganhos com projetos de melhoria contínua do controlador.

Considerando que o uso e monitoramento efetivos do MPC são muito dependentes da complexidade da tecnologia utilizada em cada planta e do domínio técnico do assunto pelos engenheiros e operadores, é uma prática da indústria petroquímica, por exemplo, considerar um período de cinco anos como tempo de vida útil de um controlador antes que este entre na região de queda de desempenho acentuada.

No entanto, remodelar todo o controlador a cada cinco anos não é uma tarefa fácil de ser conciliada com as demandas adicionais por agregação de valor (novos controladores e/ou escopos adicionais aos existentes). Além disso, é necessário que a planta apresente condições operacionais favoráveis para a remodelagem, principalmente quando o controlador utiliza modelos empíricos do processo.

Tomando-se, por exemplo, o caso das centrais de matérias-primas petroquímicas da Braskem, as áreas de produção de olefinas, aromáticos e utilidades são controladas por uma

média de sessenta controladores preditivos multivariáveis. Considerando como único fator determinante para a remodelagem um ciclo de vida de cinco anos, um processo de sustentação de valor contínuo dessas aplicações demandaria a revisão de cada controlador, contemplando o planejamento de experimentos de testes na planta, a reconstrução da matriz dinâmica do controlador, o comissionamento e sintonia da aplicação e o treinamento dos operadores em um período equivalente a pouco mais de um mês, sem contar com as demandas por novos controladores ou projetos de melhoria contínua em controladores existentes.

Mesmo que a etapa de testes na planta seja facilitada pelas últimas gerações de pacotes comerciais, os quais incluem ferramentas para testes semiautomáticos e avaliação de qualidade de modelo, a seleção de dados para modelagem ainda é fortemente dependente do conhecimento e experiência do engenheiro de controle (FORBES, PATWARDHAN, *et al.*, 2015). Isto caracteriza o trabalho de modelagem e identificação como uma tarefa especializada, normalmente realizada por uma equipe de engenharia com conhecimento diferenciado de controle de processos e experiência de planta, que são recursos escassos atualmente, como também mencionado pelos autores. Este é um dos motivos pelos quais muitas vezes se encontram controladores antigos, às vezes com dez anos de operação, que estão ligados, porém operando aquém da sua capacidade de controle e otimização, e não necessariamente agregando valor ao negócio.

Além disso, FORBES, PATWARDHAN, *et al.* (2015) também apontam que as preocupações das empresas que utilizam este tipo de tecnologia mudaram de questionamentos em relação à capacidade do controlador de entregar o benefício estimado para questões relacionadas à facilidade da utilização de instalação do *software*, facilidade e intuitividade de uso pelos operadores e como o desempenho da aplicação pode ser monitorado e mantido a longo prazo com recursos limitados.

Considerando este cenário, a auditoria de modelos de controle preditivo está posicionada como um tema muito atrativo, pois:

- Maximiza o potencial de retorno econômico dos controladores MPC, uma vez que constitui uma sistemática para auditar o desempenho dos modelos dessas aplicações periodicamente, permitindo priorizar a revisão dos controladores com degradação de desempenho, em oposição a esperar o término do ciclo de vida;
- Otimiza a utilização de recursos nas atividades de remodelagem do controlador, limitando o escopo do trabalho de revisão de controladores aos modelos da matriz dinâmica que apresentem discrepâncias que estejam degradando o desempenho do controlador;

- Disponibiliza tempo para o engenheiro de controle se dedicar a novas aplicações, pois minimiza a necessidade intervenções não programadas para sintonia/ajustes de controladores existentes para tentar manter operando um controlador com desempenho insatisfatório.

1.1 OBJETIVOS DO TRABALHO

O obtivo principal deste trabalho é desenvolver uma metodologia para detecção de modelos da matriz dinâmica do controlador que estejam efetivamente degradando o desempenho do controlador preditivo baseado em modelos, fornecendo um diagnóstico específico sobre o canal mais correlacionado ao problema de incerteza de modelo da variável controlada analisada.

São objetivos secundários:

- Detectar canais não modelados da matriz dinâmica de controladores MPC de estrutura descentralizada cuja performance está sendo degradada devido à interação significativa entre as variáveis que não estão ligadas por uma malha de controle, tendo em vista a vasta utilização deste tipo de estrutura de controle na indústria
- Avaliar a influência de variáveis adicionais à matriz de controle para tratar distúrbios não medidos.

Constituem premissas para o desenvolvimento do método, de forma a facilitar sua aplicação em controladores industriais:

- Utilizar dados históricos das variáveis de processo em detrimento a testes na planta, pois nem todos os processos industriais permitem que sejam feitas perturbações significativas visando identificar novos modelos.
- Não utilizar o *setpoint* como premissa de desempenho, para que seja o método proposto possa ser aplicado tanto a controladores que utilizem variáveis controladas em setpoints explicitamente definidos, quanto para controladores que utilizem variáveis controladas por faixas correspondentes a uma região de operação aceitável.

1.2 ESTRUTURA DA DISSERTAÇÃO

Esta dissertação está estruturada em seis capítulos. Nesta introdução, foi realizada a apresentação geral do trabalho, abrangendo a motivação e objetivos e estrutura do trabalho.

O Capítulo 2 apresenta a revisão bibliográfica, contemplando os métodos de auditoria existentes e as premissas utilizadas para o desenvolvimento da metodologia proposta, que é o objeto do Capítulo 3.

O Capítulo 4 apresenta os resultados da aplicação da metodologia no sistema de quatro tanques cilíndricos, que foi usado como referência para desenvolvimento do método. Os cenários discutidos nesse capítulo exploram as potencialidades e limitações do método proposto.

O Capítulo 5 aborda o estudo de caso de aplicação da metodologia para auditoria de um controlador industrial.

Por fim, o Capítulo 6 apresenta as conclusões gerais sobre o trabalho e sugestões para trabalhos futuros.

2. REVISÃO BIBLIOGRÁFICA

Neste capítulo é realizado um levantamento bibliográfico dos principais assuntos para o desenvolvimento deste trabalho.

2.1 CONTROLE PREDITIVO BASEADO EM MODELOS (MPC)

O controle preditivo baseado em modelos (*Model Predictive Control*, ou MPC) se refere a uma classe de algoritmos computacionais para controle que utiliza modelos do processo (empíricos e/ou fenomenológicos) para prever a resposta futura de uma planta.

A Figura 2.1 apresenta um esquema da abordagem de horizonte móvel utilizada nos controladores MPC. A cada período de amostragem, o algoritmo otimiza o comportamento futuro do processo em um horizonte de previsão, p , através do planejamento de uma sequência de movimentos para as variáveis manipuladas. O primeiro movimento desta sequência ótima é enviado à planta e toda a rotina de cálculos é repetida no próximo intervalo de amostragem do controlador (QIN e BADGEWELL, 2003). Nessa Figura, $y(k)$ é o valor de medição da variável de saída, y , no instante k ; $\hat{y}(k+l|k)$ é o valor predito de y no instante $k+l$, com base nas informações disponíveis no instante k ; $u(k+l)$ corresponde ao vetor das variáveis manipuladas no instante $k+l$.

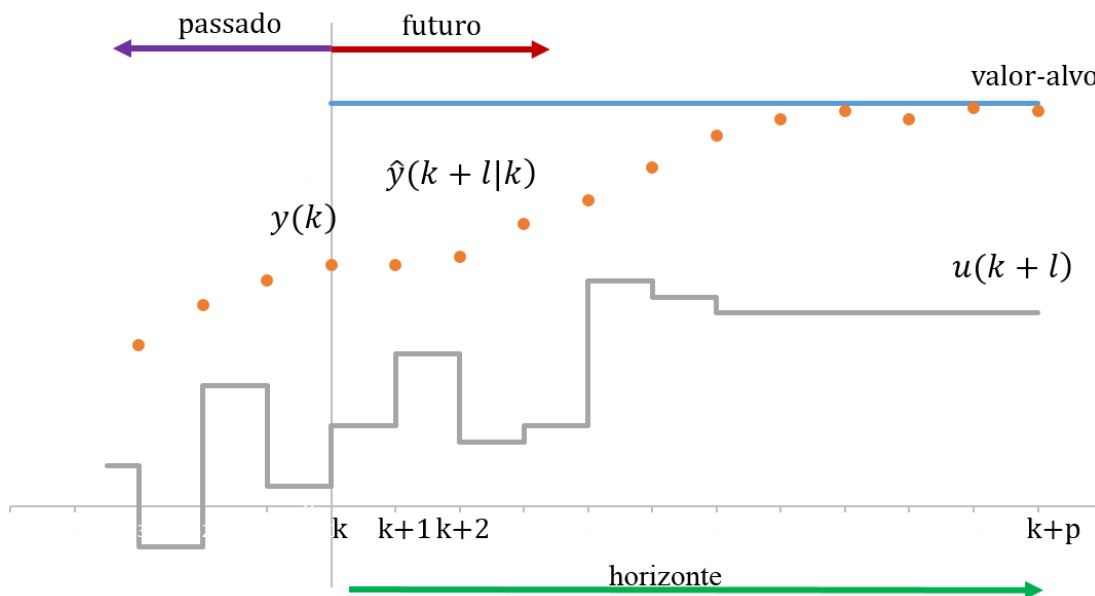


Figura 2.1: Abordagem de horizonte móvel do controle preditivo baseado em modelos. Adaptado de GARCÍA, PRETT e MORARI (1989).

Um dos principais benefícios das aplicações de MPC é sua capacidade de atuar simultaneamente nas diversas variáveis manipuladas, considerando as interações de processo entre as variáveis disponíveis na matriz dinâmica do controlador. Entender tais controladores, suas características e limitações é fundamental para desenvolver um método de auditoria compatível com as necessidades das aplicações industriais.

De uma forma geral, as ações de controle são computadas nesses algoritmos da seguinte forma (GARCÍA, C. E. PRETT e MORARI, 1989), (QIN e BADGEWELL, 2003):

1. Obtêm-se medições das variáveis de processo de entrada (manipuladas e distúrbios medidos) e de saída do controlador
2. Estima-se o comportamento do processo durante um horizonte de predição, p , utilizando medições reais do processo no instante k e modelos explícitos da dinâmica do processo.
3. Define-se o subsistema do processo que será controlado com base nas informações sobre o estado das medições e a disponibilidade de malhas e variáveis para controle.
4. Tratam-se problemas de condicionamento do sistema com os recursos disponíveis na tecnologia, tais como supressão de movimentos das entradas ou técnicas específicas, tais como limitação do valor singular (*Singular Value Thresholding*, ou SVT).
5. Obtém-se o ponto operacional ótimo em estado estacionário para as variáveis. Esses valores ótimos podem ser recebidos de uma camada de otimização externa ao controlador ou calculados internamente ao controlador utilizando um otimizador que empregue os ganhos em estado estacionário dos modelos, as restrições das variáveis e os direcionadores de lucro econômico.
6. Determina-se um plano ótimo de movimentos futuros das variáveis manipuladas. A resolução do problema de otimização que determina esse plano de movimentos deve considerar os principais objetivos do controlador que consistem em:
 - a. minimizar a violação das restrições das variáveis de entrada e saída;
 - b. levar as variáveis controladas aos valores ótimos em estados estacionário (otimização dinâmica das saídas);
 - c. utilizar os graus de liberdade restantes para levar as variáveis manipuladas às suas metas para estado estacionário;
 - d. evitar movimentos excessivos das variáveis manipuladas.
7. Implementa-se o primeiro movimento da sequência nas variáveis manipuladas.

8. Repete-se a sequência de cálculos (1 a 7) no instante $k + 1$, após o horizonte de predição haver sido defasado em um instante de tempo k .

Como exemplo de formulação do problema, apresenta-se o algoritmo de controle por matriz dinâmica (*Dynamic Matrix Control*, ou *DMC*), que é formulado como um problema de Programação Quadrática. Conforme QIN e BADGEWELL (2003), o objetivo de um controlador DMC é levar o processo o mais próximo possível dos *setpoints*, no sentido de uma abordagem de mínimos quadrados, considerando um termo de penalização dos movimentos das variáveis manipuladas. Isto resulta em menores movimentos nas variáveis manipuladas e, conseqüentemente, uma resposta menos agressiva das variáveis de saída. Esse algoritmo resolve as Equações 2.1 a 2.4 a cada intervalo de amostragem (GARCÍA, C. E. PRETT e MORARI, 1989):

$$\min_{\Delta u(k) \dots \Delta u(k+m-1)} \sum_{l=1}^p \|\hat{y}(k+l|k) - r(k+l)\|_{\Gamma_l}^2 + \|\Delta u(k+l-1)\|_{B_l}^2 \quad (2.1)$$

$$\hat{y}(k+l|k) = \sum_{i=1}^l G_i \Delta u(k+l-i) + \sum_{i=l+1}^{\eta-1} [G_i \Delta u(k+l-i)] + G_\eta u(k+l-\eta) + \hat{d}(k+l|k) \quad (2.2)$$

$$\hat{d}(k+l|k) = \hat{d}(k|k) = y(k) - \sum_{i=1}^{\eta-1} [G_i \Delta u(k-i)] + G_\eta u(k+l-\eta) \quad (2.3)$$

$$\sum_{i=1}^p C_{y_l}^j \hat{y}(k+l|k) + C_{u_l}^j u(k+l-1) + c^j \leq 0; j = 1, n_c \quad (2.4)$$

onde: $\hat{y}(k+l|k)$ é o valor predito de y no instante $k+l$, com base nas informações disponíveis no instante k ; $\hat{d}(k+l|k)$ é o valor predito dos distúrbios de processo no instante $k+l$, com base nas informações disponíveis no instante k ; $y(k)$ é o valor de medição de y no instante k ; $\Delta u(k+l) = u(k+l) - u(k+l-1)$, sendo u o vetor das variáveis manipuladas; $G_i, i = 1, \eta$ são os coeficientes da matriz de resposta à função degrau, η é a ordem de truncamento, n_c é o número de restrições, p é o horizonte de predição (em geral $p \gg \eta$); m é o número de movimentos das variáveis manipuladas no futuro; $\|x\|_Q^2 = x^T Q x$; Γ_l e B_l são matrizes de ponderação, $C_{y_l}^j, C_{u_l}^j$ e c^j são matrizes de constantes e r é a trajetória de referência.

Nesse algoritmo, o plano de movimento das variáveis manipuladas é determinado de forma a minimizar a função objetivo quadrática especificada na Equação 2.1.

A Equação 2.2 fornece a predição das saídas a partir de três termos. O primeiro termo inclui os movimentos presente e futuros das variáveis manipuladas que devem ser minimizados para resolver a Equação 2.1. O segundo termo considera apenas movimentos passados das

variáveis manipuladas e é completamente conhecido no instante k . O terceiro termo corresponde à predição dos distúrbios medidos que é mantida constante para todos os instantes futuros.

O valor predito dos distúrbios de processo, $\hat{d}(k + l|k)$, é considerado constante em todos os instantes futuros ($l \geq 0$). No instante k , ele é estimado pela diferença entre $y(k)$ e o valor de predição da saída utilizando o modelo, conforme a Equação 2.3.

A Equação 2.4 apresenta a formulação das restrições consideradas no problema de otimização.

QIN e BADGEWELL (2003) destacam que uma implementação típica de controles preditivos baseados em modelos contempla diferentes de restrições nas variáveis de entrada e de saída: restrições rígidas (*hard constraints*) que não devem ser violadas e restrições flexíveis (*soft constraints*), que permitem ser violadas por breves períodos. As restrições flexíveis podem ser tratadas inserindo um termo quadrático na função objetivo para minimizar a violação dessas restrições, ou através de uma abordagem de aproximação de *setpoints*, na qual o peso da restrição aumenta conforme se avança em direção ao *setpoint*. Já as restrições rígidas normalmente são priorizadas, de forma que o controlador possa decidir de qual restrição deva desistir em caso de inviabilidade de solução.

QIN e BADGEWELL (2003) realizaram uma análise das tecnologias de controladores MPC disponíveis no mercado até o início da década de 2000. Conforme os autores, o controlador gaussiano quadrático linear (*linear quadratic Gaussian controller, ou LQG*), desenvolvido por Kalman, na década de 1960, é o precursor dos controladores MPC atuais. No entanto, as aplicações na indústria de processos começaram a se destacar apenas no final na década de 1970, com o surgimento de uma metodologia mais genérica que o LQG, denominada Controle Preditivo Baseado em Modelos.

A Figura 2.2 resume a evolução das principais tecnologias MPC utilizadas na indústria até o início da década de 2000. Essa evolução pode ser agrupada em quatro gerações de controladores, cujas características marcantes estão relacionadas aos desafios de aplicação da tecnologia na indústria, os quais foram crescendo em tamanho, complexidade e abrangência ao longo do tempo e serão resumidamente apresentadas a seguir.

A primeira geração de controladores MPC corresponde aos produtos de software disponibilizados à indústria a partir da segunda metade da década de 1970. São exemplos de ferramentas dessa geração o DMC e o IDCOM. As aplicações dessa geração permitiram excelentes resultados no controle de processos multivariáveis sem restrições.

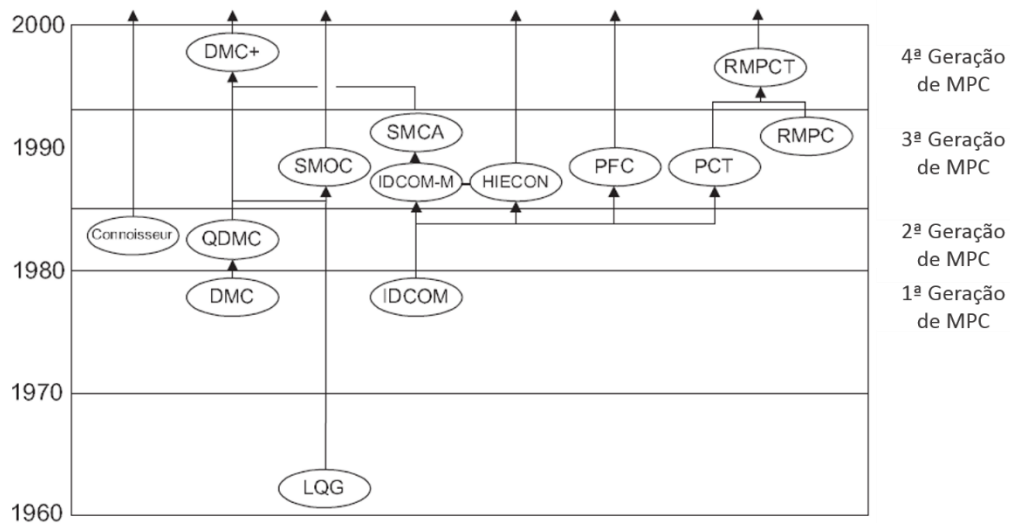


Figura 2.2: Genealogia aproximada dos controladores MPC lineares.
Adaptado de QIN e BADGEWELL (2003).

A principal característica dos algoritmos da segunda geração foi a inclusão do tratamento adequado de restrições nas variáveis de entrada e de saída. Esse avanço foi possível através da reformulação do MPC como um problema de programação quadrática (*Quadratic Programming*, ou QP), permitindo o uso de códigos para resolução de QP existentes.

A terceira geração de controladores MPC foi desenvolvida na década de 1990, visando resolver problemas de ordem prática das aplicações dos controladores, que nessa época já utilizavam um número maior de variáveis para controlar processos mais complexos. As melhorias dos algoritmos de terceira geração incluíram:

- Tratamento diferenciado aos diferentes tipos de restrições (rígidas e flexíveis) para relaxar o problema de otimização de uma forma controlada, visando sempre obter uma solução viável.
- Flexibilidade de adaptação da estrutura de controle, alterando os graus de liberdade do controlador em tempo real, de acordo com a disponibilidade de ativos do processo (tais como instrumentação e equipamentos).
- Possibilidade de utilização de modelos de espaço de estado, permitindo representar dinâmicas estáveis, instáveis e integradoras.

A quarta geração se caracteriza pela concentração de diversas tecnologias em alguns produtos em virtude dos movimentos de aquisição e fusão das empresas detentoras das tecnologias. As funcionalidades introduzidas nos algoritmos desse período incluem a possibilidade de priorizar os objetivos de controle e a introdução de técnica de controle robusto. Os produtos de software DMC+ e o RMPCT são representantes dessa geração.

Conforme FORBES, PATWARDHAN, *et al.* (2015), os desafios relacionados à utilização da tecnologia MPC na indústria entre 2005-2015 incluem a extensão das aplicações a sistemas não-lineares e aplicação de técnicas de controle robusto para controlar sistemas com incertezas de modelo. Além disso, os autores apontam que a disponibilidade de especialistas para comissionamento, monitoramento e manutenção das aplicações implantadas está cada vez mais limitada, o que leva tanto os licenciadores de tecnologias quanto clientes a buscarem maneiras de sustentar o desempenho das aplicações com o mínimo possível de intervenções manuais.

2.2 GESTÃO DAS APLICAÇÕES DE MPC

Nas indústrias de processo modernas, os controladores MPC fazem parte de uma arquitetura de funções de controle organizada em camadas (FARENZENA e TRIERWEILER, 2007), caracterizadas pelo tempo de processamento e foco de atuação de cada tipo de aplicação, conforme ilustrado na Figura 2.3. Com tempos de amostragem para execução na ordem de minutos, os controladores MPC fazem parte da camada Supervisória de Controle. Nesse contexto, a tradução das diretrizes do negócio (provenientes das camadas superiores da pirâmide) aos objetivos do controlador através da integração das diversas camadas é fundamental para garantir que a planta seja levada ao estado estacionário mais rentável. Para isso, o controlador MPC deve estar operando com desempenho aceitável.

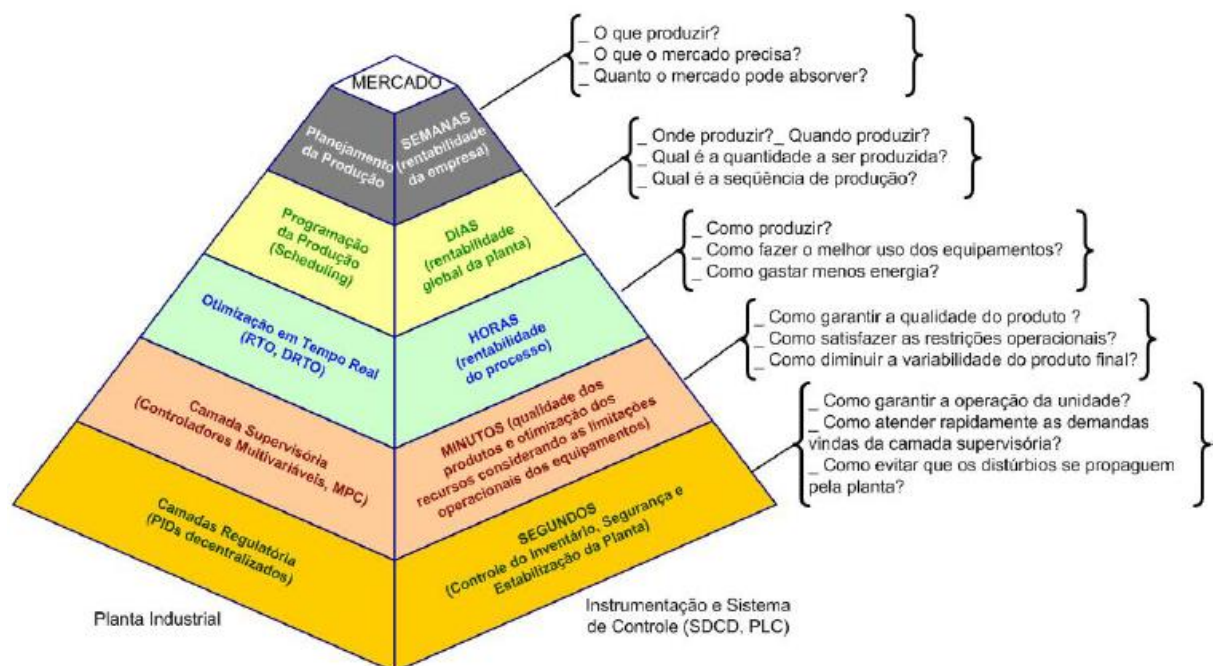


Figura 2.3: Camadas utilizadas para organizar as tecnologias de controle de processo (FARENZENA e TRIERWEILER, 2007).

Todas as camadas de controle ilustradas na Figura 2.3 devem ser geridas por ferramentas que permitam realizar auditoria, diagnóstico e propor ações corretivas para garantir o bom emprego e retorno das aplicações (FARENZENA e TRIERWEILER, 2007).

Conforme FORBES, PATWARDHAN *et al.* (2015), embora o monitoramento dessas aplicações seja normalmente realizado por indicadores técnicos (tais como, o fator de serviço da aplicação, saturação das variáveis manipuladas do controlador e indicadores de qualidade de modelo), ainda não existe uma abordagem padronizada e consistente para monitoramento de desempenho dos controladores MPC. Os autores recomendam que o monitoramento eficaz de aplicações MPC seja feito em três camadas:

- Camada de Indicadores de Gestão, utilizada para fornecer informações a toda a empresa sobre a utilização e o desempenho econômico das aplicações;
- Camada de Monitoramento de Engenharia, focada na avaliação da qualidade dos modelos do controlador e de inferências utilizadas em controle;
- Camada de Monitoramento Operacional, que consiste em indicadores de baixo nível, tais como como fator de serviço e saturação de variáveis, para comprovar a utilização efetiva da aplicação pela equipe de operação.

As tecnologias de auditoria de desempenho dos controladores MPC estão incluídas no escopo da Camada de Monitoramento de Engenharia. Os fatores que afetam o desempenho de um controlador podem ser agrupados em fontes internas e externas ao controlador (TIAN, CHEN, G. e CHEN, S., 2011) e estão resumidos na Figura 2.4.

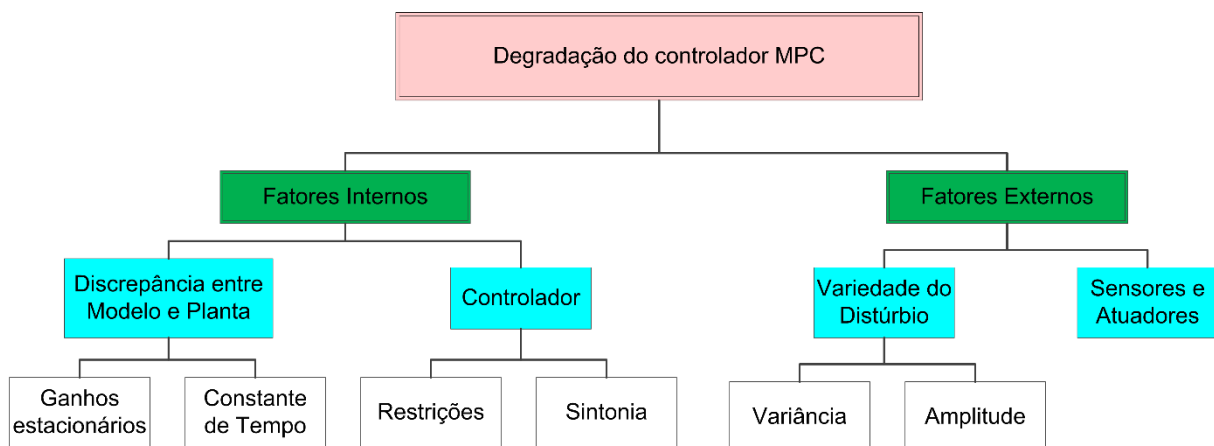


Figura 2.4: Causas de degradação de desempenho de um controlador MPC.
Adaptado de TIAN, CHEN, G. e CHEN, S. (2011).

Os fatores internos ao controlador contemplam a discrepância entre modelos e dinâmica da planta, que pode ser tanto associada à qualidade dos modelos originalmente identificados quanto às alterações da dinâmica do processo ou ponto operacional. As alterações de dinâmica

podem ser decorrentes de grandes mudanças na configuração da planta, tais como em projetos de expansão, quanto a mudanças menores, devido, por exemplo, à troca de válvulas de controle importantes por outras com características diferentes daquelas utilizadas na identificação dos modelos. Esses fatores internos constituem uma das grandes preocupações nesse tipo de controlador, visto que grande parte deles utiliza modelos empíricos, identificados em uma determinada condição operacional. De acordo com BADWE, GUDI e PATWARDHAN (2009), apesar das discrepâncias entre modelo e planta serem inevitáveis, é altamente desejável que os modelos sejam suficientemente precisos para se obter um controle satisfatório do processo.

A sintonia do controlador e a configuração inadequada de restrições constituem outras fontes de degradação de desempenho internas ao controlador. Os fatores externos ao controlador incluem distúrbios de processo e falhas de instrumentação (sensores e atuadores).

2.3 AUDITORIA DE DESEMPENHO DE CONTROLADORES MPC.

Os trabalhos de JELALI (2006), YUAN, LENNOX e MCEWAN (2009) e ZAGROBELNY (2014) fornecem perspectiva abrangentes sobre a evolução das técnicas de auditoria de controladores industriais, incluindo aquelas aplicáveis a controladores preditivos baseados em modelos.

Conforme YUAN, LENNOX e MCEWAN (2009), as técnicas de auditoria de desempenho de controladores se originaram nas técnicas para projeto ótimo desses algoritmos, e se baseavam no uso de análise de autocorrelação para comparar o desempenho observado com um controlador ideal.

JELALI (2006) afirma que o critério mais comumente usado nas técnicas de avaliação de desempenho é a variância (ou, equivalentemente, o desvio-padrão), principalmente para malhas de controle regulatório. Como esse tipo de controlador está intimamente ligado ao desempenho do processo, qualidade do produto e lucro, o desempenho é considerado inaceitável se a variável controlada exceder determinados valores críticos.

Conforme ZAGROBELNY (2014), o método de variância mínima desenvolvido por HARRIS (1989) foi um marco inicial no monitoramento de desempenho de controladores. Esse método utiliza dados em malha fechada para estimar a variância mínima possível para a saída de um sistema específico e a compara com a variância medida no processo real. A principal contribuição do método consiste em estimar a variância mínima a partir de dados em malha fechada, sem necessitar de um modelo de processo ou distúrbio, exceto o tempo de atraso. No entanto, apesar da simplicidade do método, sua aplicação a sistemas multivariáveis não é

imediate e ainda ocupa um lugar de destaque na área de pesquisa de monitoramento de desempenho de controladores.

De acordo com FORBES, PATWARDHAN *et al.* (2015), as diversas tecnologias de controle preditivo baseado em modelos possuem diferentes funcionalidades e níveis de complexidade para configuração e sintonia das aplicações, o que dificulta a padronização do processo de monitoramento até dentro da mesma empresa. Aliados à escassez de expertise para monitoramento e utilização das aplicações de MPC, torna-se essencial que o método de auditoria do controlador seja fácil de ser aplicado a qualquer tipo de tecnologia.

HUANG, KADALI *et al.* (2000) afirmam que a referência de variância mínima não é a mais adequada para avaliar o desempenho de controladores preditivos baseados em modelo, nos quais os principais objetivos são o tratamento de restrições e a otimização econômica. Em seu trabalho, os autores apresentam uma abordagem sistemática para detectar as causas de baixo desempenho do controlador MPC, incluindo a avaliação da função objetivo, a qualidade dos modelos dinâmicos, estabilidade do controlador e os controles antecipatórios. Embora não se trate de uma metodologia completa para diagnóstico de controladores, conforme comentário dos próprios autores, esse caso de sucesso de diagnóstico no final da década de 1990 é um importante exemplo do potencial que ferramentas de auditoria e diagnóstico de controladores MPC baseadas em dados históricos de processo para recuperar o desempenho de aplicações, sem necessidade de executar testes na planta para re-identificar todo o controlador.

Como a referência de variância mínima pode ser considerada um critério adequado para diversos processos, diversos trabalhos foram publicados propondo uma definição mais flexível do critério de desempenho ótimo, estendendo a lei de controle de variância mínima a malhas de controle multivariadas (ZAGROBELNY, 2014). YUAN, LENNOX e MCEWAN (2009) e JELALI (2006) destacam os métodos que utilizam referências definidas a partir do Controlador Linear Quadrático Gaussiano (LQG), propostas por DAI e YANG (2004) e HUANG e SHAH (1999). A contribuição do trabalho de YUAN, LENNOX e MCEWAN (2009) é uma plataforma para monitoramento de desempenho de malhas de controle em tempo real.

Para controladores preditivos baseados em modelos, JELALI (2006), YUAN, LENNOX e MCEWAN (2009) e ZAGROBELNY (2014) destacam as referências de desempenho propostas por JULIEN, FOLEY e CLUETT (2004) e a referência baseada em dados históricos proposta por SCHÄFER e ÇINAR (2004). ZAGROBELNY (2014) também destaca os métodos de auditoria de desempenho que realizam análise de dados de processo usando técnicas estatísticas ou baseadas em subespaços, tais como os trabalhos propostos por MCNABB e QIN (2003,2005), YU e QIN (2008a,b) e TIAN, CHEN, G. e CHEN, S. (2011). Os trabalhos de

DUMONT, KAMMER *et al.* (2002) e SUN, QIN, *et al.* (2013) se destacam dentre aqueles baseados na comparação do erro de predição com dados em malha aberta.

O trabalho de ZAGROBELNY (2014) foi motivado pela busca de um método sistemático para avaliar se os controladores MPC apresentam desempenho ótimo e propôs em um índice de referência (*benchmarking*) para monitoramento do desempenho de aplicações MPC denominado Índice Chave de Desempenho (*Key Performance Index*, ou KPI), o qual corresponde à expectativa da função de custo minimizada pelo regulador MPC.

BADWE, GUDI e PATWARDHAN (2009) propuseram um método baseado na correlação parcial entre as variáveis manipuladas e erro do controlador para detectar e isolar os modelos da matriz dinâmica com discrepâncias entre modelo e planta. 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 de correlação. Resumidamente, o método segue as seguintes etapas para cada variável controlada:

1. Selecionar dados de processo (resíduos de modelo, $e(k)$, e variáveis de entrada do controlador, $u(k)$) para um período com variações de *setpoint*, $r(k)$, disponíveis para todas as variáveis manipuladas.
2. Estimar a função de sensibilidade das entradas em relação aos *setpoints*, \hat{S}_{ru}
3. Estimar u^r , que corresponde à reconstrução das variáveis de entrada considerando apenas o efeito dos *setpoints*, $r(k)$,:

$$\hat{u}^r(k) = \hat{S}_{ru}r(k) \quad (2.5)$$

4. Descorrelacionar \hat{u}_i^r do restante das MVs:
 - a. Identificar os modelos H_{u_i} entre \hat{u}_i^r e as demais MVs utilizando um modelo baseado no erro de predição (*Prediction Error Method*, ou PEM), conforme LJUNG (1999), sendo que \tilde{u}^r contém todas as MVs, exceto \hat{u}_i^r e ϵ_{u_i} é o componente de \hat{u}_i^r que não está correlacionado às demais MVs.

$$\hat{u}_i^r(k) = H_{u_i} \tilde{u}^r(k) + \epsilon_{u_i}(k) \quad (2.6)$$

- b. Isolar o componente ϵ_{u_i} , independente de ruídos de medição e das outras MVs:

$$\hat{\epsilon}_{u_i}(k) = \hat{u}_i^r(k) - H_{u_i} \tilde{u}^r(k) \quad (2.7)$$

5. Analogamente, descorrelacionar o erro de predição, e_j , de todas as MVs, exceto u_i :
 - c. Identificar os modelos H_{e_j} :

$$e_j(k) = H_{e_j} \tilde{u}^r(k) + \epsilon_{e_j}(k) \quad (2.8)$$

- d. Isolar o componente ϵ_{e_j} , independente de ruídos de medição e das outras MVs

$$\hat{\epsilon}_{e_j}(k) = e_j(k) - H_{e_j} \tilde{u}^r(k) \quad (2.9)$$

6. Avaliar a correlação entre $\hat{\epsilon}_{u_i}$ e $\hat{\epsilon}_{e_j}$. Uma correlação diferente de zero significa discrepância de modelo relevante. Quanto mais significativa a correlação, maior a discrepância encontrada no canal $u_i - y_j$.

CARLSSON (2010) propôs uma simplificação para facilitar a aplicação do método proposto por BADWE, GUDI e PATWARDHAN (2009) em processos industriais. Trata-se de uma extensão do método original para remover o efeito de auto correlação das variáveis manipuladas nos cálculos de correlações parciais. Outros dois trabalhos estudaram a influência de estruturas de modelos nos resultados de correlação parciais proposto por BADWE, GUDI e PATWARDHAN (2009):

- IQBAL, YUSOFF e TUFA (2014) estudaram a eficácia na detecção de discrepâncias entre modelo e planta (*model-plant mismatches*, ou MPMs) ao usar modelos auto regressivos com entradas exógenas (*Auto-Regressive with Exogenous Inputs*, ou ARX) e modelos de resposta ao impulso finita (*Finite Impulse Response*, ou FIR) na etapa de decorrelação entre as variáveis. Os autores concluíram que as estruturas de modelo ARX superam os resultados obtidos com modelos de estrutura FIR na identificação discrepâncias de ganho entre modelo e planta.
- LOEFF (2014) demonstrou que o método proposto por CARLSSON (2010) é uma solução particular do método original quando se usam modelos de estrutura FIR. O seu trabalho mostra que FIR é o melhor modelo de estrutura quando se utilizam métodos de mínimos quadrados e como a ordem dos modelos usados na etapa de decorrelação afetam os resultados de correlação parciais.

BADWE, GUDI e PATWARDHAN (2009) destacam que o método em seu trabalho poderia ser incorporado como parte de um procedimento mais amplo de auditoria de controladores, podendo ser invocado após o diagnóstico de que o problema dominante afetando o desempenho do controlador estivesse relacionado à discrepância entre modelo e planta. Nesse sentido, os trabalhos a seguir propuseram formas de detectar se incertezas de modelo poderiam ser a causa de degradação de desempenho do controlador.

BADWE, PATWARDHAN *et al.* (2010) propuseram uma metodologia baseada nos índices de sensibilidade relativa (*Relative Sensitivity Index*, ou SRI) e de sensibilidade projetada (*Designed Sensitivity Index*, ou DSI) e na relação de variabilidade (*Variability Ratio*, ou VR) para quantificar a influência de discrepâncias entre modelo e planta no desempenho do controlador em relação ao caso de projeto. Esse trabalho também concluiu que o impacto da

discrepância entre modelo e planta na qualidade do controle depende tanto da intensidade da discrepância quanto da variação dos setpoints no período avaliado.

TSAI, GOPALUNI *et al.* (2015) propuseram uma metodologia de duas etapas para detecção de MPM durante operação do controlador que usa uma adaptação do índice de sensibilidade relativa (SRI) proposto por BADWE, PATWARDHAN *et al.* (2010) para identificar os modelos da matriz dinâmica com discrepâncias significativas entre modelo e planta, para casos específicos de padrões de distúrbios e de excitação de *setpoints*.

BOTELHO, TRIERWEILER *et al.* (2015b,2016) retomaram a ideia introduzida por BADWE, PATWARDHAN *et al.* (2010) referente à utilização de um indicador de variabilidade para quantificação da discrepância entre a dinâmica da planta e o modelo do controlador. Os autores propuseram o indicador de variância relativa, *Ivar*, que relaciona a variância das variáveis controladas (y) com aquela da saída estimada pelo modelo nominal em malha fechada (y_0), ambas avaliadas em relação ao valor médio do período:

$$I_{\text{var}} = \frac{\text{var}(y - \bar{y})}{\text{var}(y_0 - \bar{y}_0)} \quad (2.10)$$

A saída nominal do sistema em malha fechada, y_0 , pode ser calculada através da função sensibilidade nominal, S_0 :

$$y_0 = S_0(y_{\text{sim}} - y) + y \quad (2.11)$$

onde y_{sim} corresponde à saída simulada do modelo nominal perturbado pela matriz das ações de controle, u , e y é a matriz das variáveis de saída do controlador (medidas). S_0 é a função de sensibilidade nominal do controlador, e funciona como um filtro para os resíduos de simulação ($y_{\text{sim}} - y$), retendo o erro de simulação que não é compensado pela ação de retroalimentação do controlador. O cálculo de *Ivar* para as variáveis controladas permite delimitar o escopo de revisão do controlador, identificando aqueles que precisam ser remodeladas.

A função sensibilidade nominal fornece um diagnóstico completo do modelo, destacando não apenas o efeito das incertezas no modelo nas saídas correspondentes (através de elementos diagonais S_0), mas também como uma saída afeta as demais (através dos elementos fora da diagonal). Assim, *Ivar* pode ser calculado tanto usando a função de sensibilidade completa, como já apresentado, quanto usando os seus elementos diagonais. As saídas do controlador nominais calculados apenas com base nos elementos da diagonal de S_0 são identificadas como:

$$y_{0\text{diag}} = S_{0\text{diag}} \cdot (y_{\text{sim}} - y) + y \quad (2.12)$$

O indicador *Ivar* calculado com base no $y_{0\text{diag}}$ é identificado como *Ivar_{diag}*:

$$Ivar_{diag} = \frac{var(y - \bar{y})}{var(y_{0diag} - \bar{y}_{0diag})} \quad (2.13)$$

Pode-se usar o indicador $Ivar$ quando se deseja saber o impacto do problema de modelagem daquela variável em relação a todas as outras, ou $Ivar_{diag}$ quando se deseja avaliar apenas os efeitos na própria variável.

Segundo a metodologia, uma variável deve ser considerada sem problemas de modelagem afetando o desempenho do controle caso os indicadores de variabilidade $Ivar$ e $Ivar_{diag}$ estejam próximos a um valor unitário, ou seja, quando não houver uma diferença significativa de variância entre as saídas medida e nominal do controlador.

O diferencial do método proposto por BOTELHO, TRIERWEILER *et al.* (2015b) é a independência de variações de *setpoint* para sua utilização, já que y_0 pode ser determinado a partir da função nominal de sensibilidade, das saídas de controlador simulado e variáveis medidas, de acordo com as Equações 2.11 e 2.12. O método também foi aplicado com êxito a controladores industriais (BOTELHO, TRIERWEILER *et al.*, 2015c).

BOTELHO, TRIERWEILER *et al.* (2015a) publicaram uma extensão do método para o diagnóstico da fonte dominante de incertezas do modelo, baseado na comparação entre a saída nominal, y_{0diag} , e o correspondente erro nominal, e_{0diag} , ambos calculados com base nos elementos diagonais da função de sensibilidade para capturar os efeitos dos erros de modelagem isoladamente, desconsiderando os efeitos de interação entre os canais.

O erro nominal do controlador que representa o efeito dos problemas de modelagem em malha fechada é definido por:

$$e_0 = y_0 - y = S_0(y_{sim} - y) \quad (2.14)$$

Utilizando-se apenas os elementos diagonais da função de sensibilidade, obtém-se e_{0diag} :

$$e_{0diag} = y_{0diag} - y = S_{0diag}(y_{sim} - y) \quad (2.15)$$

A comparação entre y_{0diag} e e_{0diag} é realizada utilizando derivadas das estatísticas de assimetria (skn) e curtose (kts) de amostras das distribuições de interesse ao longo de janelas móveis:

$$dkts_{e_{0diag}}^{MW} = \frac{d(kts_{e_{0diag}}^{MW})}{dt} \quad (2.16)$$

$$dkts_{y_{0diag}}^{MW} = \frac{d(kts_{y_{0diag}}^{MW})}{dt} \quad (2.17)$$

$$dskn_{e_{0diag}}^{MW} = \frac{d(sk_{e_{0diag}}^{MW})}{dt} \quad (2.18)$$

$$dskn_{y_0diag}^{MW} = \frac{d(skn_{y_0diag}^{MW})}{dt} \quad (2.19)$$

onde $kts_{e_0diag}^{MW}$ e $kts_{y_0diag}^{MW}$ correspondem às medidas estatísticas de curtose para as distribuições e_{0diag} and y_{0diag} para a janela móvel de tamanho MW , $skn_{e_0diag}^{MW}$, enquanto $skn_{y_0diag}^{MW}$ correspondem às medidas estatísticas de assimetria para as distribuições de e_{0diag} and y_{0diag} para a janela móvel de tamanho MW .

Conforme BELFIORE (2015), assimetria e curtose são medidas estatísticas que caracterizam a forma da distribuição dos elementos da população em torno da média. A assimetria é uma medida da falta de simetria dos dados da distribuição em torno da média, enquanto a curtose fornece informação o grau de achatamento da distribuição de frequências (altura do pico da curva) em relação a uma distribuição teórica, a qual geralmente corresponde à distribuição normal. De acordo com DECARLO (1997), as medidas estatísticas de forma podem ser calculadas por:

$$skn = \frac{\frac{1}{K} \sum_{i=1}^K (Z_i - \bar{Z})^3}{\left(\sqrt{\frac{1}{K} \sum_{i=1}^K (Z_i - \bar{Z})^2}\right)^3} \quad (2.20)$$

$$kts = \frac{\frac{1}{K} \sum_{i=1}^K (Z_i - \bar{Z})^4}{\left(\frac{1}{K} \sum_{i=1}^K (Z_i - \bar{Z})^2\right)^2} \quad (2.21)$$

Onde Z é a distribuição para qual as estatísticas de assimetria e curtose serão computadas e K é o número de elementos da amostra da distribuição.

No método, essas estatísticas são calculadas em janelas móveis para garantir que todos os comportamentos dinâmicos que afetem o desempenho do controlador sejam capturados. Os autores sugerem utilizar tamanhos de janelas móveis variando entre $0.5p$ e $2p$, sendo p o tamanho do horizonte de predição do controlador MPC, para capturar apenas as inconsistências na frequência de trabalho do MPC.

Para cada tamanho de janela móvel, MW , a correlação entre as distribuições estatísticas de e_{0diag} e y_{0diag} são avaliadas através do coeficiente de correlação de Pearson, definido por:

$$c_Z^{MW} = \frac{cov(Z_{e_0diag}^{MW}, Z_{y_0diag}^{MW})}{\sqrt{var(Z_{e_0diag}^{MW}) \cdot var(Z_{y_0diag}^{MW})}} \quad (2.22)$$

onde cov e var representam, respectivamente, a covariância e a variância dos sinais correspondentes, Z é a medida estatística avaliada para a distribuição ($dkts$ ou $dskn$, conforme

Equações 2.16 a 2.19) e c_Z^{MW} é o coeficiente de correlação correspondente à distribuição estatística de Z para um tamanho de janela móvel MW .

Como a análise é efetuada para diversos tamanhos de janelas móveis, o método propõe avaliar valores médios dos coeficientes de correlação obtidos para cada tamanho de janela, \bar{c}_{kts} e \bar{c}_{skn} :

$$\bar{c}_Z = \frac{\sum_{MW=0.5p}^{2p} |c_Z^{MW}|}{N_{MW}} \quad (2.23)$$

onde N_{MW} é a quantidade de janelas móveis avaliadas.

A distinção entre a fonte predominante de problema de modelagem é feita com base na estimativa do intervalo de confiança da correlação (CI), definida por:

$$CI = ZC_{\alpha/2} \frac{\sigma(\bar{c}_Z)}{\sqrt{K}} \quad (2.24)$$

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 de \bar{c}_Z e K é o número de dados da amostra. Caso o coeficiente de correlação baseado em pelo menos uma das estatísticas, \bar{c}_Z , apresente um valor superior a CI , conclui-se que haja uma correlação significativa entre y_{0diag} e e_{0diag} , indicando que o desempenho do controlador esteja sendo afetado predominantemente por discrepâncias entre modelo e planta (*Model-plant mismatch*, ou MPM). Caso contrário, considera-se que o problema seja devido à presença de distúrbios não medidos (*Unmeasured Disturbances*, ou UD).

A metodologia proposta por BOTELHO, TRIERWEILER *et al.* (2015a,b,2016), por ser independente de setpoint, é a mais adequada para implementação em controladores MPC industriais, os quais podem ter variáveis controladas entre faixas ou no setpoint. Ela permite determinar se há MPM, e nesse caso, que quais CVs se concentra. Tendo isto em mente, para completar o processo de auditoria ainda é necessária uma última etapa de diagnóstico para responder qual ou quais variáveis manipuladas, e respectivamente, quais canais, apresentam problemas de modelagem. A presente dissertação está inserida justamente nesta última etapa de diagnóstico. No próximo capítulo são apresentadas as bases da metodologia desenvolvida nesta dissertação.

3. METODOLOGIA PROPOSTA

Neste capítulo é apresentada a metodologia proposta para a localização dos canais mais relacionados às discrepâncias em relação à planta encontrados nas variáveis de saída do controlador MPC. A detecção das variáveis controladas com discrepâncias de modelo que estejam efetivamente afetando o controlador é um pré-requisito para a aplicação do método. Nesta dissertação, utiliza-se a metodologia desenvolvida por BOTELHO, TRIERWEILER *et al.* (2015a, b, 2016) para essa finalidade. Sendo assim a metodologia proposta nesta dissertação consiste na última etapa de diagnóstico, necessária para se determinar quais são os canais que apresentam problemas de modelagem.

3.1 CONCEITOS FUNDAMENTAIS

3.1.1 Propriedades fundamentais de uma malha de controle

A Figura 3.1 representa o diagrama de blocos de uma malha de controle genérica (ÅSTROM e MURRAY, 2002) monovariável. Trata-se de um sistema composto por dois componentes: o processo, P , e o controlador, que está dividido em um controle por retroalimentação, C , e um controle pré-filtro, F , de *setpoint* que consiste em um segundo grau de liberdade para o controlador retroalimentado. Existem dois tipos de distúrbios agindo sobre o processo: os distúrbios de carga (d) e o ruído de medição (n). Distúrbios de carga são aqueles que afastam o processo do comportamento desejado e que podem entrar no processo de diversas maneiras, embora tenham sido representados simplificadaamente como um distúrbio na entrada do processo. A variável de processo w é a variável física que se deseja controlar. O controle se baseia no sinal medido y , que corresponde à medição de w afetada pelo ruído de medição, n . O controle atua no processo através da variável u . A variável e corresponde ao erro de controle, definido pela diferença entre a referência, r , e a variável controlada medida, y .




Figura 3.1: Diagrama de blocos de uma malha de controle genérica monovariável. Adaptado de ÅSTROM e MURRAY (2002).

A malha de controle da Figura 3.1 é influenciada por três sinais de entrada (r , d , n). Considerando os sinais de saída w , y e u , há nove relações entre as variáveis de entrada e de saída que são de interesse para controle. Para um sistema linear, essas relações são denominadas funções de transferência. Tomando-se W , Y , U , R , D e N como as transformadas de Laplace de w , y , u , r , d e n , as relações obtidas são:

$$W = \frac{P}{1+PC} D - \frac{PC}{1+PC} N + \frac{PCF}{1+PC} R \quad (3.1)$$

$$Y = \frac{P}{1+PC} D + \frac{1}{1+PC} N + \frac{PCF}{1+PC} R \quad (3.2)$$

$$U = -\frac{PC}{1+PC} D - \frac{C}{1+PC} N + \frac{CF}{1+PC} R \quad (3.3)$$

Para sistemas que não utilizam filtragem do *setpoint*, i.e., ($F=1$), as propriedades fundamentais da malha de controle podem ser capturadas em um conjunto de quatro funções de transferência:

$$S = \frac{1}{1+PC}, \quad \text{Função de sensibilidade} \quad (3.4)$$

$$T = \frac{PC}{1+PC}, \quad \text{Função sensibilidade complementar} \quad (3.5)$$

$$G_{yd} = \frac{P}{1+PC} = PS, \quad \text{Função de sensibilidade ao distúrbio de carga ou função de sensibilidade de entrada} \quad (3.6)$$

$$-G_{un} = \frac{C}{1+PC} = CS, \quad \text{Função de sensibilidade ao ruído de medição, ou função de sensibilidade de saída} \quad (3.7)$$

A função de sensibilidade mostra o efeito de retroalimentação do controlador na variável de saída. Assim, para um controlador baseado em modelos, a capacidade de atenuação de distúrbios pode ser avaliada filtrando as saídas medidas pela função de sensibilidade. Esta função e a correspondente função complementar de sensibilidade, T , expressam estabilidade e robustez do controlador em relação às incertezas de processo. Elas são chamadas complementares, pois:

$$S + T = 1 \quad (3.8)$$

3.1.2 Correlação cruzada entre séries temporais

A função de correlação cruzada é uma ferramenta de análise estatística utilizada para estimar o grau de correlação entre versões de dois sinais defasadas no tempo. Trata-se de uma função apropriada para comparar séries temporais com uma possível relação causal, como é o caso das variáveis manipuladas e controladas, uma vez que devido à dinâmica do processo,

incluindo o tempo morto, o efeito da variável manipulada na controlada pode não ser instantâneo.

Conforme BOX, JENKINS e REINSEL (1994), a estimativa do coeficiente de correlação cruzada para as séries temporais y_1 e y_2 estacionárias, defasadas por λ intervalos de amostragem, $XCF_{y_1 y_2}(\lambda)$, pode ser obtida por:

$$XCF_{y_1 y_2}(\lambda) = \frac{c_{y_1 y_2}(\lambda)}{s_{y_1} s_{y_2}}; \quad \lambda = 0, \pm 1, \pm 2, \dots \quad (3.9)$$

onde, $c_{y_1 y_2}(\lambda)$ corresponde à estimativa do coeficiente de covariância cruzada para cada valor de defasagem λ , computada para amostras das séries temporais de tamanho K , conforme Equação 3.10. Nessa equação, \bar{y}_1 e \bar{y}_2 são as médias dos valores das amostras das respectivas séries.

$$c_{y_1 y_2}(\lambda) = \begin{cases} \frac{1}{K} \sum_{k=1}^{K-\lambda} (y_1(k) - \bar{y}_1)(y_2(k + \lambda) - \bar{y}_2); & \lambda = 0, 1, 2, \dots \\ \frac{1}{K} \sum_{k=1}^{K+\lambda} (y_2(k) - \bar{y}_2)(y_1(k - \lambda) - \bar{y}_1); & \lambda = -1, -2, \dots \end{cases} \quad (3.10)$$

Os termos s_{y_1} e s_{y_2} da Equação 3.9 correspondem aos desvios-padrão de cada amostra, obtidos por:

$$s_{y_1} = \sqrt{c_{y_1 y_1}(0)} = \sqrt{\text{var}(y_1)} \quad (3.11)$$

$$s_{y_2} = \sqrt{c_{y_2 y_2}(0)} = \sqrt{\text{var}(y_2)} \quad (3.12)$$

A Figura 3.2 ilustra um exemplo de gráfico de correlação cruzada entre amostras de duas séries temporais hipotéticas, considerando a faixa de intervalos de defasagem, λ , variando entre -50 e 50. Observa-se que a correlação máxima ocorreu para o intervalo de defasagem 23.

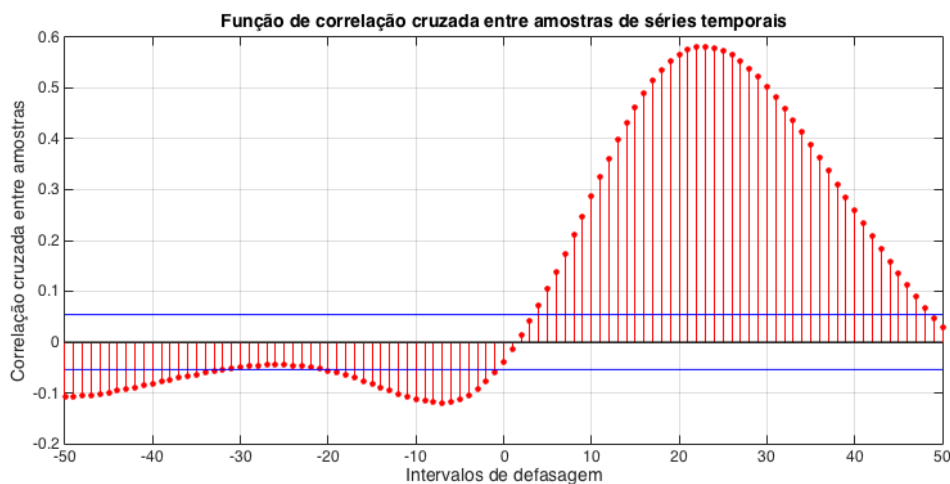


Figura 3.2: Exemplo de função de correlação cruzada entre amostras de duas séries temporais.

Conforme DRAPER e SMITH (1998), o intervalo de confiança para a correlação pode ser obtido a partir do coeficiente de correlação estimado, $XCF_{y_1y_2}$, utilizando-se a aproximação conhecida como estatística ζ de Fisher:

$$\begin{aligned}\zeta &= \frac{1}{2} \ln \left(\frac{1 + XCF_{y_1y_2}}{1 - XCF_{y_1y_2}} \right) \\ &= \tanh^{-1}(XCF_{y_1y_2}) \sim N \left(\tanh^{-1}(XCF'_{y_1y_2}), \frac{1}{K-3} \right)\end{aligned}\quad (3.13)$$

onde $XCF'_{y_1y_2}$ é coeficiente de correlação verdadeiro, porém desconhecido, e K é o número de dados nas amostras de y_1 e y_2 . Assim, obtém-se intervalo de confiança para $XCF'_{y_1y_2}$, com nível de significância α , resolvendo-se a equação:

$$\frac{1}{2} \ln \left(\frac{1 + XCF_{y_1y_2}}{1 - XCF_{y_1y_2}} \right) \pm z \left(1 - \frac{\alpha}{2} \right) \left\{ \frac{1}{K-3} \right\}^{1/2} = \frac{1}{2} \ln \left(\frac{1 + XCF'_{y_1y_2}}{1 - XCF'_{y_1y_2}} \right) \quad (3.14)$$

onde $z \left(1 - \frac{\alpha}{2} \right)$ é o valor crítico de uma distribuição normal padrão para o nível de significância α . Adicionalmente, pode-se testar a hipótese nula $H_0: XCF'_{y_1y_2} = 0$, contra a hipótese alternativa $H_1: XCF'_{y_1y_2} \neq 0$ através de um teste z bicaudal, calculado pela expressão:

$$z_{cal} = \sqrt{K-3} \left\{ \frac{1}{2} \ln \left(\frac{1 + XCF_{y_1y_2}}{1 - XCF_{y_1y_2}} \right) - \frac{1}{2} \ln \left(\frac{1+0}{1-0} \right) \right\} = \frac{\sqrt{K-3}}{2} \ln \left(\frac{1 + XCF'_{y_1y_2}}{1 - XCF'_{y_1y_2}} \right) \quad (3.15)$$

O valor da estatística z calculada pela Equação 3.15 deve ser comparado com o valor crítico referente ao nível de significância, α , desejado. A hipótese nula deve ser rejeitada se:

$$|z_{cal}| \geq \left| z \left(1 - \frac{\alpha}{2} \right) \right| \quad (3.16)$$

3.2 METODOLOGIA

Objetivando a facilidade da aplicação da metodologia a controladores industriais, propõe-se que um método ideal para localização dos modelos que estejam afetando o desempenho do controlador apresente as seguintes características, algumas das quais já foram recomendadas nos trabalhos de HUGO (2002) e BOTELHO, TRIERWEILER *et al.* (2016):

1. Capacidade de isolar os modelos do controlador MPC mais relacionados com as discrepâncias de modelo encontradas para as variáveis controladas;
2. Não ser intrusivo ao processo, ou seja, não demandar testes de planta para avaliar o desempenho do controlador;
3. Não utilizar o setpoint das variáveis controladas como uma referência para a auditoria, permitindo a sua aplicação a variáveis controladas em faixas;

4. Ser aplicável a diferentes estratégias de controle preditivo baseado em modelos, incluindo estruturas MPC descentralizadas;

5. Permitir avaliar a influência de variáveis externas no desempenho de controladores afetados por distúrbios não medidos.

Cada canal da matriz de controle corresponde a um modelo que relaciona as variações em uma variável de entrada do processo (variável manipulada ou variável distúrbio) com as variações esperadas em uma saída do processo (variável controlada). O objetivo do método proposto é encontrar a contribuição de cada canal na discrepância entre modelo e planta encontrada para a variável controlada durante o período da auditoria.

A discrepância de modelo da variável de saída é fornecida pelo erro nominal do controlador, e_0 , definido pela Equação (2.14).

Quanto à contribuição de cada canal, sabe-se que, para controladores lineares do tipo MPC, a predição da variação da saída do controlador, $\Delta\hat{y}$, é uma combinação linear dos resultados gerados a partir dos modelos de cada canal da matriz de controle, G , aplicada a variações nas entradas do controlador, Δu :

$$\Delta\hat{y}_i(k+1) = \sum_{j=1}^{n_{MV}} G(i,j)\Delta u_j(k) \quad (3.17)$$

onde $\Delta\hat{y}_i(k+1)$ é a variação da variável de saída y_i predita para o instante $k+1$; $G(i,j)$ são os modelos entre as variáveis de entrada u_j e de saída y_i ; Δu são as variações das variáveis de entrada do controlador no período e n_{MV} é o número de variáveis de entrada.

A estimativa da parcela de contribuição de cada canal na saída do controlador pode então ser obtida pela aplicação da função de transferência de cada canal às variáveis de entradas do controlador:

$$\hat{y}_p(i,j) = G(i,j)\tilde{u}(j) \quad (3.18)$$

onde $\hat{y}_p(i,j)$ é a estimativa da parcela de contribuição do canal $(y_i - u_j)$ para $y(i)$ obtida através do 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:

$$\tilde{u}(k) = u(k) - u(0) \quad (3.19)$$

No entanto, a comparação das contribuições de cada canal com o erro de modelagem é mais efetiva se for utilizada apenas a parcela de distúrbio de $u(k)$ que não é atenuada pelo controlador. Conforme o item 3.1.1, esse efeito é obtido ao se filtrar as saídas medidas pela função de sensibilidade.

Assim, define-se a saída parcial filtrada, \hat{y}_{pf} , como o resultado da aplicação do filtro $S_0(i, i)$ corresponde ao elemento diagonal da função de sensibilidade nominal do controlador para a variável de saída que está sendo analisada, à parcela de contribuição de cada canal na saída do controlador, \hat{y}_p :

$$\hat{y}_{pf}(i, j) = S_0(i, i)\hat{y}_p(i, j) = S_0(i, i)G(i, j)\check{u}(j) \quad (3.20)$$

onde os índices i e j correspondem às variáveis de entrada e de saída do controlador, u_j e y_i , respectivamente. \hat{y}_{pf} corresponde à estimativa da contribuição de cada modelo na variável de saída para os distúrbios não atenuados pelo controlador e as seguintes observações se aplicam ao seu cálculo:

1. O filtro da simulação usando apenas o canal diagonal referente a cada variável controlada da função de sensibilidade, $S_0(i, i)$, pois é ele que indica o efeito na própria saída.
2. $S_0(i, i)$ deve possuir valor unitário se a variável estiver sendo controladas por faixas, pois neste caso o controlador está em malha aberta e não deve haver a compensação do efeito de retroalimentação, caso a predição para a referida variável estiver dentro da faixa. Outra exceção a este caso é quando se usam configurações de restrições dinâmicas para as variáveis controladas em faixas caso o *target* esteja dentro da faixa. São exemplos dessas configurações os *Dynamic Middle Equal Concern Errors*, os quais afetarão o plano de movimentos do controlador.
3. Há dois casos particulares para o cálculo de \hat{y}_{pf} :

- a. Caso haja modelos nulos na matriz dinâmica do controlador, \hat{y}_{pf} é obtido por:

$$\hat{y}_{pf}(i, j) = S_0(i, i)\check{u}(j) \quad (3.21)$$

Onde $\check{u}(j)$ é obtido pela Equação 3.19. É necessário um tratamento especial para esse caso, pois o cálculo de \hat{y}_{pf} pela Equação 3.20 resultaria em um valor nulo devido à simulação do canal, inviabilizando análise de contribuição desse canal ao problema de modelagem.

- b. Uma abordagem análoga é válida para a avaliação da influência de uma variável externa no desempenho do controlador:

$$\hat{y}_{pf}(i, N_{MV} + 1) = S_0(i, i)\check{F}_{ex} \quad (3.22)$$

Onde \check{F}_{ex} corresponde à aplicação do tratamento da Equação 3.19 aos dados da variável externa F_{ex} , coletados para o mesmo período das demais variáveis do controlador. Nesse caso, a variável F_{ex} será tratada pelo método como uma entrada adicional do controlador:

$$\check{u}(n_{MV} + 1) = \check{F}_{ex} \quad (3.23)$$

onde n_{MV} é o número variáveis de entrada do controlador

4. Caso a metodologia esteja sendo aplicada na sequência do método proposto por BOTELHO, TRIERWEILER, *et al.* (2015a,b,2016) para identificação das variáveis controladas que estejam afetando o desempenho do controlador, S_0 e e_0 já estarão disponíveis para utilização, requerendo apenas a determinação de \hat{y}_{pf} para aplicação do método.

O método definido para avaliar a correlação entre e_0 com \hat{y}_{pf} é a análise de correlação cruzada, introduzida no Item 3.1.2. A vantagem dessa técnica de análise de correlação para séries temporais com uma possível relação causal é que ela permite comparar uma causa com um efeito defasado no tempo, sendo aplicável a análises que contemplem efeitos das dinâmicas de processo.

Pelo método, os resultados de correlação cruzada máxima obtida para cada canal da matriz são tratados de forma a obter um indicador discrepância de modelo normalizado (*Normalized Model Discrepancy Indicator*, NMDI) para a escala de zero a um para cada variável de saída, de forma que o pior modelo sempre apresente valor igual à unidade. Devido ao nome do indicador, o método proposto será referido como a metodologia NMDI.

O método proposto atende a todas as características desejadas, previamente apresentadas, e se difere do método proposto por BADWE, GUDI e PATWARDHAN (2009) das seguintes maneiras:

- A função de sensibilidade do controlador é aquela que relaciona as saídas aos distúrbios, sendo, portanto, um método independente de setpoints das variáveis controladas;
- O método não utiliza análise de correlação parcial, não requerendo a estimação de modelos para regenerar as entradas do sistema.

A Figura 3.3 apresenta um fluxograma dos passos necessários para aplicação da metodologia NMDI para localizar o modelo mais correlacionado ao erro nominal do controlador para uma dada variável controlada, y_i .

Os próximos parágrafos detalham a execução de cada etapa do fluxograma.

1. Coletar os dados para a aplicação da metodologia

Os requisitos para aplicação da metodologia são:

- a. Coletar dados das variáveis de entrada e saída do controlador para auditoria (valores medidos das variáveis, limites mínimo e máximo de operação de cada variável do controlador, valor alvo no estado estacionário e predições) Recomenda-se procurar períodos de operação de planta relativamente estável, sem distúrbios operacionais significativos, nos quais todas as variáveis tenham operado ligadas por um período superior ao tempo necessário para o sistema atingir o estado estacionário.
- b. Determinar a função de sensibilidade nominal, S_0 , com base em simulação off-line do controlador;
- c. Opcionalmente, se estiver sendo avaliada a influência de uma variável externa (distúrbio não medidos) no desempenho do controlador, coletar dados para essa variável referentes ao mesmo período utilizado para as demais variáveis;

2. Efetuar o tratamento de dados para a análise de correlação

- a. Determinar \hat{y}_{pf} , conforme a Equação 3.20, respeitando as observações aplicáveis;
- b. Calcular a matriz de erro nominal do controlador, e_0 , para todas as variáveis controladas (Equação 2.14);
- c. Determinar o número limite de intervalos de atrasos, Λ , a ser utilizado na análise de correlação cruzada, com base na inspeção dos modelos da matriz dinâmica do controlador. Esse valor evita que a análise de correlação cruzada percorra toda a dimensão da série temporal, tornando o processo de cálculo mais lento do que o necessário. O valor deve ser compatível com o tempo para estado estacionário dos modelos, de forma a garantir que a análise de correlação considere o efeito da variável de entrada na variável de saída.

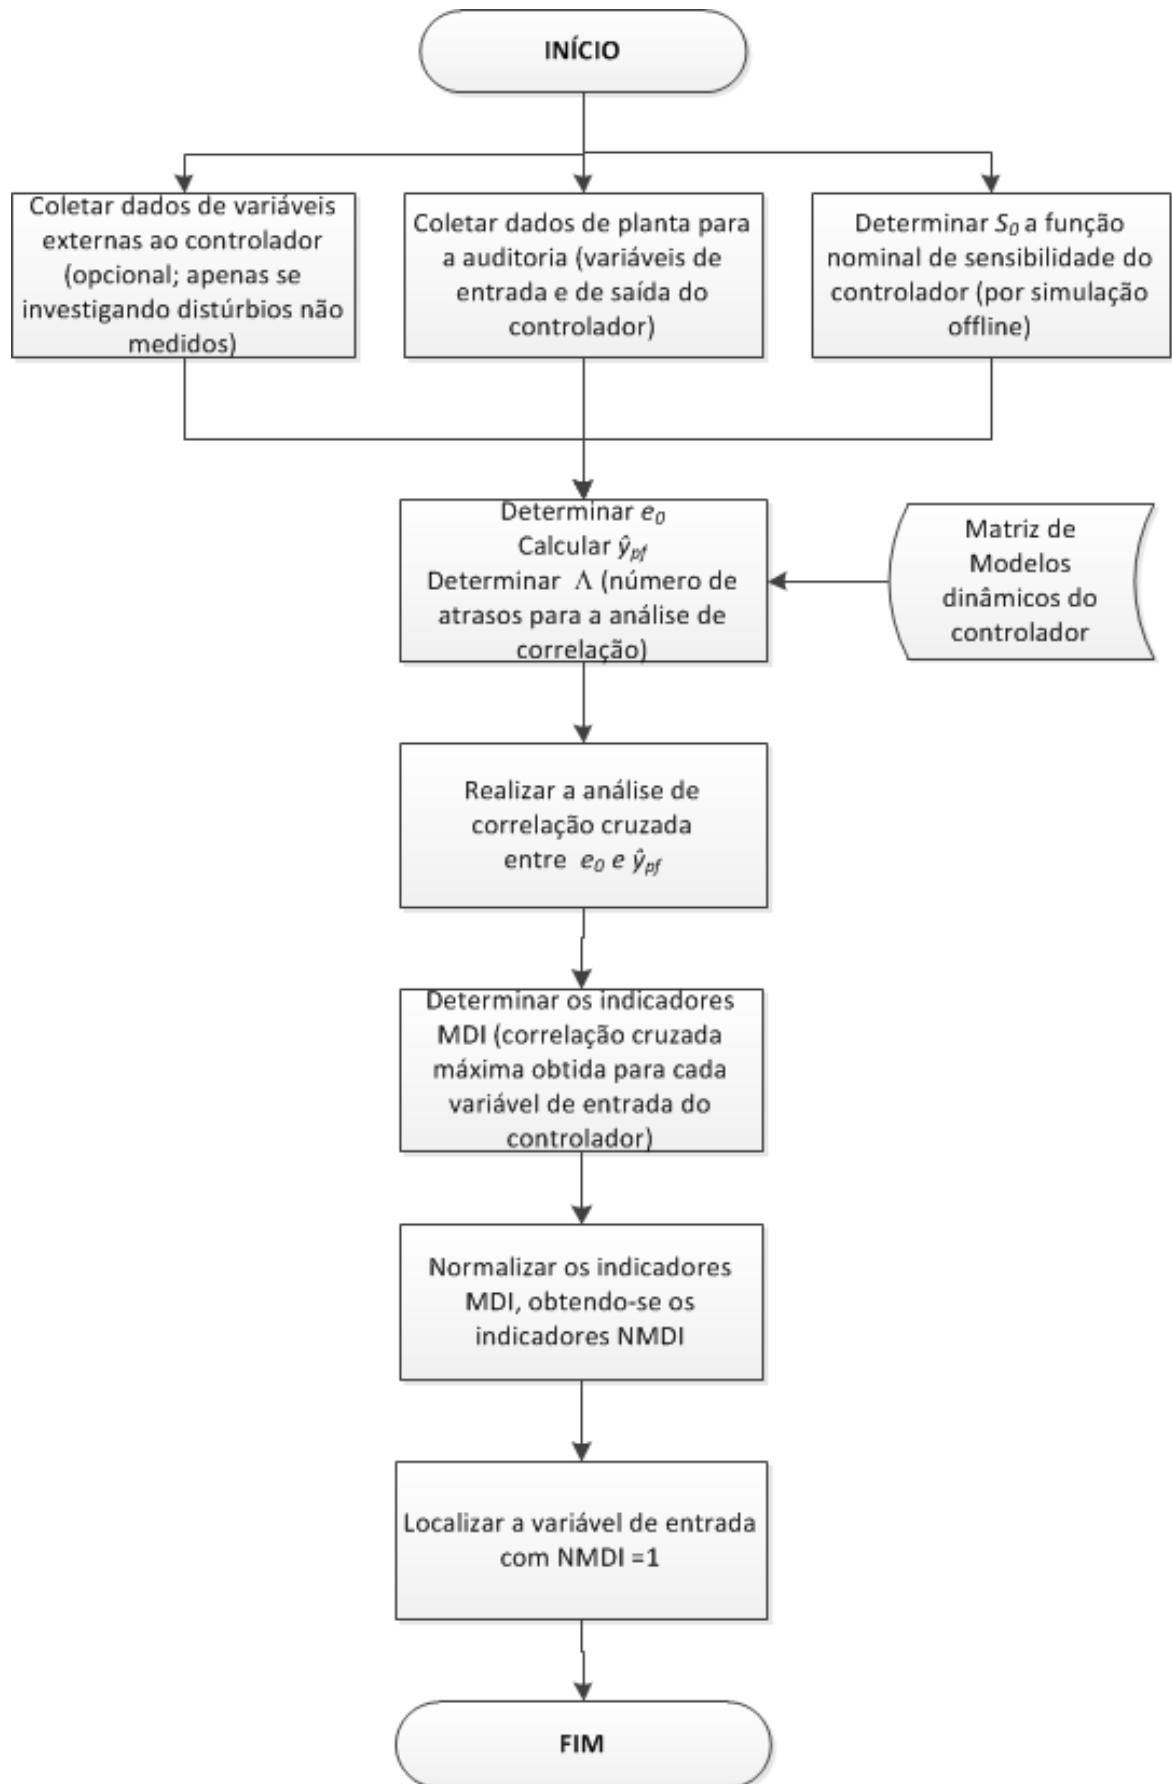


Figura 3.3: Fluxograma para aplicação da metodologia NMDI.

3. Efetuar a análise de correlação cruzada

Para cada variável controlada a ser avaliada (y_i), estimar o coeficiente de correlação cruzada, XCF, para intervalos de defasagem de interesse variando de 0 a Λ :

$$XCF_{\hat{y}_{pf}(i,j),e_0(i)}(\lambda) = \frac{c_{\hat{y}_{pf}(i,j),e_0(i)}(\lambda)}{S_{\hat{y}_{pf}(i,j)}S_{e_0(i)}}; \lambda = 0,1,2,\dots,\Lambda \quad (3.24)$$

A Equação 3.24 é uma aplicação direta da Equação 3.9, na qual as estimativas da covariância e desvio padrão das amostras são obtidas pela aplicação das Equações 3.10 a 3.12.

Neste trabalho, utilizou-se diretamente a função *crosscorr* do MATLAB™ (MATHWORKS, 2016a), para obtenção da estimativa de correlação cruzada entre amostras de séries temporais. Esta função faz parte do pacote *Econometrics Toolbox*™ do MATLAB™, o qual contém diversas ferramentas para modelagem e análise de séries temporais.

O MATLAB™ possui outra função, a *xcorr* (MATHWORKS, 2016b), que calcula a correlação cruzada de duas sequências de dados discretos. O diferencial da função *crosscorr* para a aplicação específica deste trabalho é que ela já realiza internamente o tratamento de dados para ajustar as séries temporais à média zero antes de realizar a análise de correlação cruzada (MATHWORKS, 2012). Caso a função *xcorr* fosse utilizada, o tratamento dos dados para ajuste das séries temporais à média zero deve ser feito pelo usuário. A sintaxe para utilização da função *crosscorr* é

$$[XCF, lags] = crosscorr(série_1, série_2, \Lambda, numSTD) \quad (3.25)$$

onde *XCF* e *lags* correspondem, respectivamente, aos vetores de resultados dos coeficientes de correlação e dos intervalos considerados na análise. Os vetores *série₁* e *série₂* são as amostras de séries temporais para as quais será realizada a análise de correlação; Λ é o número limite de intervalos de amostragem a ser considerado na análise e *numSTD* é número de desvios-padrão a serem considerados na estimativa de erro da correlação cruzada. O valor padrão para *numSTD* é 2, o qual corresponde a um intervalo de confiança de aproximadamente 95%.

Observações:

1. As funções de correlação cruzada normalmente consideram os intervalos de defasagem λ variando entre $-\Lambda$ a Λ para defasagem de uma série temporal em relação à outra. Para a aplicação específica deste trabalho, há interesse apenas quando a defasagem é tal que a série temporal de saída, correspondente à variável controlada, esteja atrasada em relação à variável de entrada. Por exemplo, no caso da função *crosscorr*, interessam os intervalos positivos quando a chamada da função é:

$$[XCF, lags, bounds] = \text{crosscorr}(\hat{y}_{pf}, e_0, \Lambda, numSTD) \quad (3.26)$$

2. Considerando os propósitos da análise de correlação aplicada ao presente trabalho, a correlação cruzada obtida deve ser anulada nos seguintes casos:

- a) Para os valores de intervalos λ em que a variável de entrada esteja atrasada em relação à variável de saída (conforme explicado na Observação 1).
- b) Caso o coeficiente de correlação obtido não seja significativamente diferente de zero, conforme resultado do teste de hipótese definido pela Equação 3.15.

4. Obter a matriz de indicadores de discrepância de modelo, MDI

O Indicador de Discrepância Modelo (*Model Discrepancy Indicator*, ou MDI) é definido para cada par $(y_i - u_j)$ como o valor máximo do módulo da correlação encontrado para todos os intervalos de defasagem λ utilizados na análise de correlação cruzada:

$$MDI_{i,j} = \text{máximo} \left(\left| XCF_{\hat{y}_{pf}(i,j), e_0(i)}(\lambda) \right| \right) \quad (3.27)$$

onde i e j são os índices correspondentes às variáveis de entrada u_j e y_i . Considera-se que já tenham sido feitos os ajustes para anular os resultados de correlação cruzada, quando aplicável, conforme a observação 2 do item 3.

A Tabela 3.1 apresenta um exemplo de uma matriz de indicadores MDI. Considerando que o método seja aplicado a todas as variáveis controladas de um controlador com quatro variáveis de entrada e cinco variáveis de saída, MDI será uma matriz com cinco linhas (correspondentes às variáveis de saída) e quatro colunas (correspondentes às variáveis de entrada), sendo que cada célula contém a correlação cruzada máxima obtida para o par $(y_i - u_j)$.

Tabela 3.1: Exemplo de resultados de indicadores de discrepância de modelo, MDI, obtidos para um controlador MPC hipotético com quatro variáveis de entrada (u_1 a u_4), para o qual o método NMDI foi aplicado para as cinco variáveis controladas (y_1 a y_4).

	u_1	u_2	u_3	u_4
y_1	0,79	0,80	0,78	0,76
y_2	0,60	0,30	0,10	0,20
y_3	0,30	0,25	0,45	0,90
y_4	0,21	0,80	0,25	0,40
y_5	0,87	0,81	0,30	0,67

Na Tabela 3.1, os valores de cada linha correspondem ao indicador MDI obtido os pares de variáveis $(y_i - u_j)$. Tomando a primeira linha como exemplo, observa-se, para uma mesma variável controlada, y_1 , os indicadores MDI podem ser bastante próximos entre si, dificultando a visualização do canal com a correlação mais relevante. Para facilitar a interpretação dos resultados, propõe-se a normalização do indicador MDI para o intervalo $[0,1]$, de forma que a correlação mais

relevante apresentará valor unitário e a menor correlação será descartada, passando a apresentar valor zero.

5. Calcular os Indicadores de Discrepância de Modelo Normalizados (NMDI)

A última etapa da aplicação da metodologia é efetuar a mudança de escala dos indicadores MDI obtidos para cada variável controlada para o intervalo $[0,1]$, obtendo-se como indicador final do método o Indicador Normalizado de Discrepância de Modelo, NMDI:

$$NMDI_{i,j}|_i = \frac{MDI_{i,j}|_i - \text{mínimo}(MDI_{i,j}|_i)}{\text{máximo}(MDI_{i,j}|_i) - \text{mínimo}(MDI_{i,j}|_i)}, \quad (3.28)$$

onde $\text{máximo}(MDI_{i,j}|_i)$ e $\text{mínimo}(MDI_{i,j}|_i)$ correspondem respectivamente, aos valores máximo e mínimo de correlação obtidos para uma mesma variável controlada y_i .

6. Localizar a variável de entrada com NMDI unitário

Com a mudança de escala efetuada, a variável de entrada do controlador mais relacionada ao erro terá sempre $NMDI_{i,j}$ igual a um, facilitando a localização do par $(y_i - u_j)$ cujo modelo deva ser melhorado.

A Tabela 3.2 apresenta os resultados dos indicadores NMDI correspondentes ao exemplo apresentado na Tabela 3.1. A análise dos resultados deve ser feita para cada variável de saída, ou seja, ao longo das linhas da tabela. O valor do indicador NMDI fornece uma priorização relativa de cada canal em relação ao erro de modelagem para a variável de saída no período da auditoria, e_0 . O pior modelo corresponde ao canal com valor de NMDI unitário. Os valores de NMDI decrescem conforme diminua a participação de cada canal no erro de modelagem, chegando a zero para o canal menos correlacionado ao problema de modelagem detectado.

Tabela 3.2: Resultados dos Indicadores NMDI correspondentes aos exemplos fornecidos na Tabela 3.1

	u_1	u_2	u_3	u_4
y_1	0,75	1,00	0,50	0,00
y_2	1,00	0,40	0,00	0,20
y_3	0,08	0,00	0,31	1,00
y_4	0,00	1,00	0,07	0,32
y_5	1,00	0,89	0,00	0,65

Devido à interação entre as variáveis do controlador, propõe-se que sua correção seja feita por etapas, em um processo iterativo. Em cada etapa:

1. Identificam-se os modelos referentes aos canais com valor unitário de NMDI;
2. Identifica-se a função de sensibilidade do controlador com a matriz de modelos atualizada;

3. Realiza-se a avaliação de qualidade de modelos e quantificação do impacto das discrepâncias de modelo no controlador utilizando a metodologia proposta por Botelho *et al.* (2015a,b,2016);
4. Para as variáveis com discrepâncias de modelo que estejam afetando o desempenho do controlador, executa-se novamente a metodologia NMDI;

O processo iterativo é interrompido quando a quantificação do impacto das discrepâncias de modelo no desempenho do controlador estiver aceitável.

4. ESTUDO DE CASO: O SISTEMA DE QUATRO TANQUES

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

4.1 DESCRIÇÃO DO PROCESSO

O sistema de quatro tanques proposto por JOHANSSON (2000) é constituído por quatro tanques cilíndricos conectados de acordo com a Figura 4.1. A água é bombeada a partir do reservatório para os tanques por meio das bombas 1 e 2. A energia consumida em cada bomba é medida através das tensões V_1 e V_2 . A variável x_1 corresponde à fração da vazão de água bombeada pela Bomba 1 que é enviada ao Tanque 1, enquanto $(1-x_1)$ corresponde à fração da vazão de água oriunda da mesma bomba que é enviada ao Tanque 4. Analogamente, x_2 indica a fração da vazão de água bombeada pela Bomba 2 que é enviada ao Tanque 2, enquanto $(1-x_2)$ corresponde à vazão de água proveniente desta bomba que é enviada ao Tanque 3.

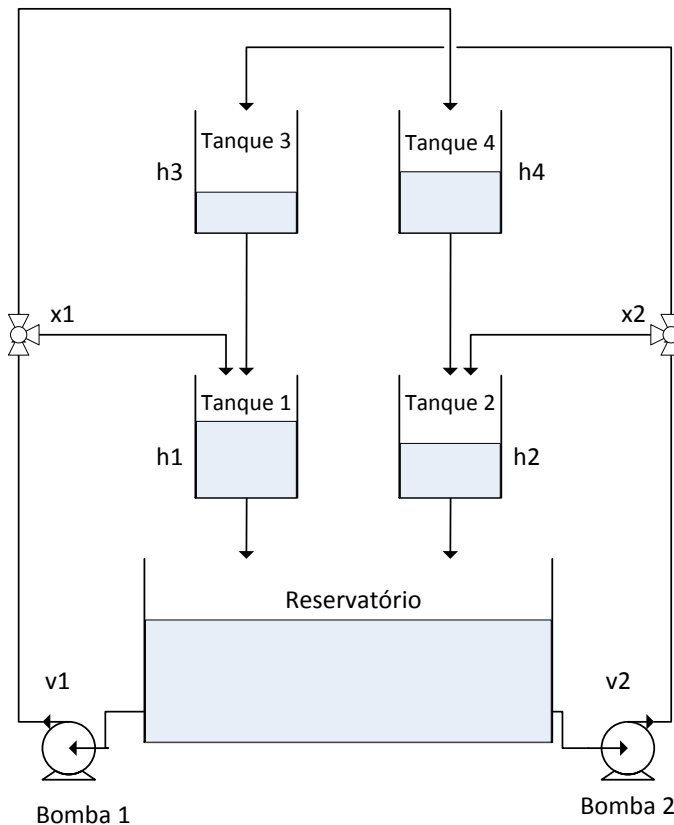


Figura 4.1: Esquema do sistema de quatro tanques. Adaptado de JOHANSSON (2000).

As equações (4.1) a (4.4) correspondem ao balanço de massa em torno de cada tanque. A Tabela 4.1 apresenta os parâmetros relativos à configuração do sistema. As variáveis do processo a ser controlado são os níveis de água dos quatro tanques.

$$\frac{dh_1}{dt} = -\frac{a_1}{A_1}\sqrt{2gh_1} + \frac{a_3}{A_1}\sqrt{2gh_3} + \frac{x_1 k_{f1}}{A_1}v_1 \quad (4.1)$$

$$\frac{dh_2}{dt} = -\frac{a_2}{A_2}\sqrt{2gh_2} + \frac{a_4}{A_2}\sqrt{2gh_4} + \frac{x_2 k_{f2}}{A_2}v_2 \quad (4.2)$$

$$\frac{dh_3}{dt} = -\frac{a_3}{A_3}\sqrt{2gh_3} + \frac{(1-x_2)k_{f2}}{A_3}v_2 \quad (4.3)$$

$$\frac{dh_4}{dt} = -\frac{a_4}{A_4}\sqrt{2gh_4} + \frac{(1-x_1)k_{f1}}{A_4}v_1 \quad (4.4)$$

Tabela 4.1: Parâmetros do processo do sistema de quatro tanques (JOHANSSON, 2000)

Descrição do Parâmetro	Unidade	Valores
Área transversal dos tanques	cm ²	$A = [28 \ 32 \ 28 \ 32]$
Área transversal do bocal de saída do tanque	cm ²	$a = [0.071 \ 0.057 \ 0.071 \ 0.057]$
Aceleração da gravidade	cm/s ²	$g = 981$
Constante de vazão	cm ³ /V.s	$k_f = [3.14 \ 3.29]$

Um controlador preditivo baseado em modelos foi projetado para esse sistema, com o propósito de controlar o nível de água dos quatro tanques através da manipulação da voltagem das bombas e da fração desviada. Os modelos usados no controlador foram obtidos através de linearização do modelo fenomenológico (Equações 4.1 a 4.4). O ponto de operação selecionado, apresentado na Tabela 4.2, corresponde a um ponto de operação de fase não-mínima, conforme trabalho original publicado por JOHANSSON (2000).

Tabela 4.2: Variáveis do controlador e ponto de operação para linearização do sistema.

Tipo de variáveis	Variáveis	Unidade de Engenharia	Ponto operacional utilizado na linearização
Controladas	$y = [h_1 \ h_2 \ h_3 \ h_4]$	[cm cm cm cm]	$y^0 = [12.6 \ 13 \ 4.8 \ 4.9]$
Manipuladas	$u = [v_1 \ v_2 \ x_1 \ x_2]$	[V/cm V/cm - -]	$u^0 = [3.15 \ 3.15 \ 0.43 \ 0.34]$

Aplicando-se os valores dos parâmetros, obtém-se a função de transferência resultante para o sistema nominal, G_0 :

$$G_0(s) = \begin{bmatrix} \frac{0.0482}{s+0.01582} & \frac{0.001988}{s^2+0.04145s+0.0004055} & \frac{0.3533}{s+0.01582} & \frac{-0.009487}{s^2+0.4145s+0.0004055} \\ \frac{0.0009968}{s^2+0.02876s+0.000195} & \frac{0.03496}{s+0.01094} & \frac{-0.005509}{s^2+0.04145s+0.0004055} & \frac{0.3239}{s+0.01094} \\ 0 & \frac{0.07755}{s+0.02563} & 0 & \frac{-0.3701}{s+0.02563} \\ \frac{0.05593}{s+0.01782} & 0 & \frac{-0.3091}{s+0.01782} & 0 \end{bmatrix} \quad (4.5)$$

4.2 DESCRIÇÃO DO CONTROLADOR MPC

Um controlador MPC para controle do sistema de quatro tanques foi implementado no MATLABTM para controlar os níveis do tanque por faixas, o que significa que o controle atua nas variáveis manipuladas apenas para evitar violação das faixas (limites de operação), como é usual para muitas aplicações industriais. Esse controlador possui uma camada de otimização para calcular os valores ótimos (metas) para as variáveis em estado estacionário (*targets*), respeitando restrições definidas.

A Tabela 4.3 mostra os valores de parametrização do controlador MPC, A sintonia do controlador (configuração da supressão de movimentos, taxa de variação das variáveis manipuladas e pesos das variáveis de saída) foi executada através da ferramenta *Tuning Advisor* do MATLABTM, buscando um controle suave, com resposta rápida a uma variação de setpoint, porém evitando sobre-elevação.

As configurações do otimizador consistiram no peso das restrições flexíveis, custo das MVs e variação máxima para cada variável controlada. Os valores desses parâmetros foram definidos por tentativa e erro, a fim de manter os níveis de tanques otimizados em seu limite superior. Esta configuração permitiu perturbar o sistema através da alteração do limite superior das variáveis controladas nos cenários de estudo.

O cálculo das metas (*targets*) para as variáveis do otimizador é efetuado através de um algoritmo de programação quadrática (QP), implementado através da função *quadprog* do MATLABTM (MATHWORKS, 2016c) que minimiza a função objetivo:

$$J = \min_x \frac{1}{2} x^T M x + f^T x \quad (4.6)$$

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 (disponíveis na Tabela 4.3).

A resolução do problema de otimização está sujeita a restrições de desigualdade configuradas, as quais correspondem às restrições rígidas das variáveis controladas que por sua

vez visam respeitar os limites no estado estacionário sendo esses limites implementados como sendo o tamanho máximo de variação permitida da variável até o estado estacionário.

Tabela 4.3: Parâmetros de sintonia do controlador e do otimizador

Parâmetro	Valor
Tempo de amostragem (T_s), [segundos]	10
Horizonte de predição (p)	48
Horizonte de controle (m)	12
Vetor de supressão de movimentos	[5 5 5 5]
Pesos das variáveis de saída	[0.1 0.1 0.1 0.1]
Pesos dos targets	[0.1 0.1 0.1 0.1]
Peso das restrições flexíveis	2500
Custo das MVs	[-350 -350 200 200]
Varição máxima para cada CV	[2.5 2.5 0.25 0.25]

A função nominal de sensibilidade, S_0 , foi obtida pela simulação do controlador adicionando-se um distúrbio na carga e mantendo os limites superiores e inferiores das variáveis manipuladas e controladas fixos. Tomou-se cuidado para evitar saturação de variáveis durante os testes para não afetar a identificação da função de sensibilidade pela redução de graus de liberdade. A Figura 4.2 apresenta as respostas da função de sensibilidade nominal à função degrau.




Figura 4.2: Resposta da função de sensibilidade de saída nominal, S_0 , à função degrau.

4.3 RESULTADOS E DISCUSSÃO DOS CENÁRIOS

Nesta seção são apresentados e discutidos três cenários estudados para explorar as capacidades e limitações da metodologia proposta.

4.3.1 Roteiro de análise

A auditoria de desempenho do controlador realizada no estudo de caso integra as metodologias propostas por BOTELHO, TRIERWEILER, *et al.* (2015a,b,2016) para identificação das variáveis controladas com incertezas de modelo afetando o desempenho do controlador com a metodologia NMDI proposta neste trabalho para localizar os modelos que precisem ser melhorados. A Figura 4.3 resume o processo de análise a ser utilizado no estudo de cada cenário.

Os resultados obtidos serão comparados com o método proposto por BADWE, GUDI e PATWARDHAN (2009), selecionado como método de referência. Este método foi escolhido para comparação por possuir, conforme apresentado no Capítulo 2, uma abordagem interessante para encontrar modelos de controladores MPC com discrepâncias relevantes em relação à dinâmica da planta, além de ser compatível com a maioria das características desejadas para o método ideal.

No entanto, ele apresenta duas desvantagens. Uma delas é que a coleta de dados para auditoria deve contemplar um período com variação de *setpoints* para todas as variáveis manipuladas. A outra está relacionada ao cálculo das correlações parciais dinâmicas, as quais requerem ajuste de modelos baseados no erro de saída para obter as entradas do sistema. Conforme CARLSSON (2010), a seleção de parâmetros a serem utilizados nas correlações parciais dinâmicas resulta em um método difícil de automatizar, tornando sua implementação computacionalmente intensiva.

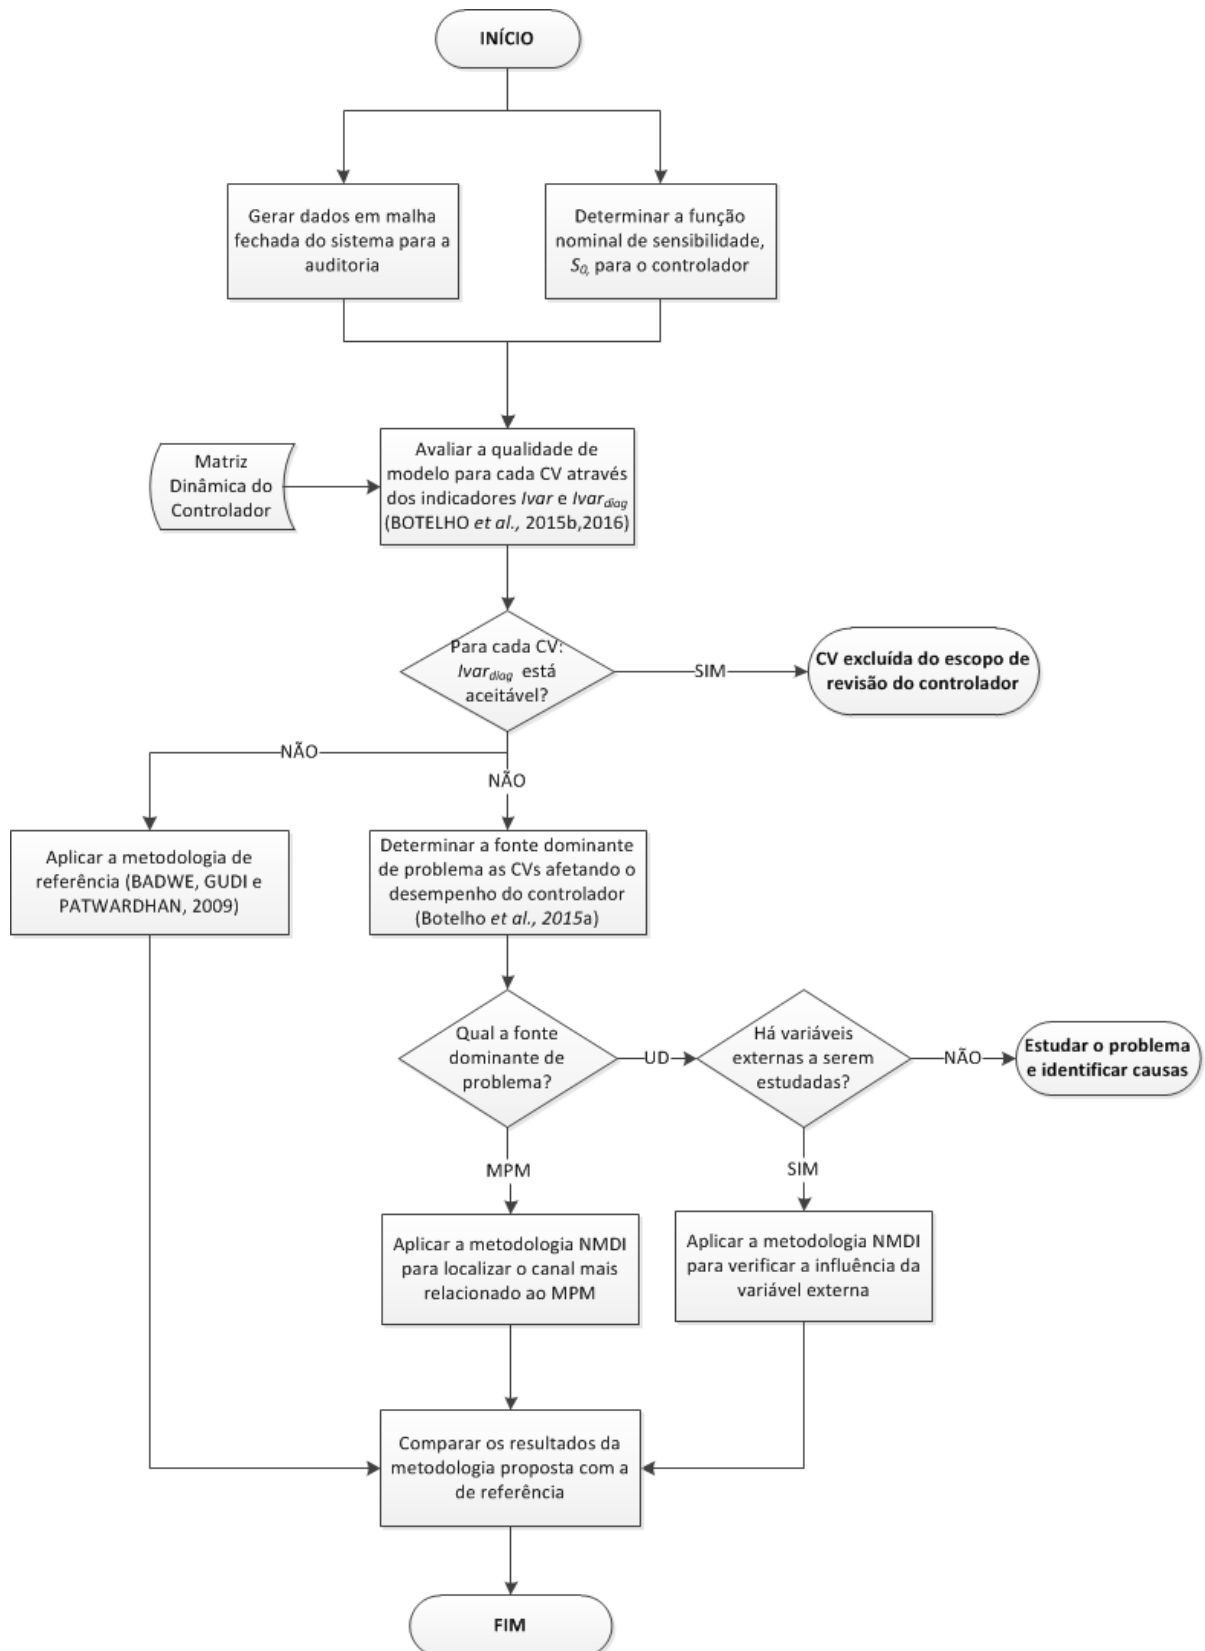


Figura 4.3: Processo de análise utilizado na auditoria de controladores para o estudo de caso do Sistema de Quatro Tanques.

4.3.2 Premissas

O potencial e as limitações do método serão explorados através do estudo de três cenários, para as quais as seguintes considerações são válidas:

- Os estudos de todos os cenários foram realizados com base em uma simulação do processo com duração de 15000 s. Utilizaram-se 1362 amostras por variável em cada caso com um período de amostragem das variáveis, $T_s = 10$ s,
- As discrepâncias entre modelo e planta foram introduzidas no modelo da planta, permitindo utilizar a mesma função de sensibilidade nominal do controlador em mais de um cenário
- Na avaliação de qualidade de modelos, a avaliação do indicador *Ivar*, para determinar se a variância da saída medida é diferente da saída nominal do controlador em malha fechada foi realizada através de um teste de hipóteses para homogeneidade de variâncias. Conforme BELFIORE (2015), a hipótese nula dos testes de homogeneidade de variância afirma que as variâncias das n_p populações são homogêneas, enquanto a hipótese alternativa afirma que pelo menos uma variância populacional é diferente das demais:

$$H_0: \sigma_1^2 = \sigma_2^2 = \dots = \sigma_{n_p}^2 \quad (4.7)$$

$$H_1: \exists i, j: \sigma_i^2 \neq \sigma_j^2 \quad (i, j = 1, \dots, n_p) \quad (4.8)$$

- O teste de homogeneidade de variâncias selecionado foi o Teste F de Levene, pois este, de acordo com BELFIORE (2015), é considerado mais robusto e menos sensível a desvios de normalidade que os demais testes existentes. A estatística do teste de Levene segue aproximadamente uma distribuição F com $\nu_1 = n_p - 1$ e $\nu_2 = N_k - n_p$ graus de liberdade para um nível de significância α :

$$F_{cal} = \frac{(N_k - n_p)}{(n_p - 1)} \cdot \frac{\sum_{i=1}^{n_p} K_i (\bar{\xi}_i - \bar{\xi})^2}{\sum_{i=1}^{n_p} \sum_{j=1}^{K_i} (\xi_{ij} - \bar{\xi}_i)^2} \sim F_{n_p - 1, N_k - n_p, \alpha} \quad (4.9)$$

onde: K_i é a dimensão de cada uma das n_p amostras ($i = 1, 2, \dots, n_p$); N_k é a dimensão da amostra global ($N_k = K_1 + K_2 + \dots + K_{n_p}$); $\xi_{ij} = |Z_{ij} - \bar{Z}_i|$, $i = 1, \dots, n_p$ e $j = 1, \dots, K_i$; Z_{ij} é a observação j na amostra i ; \bar{Z}_i é a média da amostra i ; $\bar{\xi}_i$ é a média de ξ_{ij} na amostra i e $\bar{\xi}$ é a média de ξ_i na amostra global.

Rejeita-se H_0 quando o *p-value* (probabilidade associada à estatística F_{cal}) for inferior ao limite de significância, α , conforme a tabela da Distribuição F de Fisher-Snedecor. Para a aplicação deste estudo, $n_p = 2$, resultando em $\nu_1 = n_p - 1 = 1$ e $\nu_2 = N_k - n_p = 2K_i - 2$.

- No MATLABTM, o valor de *p-value* referente ao teste F de Levene para homogeneidade de variância das amostras amostras y_1 e y_2 é obtido pelo seguinte comando:

$$[pval] = \text{vartestn}([y1 \ y2], 'TestType', 'LeveneAbsolute') \quad (4.10)$$

- A implementação do método proposto para comparação dos resultados (BADWE, GUDI e PATWARDHAN, 2009) seguiu as Equações 2.5 a 2.9. A a estrutura de modelo utilizada na etapa de descorrelação de variáveis foi a de erro na saída (*Output Error*, ou *OE*), representada pelas equações 4.11 a 4.14, conforme LJUNG (1999):

$$y(t) = \frac{B(q)}{F(q)} u(t - n_k) + e(t) \quad (4.11)$$

onde $y(t)$ é a variável de saída do modelo, $u(t)$ é variável de entrada, $e(t)$ é o erro, $B(q)$ e $F(q)$ são os polinômios do modelo, n_k é o atraso e q é o operador de avanço, definido por

$$qu(t) = u(t + 1) \quad (4.12)$$

As ordens do modelo de erro na saída são dadas por:

$$B(q) = b_1 + b_2 q^{-1} + \dots + b_{nb}^{-nb+1} \quad (4.13)$$

$$F(q) = 1 + f_1 q^{-1} + \dots + f_{nf}^{-nf} \quad (4.14)$$

As ordens dos polinômios B e F iguais foram ajustadas em cada cenário. O atraso n_k foi considerado igual a um intervalo de amostragem, visto que o sistema não possui atrasos significativos. O erro de predição foi estimado pela aproximação:

$$\hat{y}(k + 1) = y(k) + y_{sim}(k + 1) - y_{sim}(k) \quad (4.15)$$

4.3.3 Cenário 1: Detecção de discrepância entre modelo e planta em um controlador MPC MIMO (*Multiple Input, Multiple Output*)

A Figura 4.4 apresenta os gráficos de tendência das variáveis do controlador durante a simulação do caso nominal, que é o caso de referência de desempenho do controlador para todos os casos de estudo. As variáveis controladas (níveis de tanques) são apresentadas na linha superior, enquanto as variáveis manipuladas são apresentadas na fileira inferior.




Figura 4.4: Simulação de processo do caso nominal do controlador, considerando a dinâmica da planta igual aos modelos do controlador. As variáveis medidas estão plotadas em azul, os limites de controle em linhas vermelhas tracejadas e as metas de controle calculadas pelo otimizador, em verde.

Durante a simulação, o limite superior das variáveis controladas foi variado para perturbar o sistema (já que o controlador tenderá a levar as variáveis ao seu limite máximo, conforme sintonia efetuada). O limite inferior de operação das variáveis foi mantido fixo durante todo o período. Como não há discrepâncias entre modelo e planta no caso nominal, o indicador *Ivar* tem o valor de um para todas as variáveis.

O primeiro caso estudado é a avaliação do desempenho para a detecção de discrepâncias entre modelo e planta em um controlador preditivo baseado em modelos de estrutura MIMO (*Multiple Input, Multiple Output*), cuja matriz de controle contém todos os canais do modelo linearizado da planta. Para este caso, três tipos de discrepâncias foram introduzidos no modelo da planta, conforme a Tabela 4.4. Para todos os outros canais da matriz dinâmica, os modelos foram mantidos idênticos ao caso nominal.

Tabela 4.4: Discrepâncias entre modelo e planta introduzidas para o Cenário 1

Par (CV – MV)	Modelo do Controlador (G)	Dinâmica da Planta (G_p)
$(h_2 - v_1)$	$G_0(2,1)$	$G_0(2,1) * (-2)$
$(h_3 - x_2)$	$G_0(3,4)$	$G_0(3,4) * \frac{1}{400s + 1}$
$(h_4 - x_1)$	$G_0(4,3)$	$G_0(4,3) * \frac{1}{100s + 1}$

As discrepâncias foram introduzidas simultaneamente nos três canais para verificar a capacidade do método de isolar o que estava acontecendo com cada variável controlada, independentemente do estado global do controlador. Acredita-se que esta abordagem seja mais próxima de uma aplicação real do que avaliar a capacidade de detecção do método frente a uma única discrepância por vez.

A Figura 4.5 apresenta a simulação do controlador para este cenário. Comparando-se as Figuras 4.4 e 4.5, observa-se um comportamento bastante oscilatório em todas as variáveis, e grande dificuldade de respeitar os limites máximos, principalmente para as variáveis h_1 e h_2 .

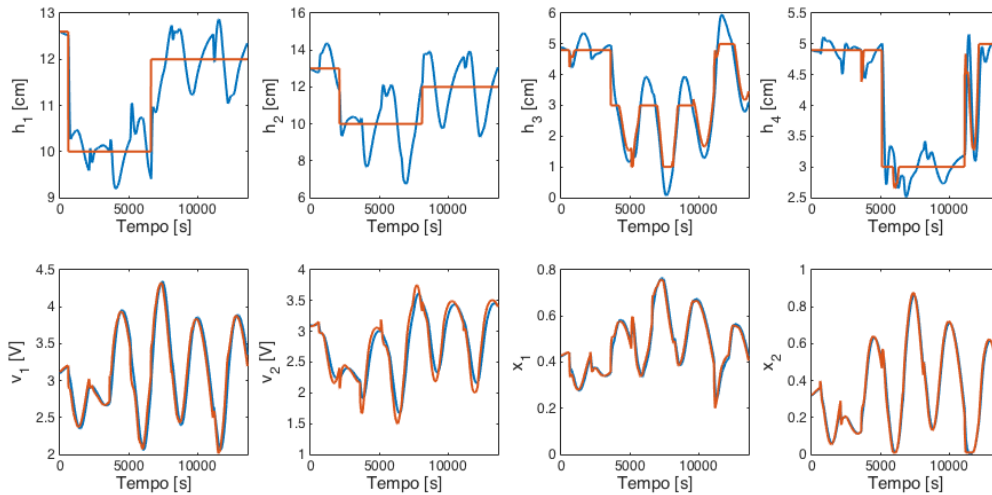


Figura 4.5: Simulação do Cenário 1. Variáveis medidas exibidas em azul e as metas otimizadas do controlador em laranja.

A Figura 4.6 mostra os resultados da avaliação dos modelos do controlador. A linha vermelha corresponde ao valor unitário para os indicadores $Ivar$ e $Ivar_{diag}$, correspondente a homogeneidade ou igualdade entre as variâncias de y e y_o . As variáveis que sugerem maiores um aumento significativo da variância de y em relação à de y_o , para as variáveis h_2 e h_3 . Esta percepção deve ser confirmada pelo teste de hipótese de homogeneidade ou igualdade de variâncias.




Figura 4.6: Avaliação da qualidade dos modelos para o Cenário 1.

A Tabela 4.5 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 igualdade de variâncias) para valores de probabilidade *p-value* inferiores a 0,05.

Tabela 4.5: Resultados do teste F de Levene para igualdade de variâncias para o Cenário 1.

<i>Variável</i>	<i>Ivar</i>	<i>p-value</i>	<i>Ivar_{diag}</i>	<i>p-value</i>
h_1	1,1253	0,0287	0,9987	0,9787
h_2	2,6686	0	2,4947	0
h_3	1,4289	0	1,4082	0
h_4	1,0531	0,0228	0,9949	0,6265

A análise da Tabela 4.5 mostra que os valores de *p-value* para o indicador *Ivar* encontram-se abaixo de 0,05 para todas as variáveis, indicando que a hipótese de igualdade de variâncias deve ser rejeitada, ou seja, $Ivar \neq 1$. Além disso, como o valor do indicador é superior a uma unidade, conclui-se que todas as variáveis estão afetando o desempenho do controlador, pois possuem variância significativamente maior do que as saídas nominais do controlador em malha fechada.

Em relação ao indicador *Ivar_{diag}*, observa-se que os valores de *p-value* para as variáveis h_1 (para a qual não houve inserção de MPM) e h_4 estão acima de 0,05. Nesse caso, aceita-se a hipótese de igualdade de variâncias ($Ivar_{diag} = 1$) e conclui-se que o problema observado nessas variáveis não está ligado aos seus modelos, sendo provavelmente resultado de interação entre as variáveis. Para as variáveis h_2 e h_3 , os valores de *p-value* confirmam que $Ivar_{diag} \neq 1$, indicando que essas variáveis também estão sendo afetadas por suas próprias incertezas de modelos e, portanto devem ser estudadas. O resultado da análise é que as variáveis controladas que precisam ser estudadas são as variáveis h_2 e h_3 .

A Figura 4.7 apresenta os resultados da segunda etapa da auditoria para as variáveis h_2 e h_3 . Conforme esperado, os indicadores de correlação médios, calculados através da Equação 2.21, superaram limite definido pelo intervalo de confiança da correlação, obtido pela Equação 2.22 e indicado no gráfico pela linha vermelha. Conclui-se que a fonte principal de incerteza de modelos é MPM para ambas as variáveis.




Figura 4.7: Diagnóstico da causa predominante de discrepância de modelo.

(a) para a variável h_2 ; (b) para a variável h_3 .

A Figura 4.8 mostra o gráfico do indicador NMDI para as variáveis h_2 e h_3 . De acordo com o método proposto, o canal mais relacionado com a discrepância de modelo encontrada é aquele cujo NMDI atinge o valor de 1. Consta-se que o método foi capaz de identificar corretamente os canais em que os MPMs foram introduzidos, formados pelos pares: definidos pelas variáveis $(h_2 - v_1)$ e $(h_3 - x_2)$.




Figura 4.8: Localização da MV mais relacionada à discrepância de modelo.

(a) para a variável h_2 ; (b) para a variável h_3 .

A Figura 4.9 mostra os resultados da aplicação da metodologia proposta por BADWE, GUDI e PATWARDHAN (2009) para as variáveis h_2 e h_3 . O método apresentou corretamente as maiores correlações parciais para os pares $(h_2 - v_1)$ e $(h_3 - x_2)$. ao se empregar as seguintes ordens de polinômios na etapa de decorrelação das variáveis: $n_b = n_f = 4$ para a variável h_2 e $n_b = 5; n_f = 3$ para a variável h_3 .




Figura 4.9: Resultados da análise de correlação parcial entre o erro de predição e as variáveis de entrada do controlador (BADWE, GUDI e PATWARDHAN, 2009): (a) Para a variável h_2 ; (b) Para a variável h_3 .

Comparando-se as Figuras 4.8 e 4.9, nota-se, para a variável h_2 , que embora ambos os métodos tenham corretamente identificado o canal mais correlacionado ao problema, eles diferem bastante em relação à correlação obtida para as demais variáveis de entrada do controlador. Por exemplo, enquanto o método proposto neste trabalho aponta o par $(h_2 - x_2)$ como aquele menos correlacionado ao problema, pois a correlação foi anulada após a normalização do indicador NMDI, este par foi identificado como o segundo mais relevante pelo método proposto por BADWE, GUDI e PATWARDHAN (2009), com uma diferença bastante pequena em relação par $(h_2 - v_1)$.

Outra observação interessante é que, para ambas as variáveis, as duas correlações parciais mais elevadas apresentam valores muito próximos, dificultando até mesmo identificar visualmente qual a correlação mais elevada. De acordo com LOEFF (2014), o uso de estruturas de modelo de erro na saída (OE) na etapa de descorrelação de variáveis fornece resultados significativos na detecção das discrepâncias, embora não funcione tão bem para quantificá-las, devido à possibilidade de correlação entre as variáveis estimadas e seus resíduos. Por essa razão, considerou-se a correlação mais elevada como predominante, mesmo se estivesse muito próxima do segundo valor mais alto.

A maior dificuldade encontrada na aplicação do método proposto por BADWE, GUDI e PATWARDHAN (2009) foi a seleção da ordem dos polinômios na etapa de descorrelação das variáveis.

A Figura 4.10 mostra os resultados obtidos para a variável h_3 utilizando diferentes ordens de polinômios. Os resultados esperados foram obtidos apenas para as ordens utilizadas na Figura 4.10 (d), na qual a maior correlação parcial é obtida para o par $(h_3 - x_2)$.

Este caso mostra que a metodologia NMDI permite localizar os modelos do controlador associados às discrepâncias de ganho e de dinâmica (constante de tempo) que estejam afetando o desempenho do controlador MPC. Considerando a dificuldade explicada para selecionar as ordens de polinômios adequadas para utilização do método proposto por BADWE, GUDI e PATWARDHAN (2009), conclui-se que a metodologia NMDI forneceu melhores resultados por ser menos dependente de decisões tomadas pelo usuário para fornecer resultados satisfatórios.

É interessante destacar que a abordagem de auditoria utilizada para este cenário poderia também ter sido focada na quantificação do impacto da discrepância de modelo no desempenho do controlador, fornecida pela intensidade dos indicadores de variância, $Ivar$. Retomando a Figura 4.6, observa-se, pela comparação entre as intensidades dos indicadores $Ivar$ que o impacto causado por uma inversão de ganho em um canal (caso da variável h_2) é mais significativo que a variação da velocidade da dinâmica da planta, uma vez que esta é mais facilmente atenuada pelo mecanismo de retroalimentação do controlador. Tendo isto em mente, realizou-se primeiramente, a correção apenas do modelo ($h_2 - v_1$).




Figura 4.10: Resultados obtidos para a aplicação do método proposto por BADWE, GUDI e PATWARDHAN (2009) para a variável h_3 . (a) modelos OE ordem 3 ($n_b = n_f = 3$); (b) modelos OE ordem 4 ($n_b = n_f = 4$); (c) modelos OE ordem 5 ($n_b = n_f = 5$); (d) modelos OE ordem $n_b = 5$; $n_f = 3$.

A Figura 4.11 corresponde à simulação do controlador após essa correção. Observa-se uma melhora considerável de desempenho do controlador, reduzindo significativamente os efeitos oscilatórios.




Figura 4.11: Simulação do cenário após correção do modelo referente ao par $(v_1 - h_2)$.

A Figura 4.12 apresenta os resultados da avaliação da qualidade de modelo após essa correção do controlador e a Tabela 4.6 apresenta os resultados do teste F de Levene para igualdade de variâncias.




Figura 4.12: Avaliação da qualidade dos modelos para o Cenário 1 após correção da variável h_2

Tabela 4.6: Resultados do teste F de Levene para igualdade de variâncias após correção da variável h_2 .

<i>Variável</i>	<i>Ivar</i>	<i>p-value</i>	<i>Ivar_{diag}</i>	<i>p-value</i>
h_1	1,0024	0,9936	0,9999	0,9985
h_2	1,0004	0,9817	0,9999	0,9986
h_3	1,1018	0,2773	1,0172	0,2088
h_4	1,0243	0,1796	1,0227	0,1712

Observa-se, da Tabela 4.6, que os valores de *p-value* encontram-se acima de 0,05 para todas as variáveis para ambos os indicadores *Ivar* e *Ivar_{diag}*. Isto indica que a hipótese de igualdade de variâncias deve ser aceita, não havendo discrepâncias de modelo que estejam afetando o desempenho do controle de nenhuma variável. Estes resultados demonstram que a discrepância introduzida no aumento da ordem de modelo para as variáveis h_3 e h_4 são atenuadas pelo efeito de retroalimentação do controlador e não constituem um problema de desempenho.

Assim, conclui-se que o que estava realmente afetando o desempenho do controlador, na análise original, era a inversão de ganho na variável h_2 e seu impacto nas demais variáveis do controlador. Esse exemplo ilustra a importância de realizar a revisão do controlador em etapas, focando primeiramente nas discrepâncias de maior intensidade, que pode contribuir significativamente para redução de escopo da revisão de modelos do controlador.

4.3.4 Cenário 2: Avaliação de variáveis para recuperar o desempenho de um sistema afetado por distúrbios não medidos.

Este cenário demonstra como o método proposto pode ser utilizado para avaliar a influência de uma variável externa no comportamento do controlador no caso de um sistema afetado por distúrbios não medidos.

Propõe-se um cenário correspondente a uma modificação da planta que afete o controle do nível dos tanques, mas que não seja modelada no controlador. Para o caso de estudo, o cenário consiste na inserção de novos equipamentos no sistema (Tanque 5 e Bomba 3), que pode enviar uma vazão adicional ao Tanque 1, *F_{ex1}*, conforme ilustrado na Figura 4.13.

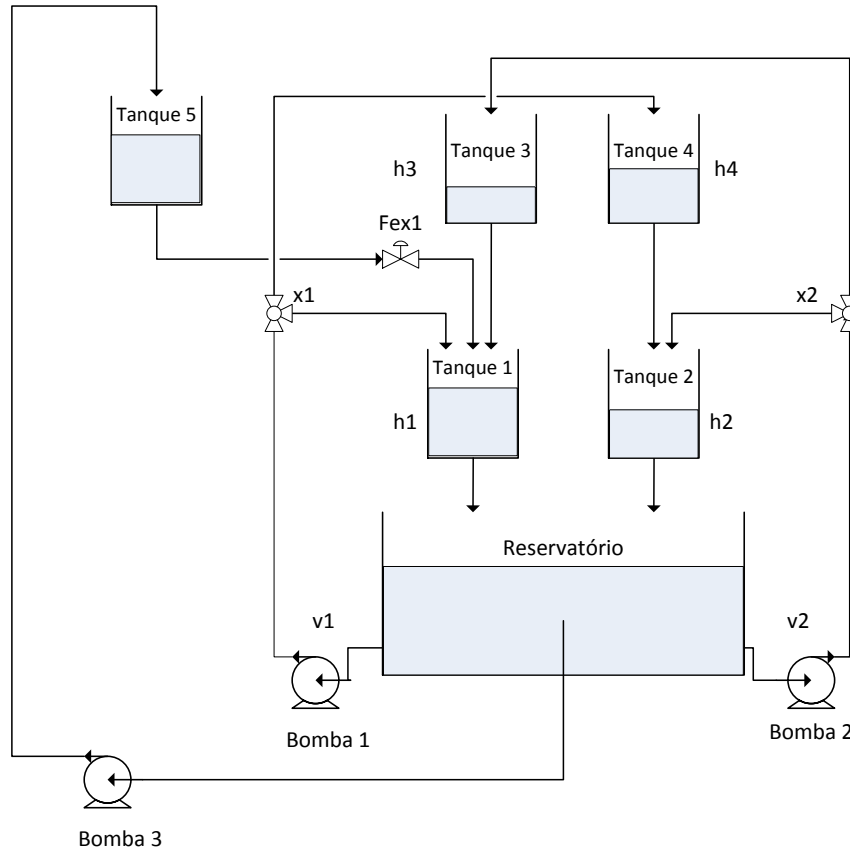


Figura 4.13: Esquema do sistema de quatro tanques com uma vazão adicional ao Tanque 1, F_{ex1} .

O controlador não possui modelo referente ao impacto de F_{ex1} no nível do Tanque 1, de forma que essa vazão afetará o sistema como um distúrbio não medido. Este cenário exemplifica casos industriais em que a planta é modificada por um projeto, após o comissionamento do controlador. Deseja-se verificar se a metodologia pode auxiliar o engenheiro de controle a verificar se a causa de degradação do desempenho do controlador pode ter sido causada pela falta de adequação do controlador para contemplar as modificações da planta. Assim, deseja-se verificar se a auditoria do controlador:

- Detecta que a variável h_1 está sendo afetada por uma fonte de distúrbio não medido que está degradando o desempenho do controlador
- Valida que a variável F_{ex1} está correlacionada ao problema de modelagem identificado.

Para executar o cenário, o modelo da planta, G , foi atualizado para incluir o modelo da variável F_{ex1} , configurada como quinta variável de entrada, com a variável controlada h_1 :

$$G_p(s) = \begin{bmatrix} \frac{0.0482}{s+0.01582} & \frac{0.001988}{s^2+0.04145s+0.0004055} & \frac{0.3533}{s+0.01582} & \frac{-0.009487}{s^2+0.4145s+0.0004055} & \frac{0.03571}{s+0.01582} \\ \frac{0.0009968}{s^2+0.02876s+0.000195} & \frac{0.03496}{s+0.01094} & \frac{-0.005509}{s^2+0.04145s+0.0004055} & \frac{0.3239}{s+0.01094} & 0 \\ 0 & \frac{0.07755}{s+0.02563} & 0 & \frac{-0.3701}{s+0.02563} & 0 \\ \frac{0.05593}{s+0.01782} & 0 & \frac{-0.3091}{s+0.01782} & 0 & 0 \end{bmatrix} \quad (4.16)$$

Para compatibilidade numérica no cálculo com matrizes, a variável Fex_1 também foi incluída como variável de entrada na matriz de controle. Porém, os modelos foram mantidos nulos:

$$G(s) = \begin{bmatrix} \frac{0.0482}{s+0.01582} & \frac{0.001988}{s^2+0.04145s+0.0004055} & \frac{0.3533}{s+0.01582} & \frac{-0.009487}{s^2+0.4145s+0.0004055} & 0 \\ \frac{0.0009968}{s^2+0.02876s+0.000195} & \frac{0.03496}{s+0.01094} & \frac{-0.005509}{s^2+0.04145s+0.0004055} & \frac{0.3239}{s+0.01094} & 0 \\ 0 & \frac{0.07755}{s+0.02563} & 0 & \frac{-0.3701}{s+0.02563} & 0 \\ \frac{0.05593}{s+0.01782} & 0 & \frac{-0.3091}{s+0.01782} & 0 & 0 \end{bmatrix} \quad (4.17)$$

Na simulação para geração de dados de planta, Fex_1 foi configurada pela Equação 4.18, utilizando a função dente de serra (*sawtooth*) do MATLAB (MATHWORKS, 2016d). A Figura 4.14 apresenta a simulação dessa variável ao longo do tempo.

$$Fex_1 = 1 + \text{sawtooth}\left(\frac{5\pi t}{t_f}\right), t = 0, \dots, t_f = 15000s \quad (4.18)$$




Figura 4.14: Gráfico do distúrbio inserido no sistema de quatro tanques através da variável Fex_1 .

A Figura 4.15 apresenta a simulação do sistema em malha fechada. Comparando-se as Figuras 4.14 e 4.15, observam-se distúrbios no comportamento da variável h_1 alinhados aos dentes de serra da função Fex_1 .

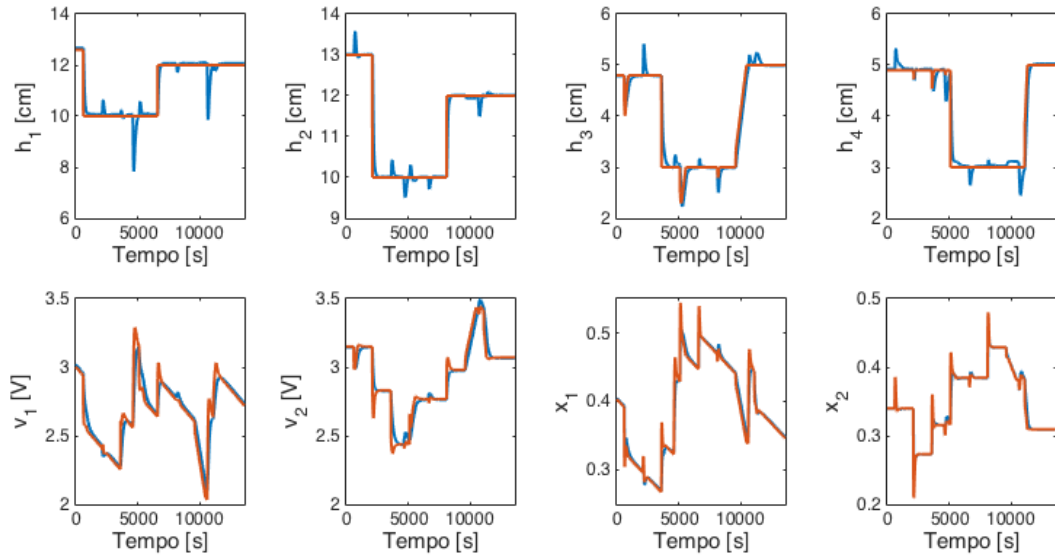


Figura 4.15: Simulação do Cenário 3. Variável medida plotada em azul e valores-alvo em laranja.

A Figura 4.16 (a) apresenta os resultados da avaliação da qualidade de modelo. Observa-se que apenas a variável h_1 parece apresentar um aumento na variância da saída em relação à saída nominal do controlador, pois ultrapassa a linha vermelha, correspondente a indicador de valor unitário. Essa percepção é confirmada pelos resultados do teste de hipótese de igualdade de variâncias, apresentados na Tabela 4.7, e que comprovam que apenas a variável h_1 apresenta probabilidades *p-value* inferiores a 0,05. Além disso, os indicadores $Ivar$ e $Ivar_{diag}$ apresentam valores bastante próximos entre si, indicando que o problema dessa variável não está relacionado a interações com outras variáveis do controlador. As demais variáveis controladas apresentam variabilidade aceitável.

A Figura 4.16 (b) apresenta os resultados da etapa de diagnóstico da variável. O indicador de correlação baseado na estatística de curtose está no limiar da linha de referência (em vermelho) fornecida pelo intervalo de confiança da correlação. Já o indicador baseado na estatística de assimetria não ultrapassou o limite de referência, indicando a predominância de efeito de distúrbio não medido na variável. Com base nos dois indicadores, conclui-se que a variável esteja predominantemente afetada por distúrbios não medidos.




Figura 4.16: (a) Indicadores $Ivar$ apontando discrepância de modelo significativa para a variável h_1 .
(b) diagnóstico da fonte predominante de discrepância de modelo para a variável h_1 .

Tabela 4.7: Resultados do teste de hipótese de Levene para igualdade de variâncias para o Cenário 2.

Variável	$Ivar$	p -value	$Ivar_{diag}$	p -value
h_1	1,1051	0,0045	1,1051	0,0045
h_2	1,009	0,925	1	1
h_3	1,0012	0,9713	1	1
h_4	1,0152	0,7336	1	1

A Figura 4.17 apresenta os resultados do indicador NMDI para a variável controlada h_1 considerando também a variável externa ao controlador, Fex_1 . A inclusão dessa variável na análise utilizou as Equações 3.22 e 3.23. Observa-se que o método apontou o canal referente ao par $(h_1 - Fex_1)$ como aquele mais relacionado à incerteza de modelo. Logo, a recomendação é que a matriz de controle seja atualizada para incluir o respectivo modelo.




Figura 4.17: Resultados da metodologia NMDI para o Cenário 2.

A Figura 4.18 apresenta os resultados da aplicação do método proposto por BADWE, GUDI e PATWARDHAN (2009) para este cenário, utilizando polinômios B e F de ordem $n_b=n_f=4$ e atraso referente a um período de amostragem. Observa-se que este método também apontou o modelo referente ao par $(h_1 - Fex_1)$ como aquele mais relacionado à discrepância de modelo para a variável h_1 .




Figura 4.18: Resultados da metodologia proposta por BADWE, GUDI e PATWARDHAN (2009) para o Cenário 2.

O estudo deste cenário comprova que ambos os métodos são capazes de avaliar a influência de uma variável externa no desempenho do controlador degradado devido a distúrbios não medidos.

4.3.5 Cenário 3: Detecção de MPM em um controlador MPC de estrutura descentralizada

As aplicações industriais de controladores MPC de estrutura descentralizada, caracterizados por matrizes dinâmicas com diversos canais não utilizados (modelos nulos), são bastante encontradas na indústria. Uma das justificativas para isso é que identificar relações de causa e efeito em sistemas pequenos e, em seguida, determinar como os subsistemas interagem é uma tarefa mais fácil do que obter bons modelos para todos os canais (GUDI e RAWLINGS, 2006). Outro ponto é que a divisão do problema em subsistemas facilita o entendimento da aplicação pelos operadores, além de limitar as interações entre os sistemas. Além disso, em alguns casos a exclusão de alguns canais é intencional. Por exemplo, às vezes não se deseja mover uma variável para atender a uma determinada restrição.

No entanto, devido à interação entre as variáveis, é possível que a falta de um modelo na matriz de controladores descentralizados seja percebida pelo método de auditoria como uma discrepância entre modelo e planta em um canal existente na matriz, mesmo que o modelo desse

canal esteja de fato adequado. Por isso, o diagnóstico de controladores MPC descentralizados deve ser mais cauteloso que nos casos MIMO.

Para explorar a aplicabilidade do método proposto em tais cenários, projetou-se um controlador multi-SISO para o sistema de quatro tanques, empregando o emparelhamento de variáveis mais adequado para o ponto de operação de fase não mínima, de acordo com (JOHANSSON, 2000). A Figura 4.19 apresenta a resposta à função degrau da função nominal de sensibilidade, S_0 , para esse controlador.

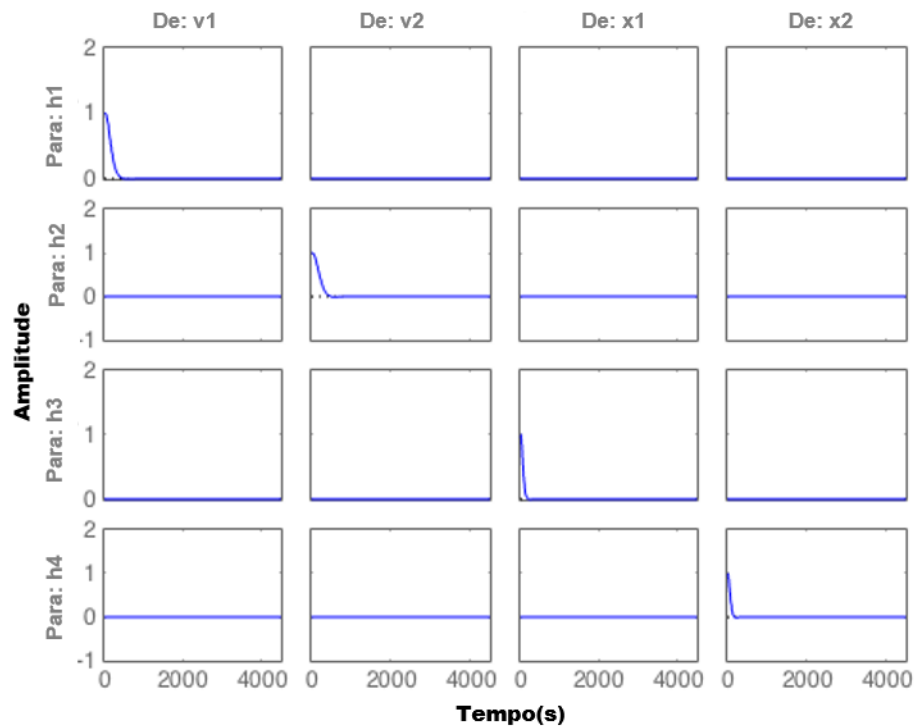


Figura 4.19: Resposta da função de sensibilidade nominal do controlador multi-SISO, S_0 , à função degrau.

A Figura 4.20 apresenta a simulação do controlador atuando sobre a planta nominal. Observa-se o comportamento sem interações significativas entre as variáveis, caso a estrutura multi-SISO do controlador correspondesse a um modelo da planta perfeito.

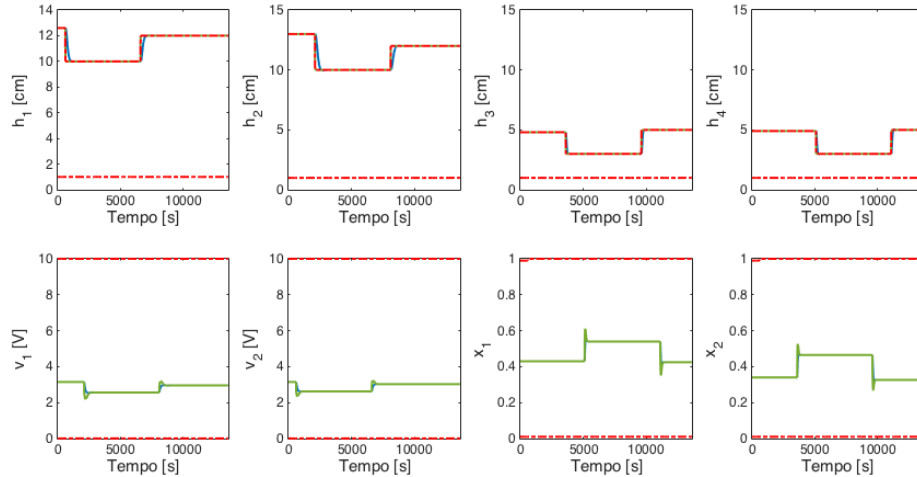


Figura 4.20: Simulação do controlador Multi-SISO atuando sobre o modelo de planta nominal. Variáveis controladas plotadas em azul, limites inferior e superior de operação em linhas vermelhas tracejadas e metas ótimas do controlador em verde.

Para simular o impacto das interações entre as dinâmicas das variáveis no desempenho do controlador, as dinâmicas linearizadas referentes aos pares $(h_1 - v_1)$ e $(h_2 - v_2)$ da Equação 4.5 foram acrescentadas aos modelos da planta. As Equações 4.15 e 4.16 apresentam as matrizes dinâmicas da planta e do controlador, respectivamente:

$$G_p(s) = \begin{bmatrix} \frac{0.0482}{s + 0.01582} & \frac{0.001988}{s^2 + 0.04145s + 0.0004055} & 0 & 0 \\ \frac{0.0009968}{s^2 + 0.02876s + 0.000195} & \frac{0.03496}{s + 0.01094} & 0 & 0 \\ 0 & 0 & 0 & \frac{-0.3701}{s + 0.02563} \\ 0 & 0 & \frac{-0.3091}{s + 0.01782} & 0 \end{bmatrix} \quad (4.19)$$

$$G(s) = \begin{bmatrix} 0 & \frac{0.001988}{s^2 + 0.04145s + 0.0004055} & 0 & 0 \\ \frac{0.0009968}{s^2 + 0.02876s + 0.000195} & 0 & 0 & 0 \\ 0 & 0 & 0 & \frac{-0.3701}{s + 0.02563} \\ 0 & 0 & \frac{-0.3091}{s + 0.01782} & 0 \end{bmatrix} \quad (4.20)$$

O objetivo do teste é que a metodologia recomende a inclusão dos canais inseridos no modelo da planta, caso a interação seja significativa. A Figura 4.21 apresenta a simulação do controlador atuando sobre a planta nesse cenário.

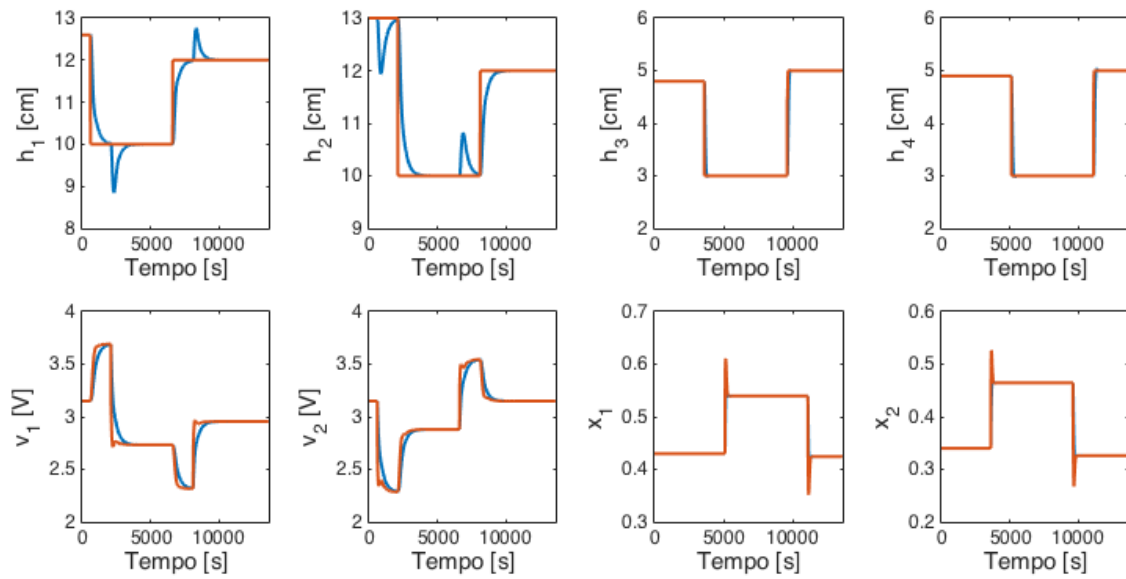


Figura 4.21: Simulação do controlador Multi-SISO atuando sobre o a planta do cenário 3. Variáveis controladas plotadas em azul, e metas ótimas do controlador em laranja.

Comparando as Figuras 4.20 e Figura 4.21, constata-se que a inclusão desses modelos já permite enxergar interações reais entre as dinâmicas dos níveis dos Tanques 1 e 2, h_1 e h_2 , as quais estão afetando o desempenho do controlador.

A Figura 4.22 mostra os resultados da avaliação de qualidade dos modelos e sugere que os indicadores $Ivar_{diag}$ e $Ivar_{diag}$ estejam significativamente diferentes do valor unitário para as h_1 e h_2 . No caso da variável h_1 , os indicadores superaram a linha de referência, indicando que o problema de modelagem está aumentando a variância dessa saída em relação à saída nominal do controlador em malha fechada. Já, para h_2 , os indicadores $Ivar_{diag}$ e $Ivar_{diag}$ encontram-se abaixo da linha de referência, demonstrando que o problema de modelagem está diminuindo a variância dessa saída em relação à saída nominal do controlador. Esta análise é respaldada pelo teste de hipóteses de igualdade de variâncias, cujos resultados estão apresentados na Tabela 4.8, e indicam, com base nos valores de p -value, que se deva rejeitar a hipótese nula (igualdade de variâncias) para as variáveis h_1 e h_2 . Conclui-se, assim, que essas duas variáveis devam ser estudadas.




Figura 4.22: Avaliação da qualidade de modelo para o Cenário 3.

Tabela 4.8: Resultados do teste F de Levene para igualdade de variâncias para o Cenário 3.

<i>Variável</i>	<i>Ivar</i>	<i>p-value</i>	<i>Ivar_{diag}</i>	<i>p-value</i>
h_1	1,1116	0,003	1,1116	0,003
h_2	0,8174	3,48E-15	0,8174	3,48E-15
h_3	1	1	1	1
h_4	1	1	1	1

As Figuras 4.23 (a) e (b) apresentam os resultados do diagnóstico da fonte predominante de problema de modelagem para as variáveis h_1 e h_2 , respectivamente. Para a variável h_1 obteve-se um coeficiente de correlação ligeiramente acima da linha de referência que distingue entre o diagnóstico predominante de MPM ou UD e outro coeficiente indicando efeito predominante de distúrbio não medido. Para a variável h_2 , o diagnóstico foi de predominância de discrepância entre modelo e planta, pois ambos os coeficientes de correlação ultrapassaram o intervalo de confiança representado pela linha de referência vermelha. Sabendo que nos dois casos o problema é discrepância de modelo pela ausência do canal modelado na matriz, constata-se que a identificação da fonte dominante de problema de modelagem nem sempre é conclusiva para controladores MPC de estrutura descentralizada.




Figura 4.23: Diagnóstico da causa predominante de problema de modelagem.
(a) para a variável h_1 . (b) para a variável h_2

Como pelo menos uma das variáveis apresentou causa de problema predominante relacionada a distúrbios não medidos, optou-se por aplicar a metodologia NMDI para avaliar possibilidades de melhoria do controlador com as variáveis já contidas na matriz de controle.

As Figuras 4.24 (a) e (b) apresentam os resultados do indicador NMDI para as variáveis h_1 e h_2 , respectivamente. Em ambos os casos, o método foi capaz de identificar que a incerteza de modelo está mais relacionada aos canais não incluídos no controlador, mas que apresentam relevante interação entre as dinâmicas: $(h_1 - v_1)$ e $(h_2 - v_2)$.

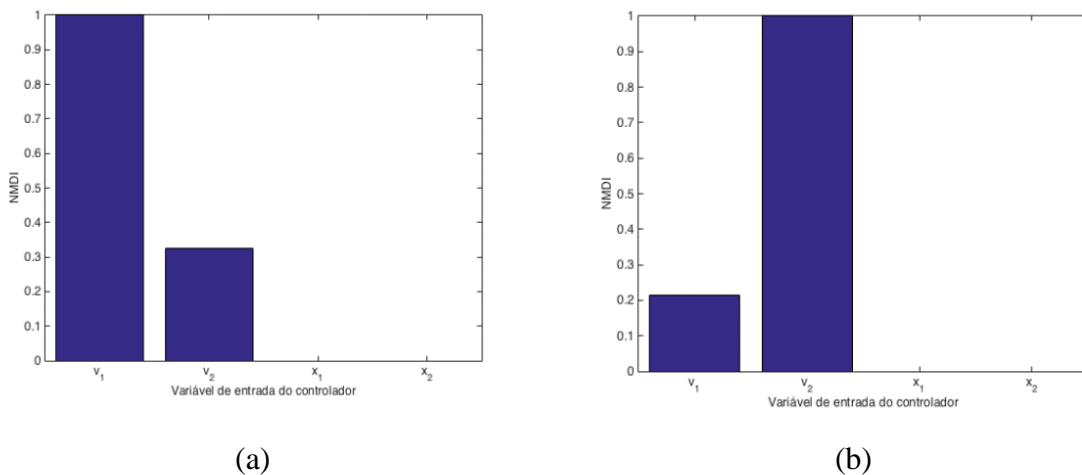


Figura 4.24: Localização da variável de entrada do controlador mais relacionada à discrepância de modelo da variável controlada pela metodologia NMDI. (a) para a variável h_1 . (b) para a variável h_2 .

A Figura 4.25 apresenta os resultados da aplicação do método proposto por BADWE, GUDI e PATWARDHAN (2009). O método encontrou as correlações parciais mais elevadas

para os pares esperados $(h_1 - v_1)$ e $(h_2 - v_2)$ utilizando-se, na etapa de decorrelação de variáveis, as ordens de polinômios $n_b=3$; $n_f=2$ para a variável h_1 e $n_b=n_f=4$ para a variável h_2 .




Figura 4.25: Resultados obtidos para a aplicação do método proposto por BADWE, GUDI e PATWARDHAN (2009). (a) para a variável h_1 ; (b) para a variável h_2 .

A maior dificuldade observada na aplicação do método proposto por BADWE, GUDI e PATWARDHAN (2009) consistiu na seleção da ordem dos modelos dos polinômios B e F para a etapa de decorrelação de variáveis. Para exemplificar a dificuldade, a Figura 4.26 mostra os resultados do método para a variável h_2 utilizando-se polinômios de ordem 3, 4 e 5. Observa-se que o resultado esperado de identificação do par $(h_2 - v_2)$ ocorreu apenas para ordem igual a 4. Neste cenário, sabe-se o resultado esperado porque a discrepância foi inserida propositalmente. Mas é questionável como fazer a seleção dessas ordens para o caso real, no qual não se sabe que discrepância existe.




Figura 4.26: Resultados obtidos para a aplicação do método proposto por BADWE, GUDI e PATWARDHAN (2009) para a variável h_2 . (a) modelos OE ordem $n_b=n_f=3$; (b) modelos OE ordem $n_b=n_f=4$; (c) modelos OE ordem $n_b=n_f=5$.

Uma possibilidade avaliada para apoiar a seleção das ordens foi verificar as estatísticas referentes ao percentual de ajuste dos modelos aos dados utilizados na modelagem, que mede a discrepância entre os dados reais e aqueles obtidos através do modelo. A Tabela 4.9 apresenta

os resultados do percentual de ajuste para cada os modelos obtidos para cada ordem selecionada para os polinômios B e F, para o caso da variável h_3 .

Tabela 4.9: Ajuste dos dados nos modelos da etapa de descorrelação para a variável h_3

<i>Ordens de polinômios</i>						
<i>Variável de entrada</i>	$n_b = n_f = 3$		$n_b = n_f = 4$		$n_b = n_f = 5$	
	H_{u_i}	H_{e_j}	H_{u_i}	H_{e_j}	H_{u_i}	H_{e_j}
v_1	72,9%	100%	75,0%	100%	38,1%	100%
v_2	77,7%	48,8%	79,7%	43%	35,3%	22,8%
x_1	-15,8%	100%	60,1%	100%	58,5%	100%
x_2	57,3%	100%	60,3%	100%	60,2%	100%

Constata-se os polinômios de ordem $n_b = n_f = 4$, os quais corresponderam aos resultados esperados, apresentou os melhores ajustes (percentuais mais elevados) para os modelos de descorrelação das variáveis de entrada do controlador, H_{u_i} , porém não apresentaram os melhores ajustes para os modelos de descorrelação do erro, H_{e_j} . Essa dificuldade de análise da ordem de modelo mais adequada complica a automatização da etapa de descorrelação, que fica bastante dependente da capacidade de análise do usuário.

O estudo deste cenário mostrou que a metodologia proposta pode ser facilmente utilizada para detector modelos nulos de controladores MPC de estrutura descentralizada que deveriam ser incluídos na matriz para considerar o efeito de interações relevantes entre as variáveis.

Assim como no primeiro cenário estudado, embora tanto a metodologia proposta quanto o método de referência tenham fornecido o diagnóstico esperado, conclui-se que a metodologia NMDI, apresentada neste trabalho é mais robusta, por ser menos dependente das decisões do usuário para obter bons resultados.

5. ESTUDO DE CASO EM CONTROLADOR INDUSTRIAL

Este capítulo apresenta um estudo de caso de auditoria do modelo de um controlador linear do tipo DMC (*Dynamic Matrix Controller*) de quarta geração aplicado a um sistema de fracionamento de propeno/propano da unidade de petroquímicos básicos da Braskem no Polo Petroquímico de Triunfo, no Rio Grande do Sul.

5.1 DESCRIÇÃO DA PLANTA INDUSTRIAL

A Figura 5.1 apresenta uma visão geral do sistema de interesse, incluindo um balanço material global em torno dos equipamentos principais. A corrente de carga principal, identificada como corte C₃ hidrogenado, é composta principalmente por propeno e propano. O propósito da primeira coluna (T01) é especificar o propeno grau químico, com pureza variando entre 92% e 96% mol de propeno, através da remoção de componentes mais pesados pela corrente de fundo e eventuais componentes leves pela corrente de topo.

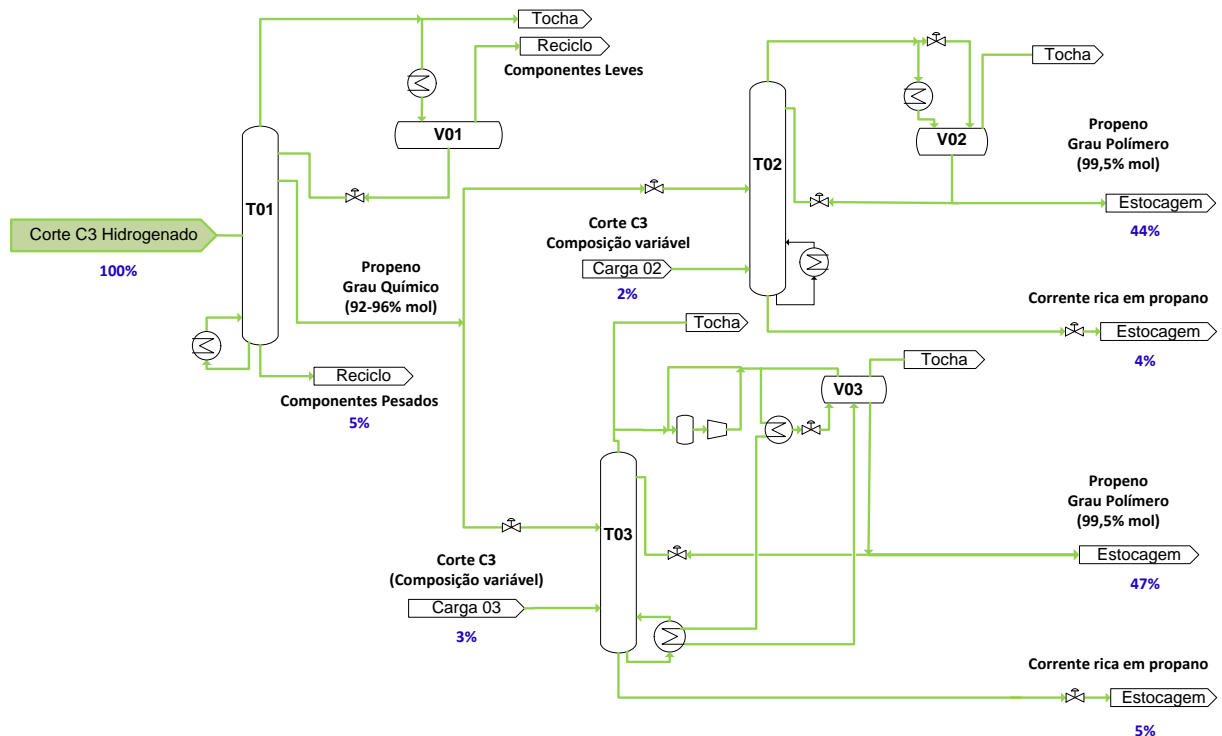


Figura 5.1: Esquema simplificado dos objetivos da aplicação de controle avançado.

O propeno grau químico é removido da coluna *T01* através de uma retirada lateral, e enviado para as colunas de fracionamento propeno/propano, *T02* e *T03*, que operam em paralelo. Ambas as colunas podem receber cargas adicionais de outras unidades (Cargas 02 e 03, respectivamente). O propeno grau polímero, com teor mínimo de 99,5% mol de propeno, é produzido em fase líquida pelo topo das colunas *T02* e *T03*. A corrente de fundo de ambas as torres, rica em propano, é enviada para estocagem.

5.2 DESCRIÇÃO DA ESTRATÉGIA DE CONTROLE DE PROCESSOS

A estratégia de controle regulatório atual das colunas *T01* e *T02* foi escopo do trabalho realizado por FUCHS (2010). O controlador MPC contemplando essas duas colunas entrou em operação em 2011. A coluna *T03* foi incluída em 2013, juntamente com a estratégia para otimização da distribuição de carga entre as colunas fracionadoras de propeno (*T02* e *T03*).

A aplicação MPC é um controlador linear do tipo *DMC* (*Dynamic Matrix Controller*), desenvolvido em um pacote comercial e possui oito variáveis manipuladas (*MVs*), quatro variáveis distúrbio (*DVs*) e doze variáveis controladas (*CVs*), que estão identificadas na Figura 5.2 e descritas na Tabela 5.1. O controlador opera no nível de supervisão, enviando *setpoints* a cada minuto aos controladores tipo *PID* que rodam no sistema digital de controle distribuído (*SDCD*).

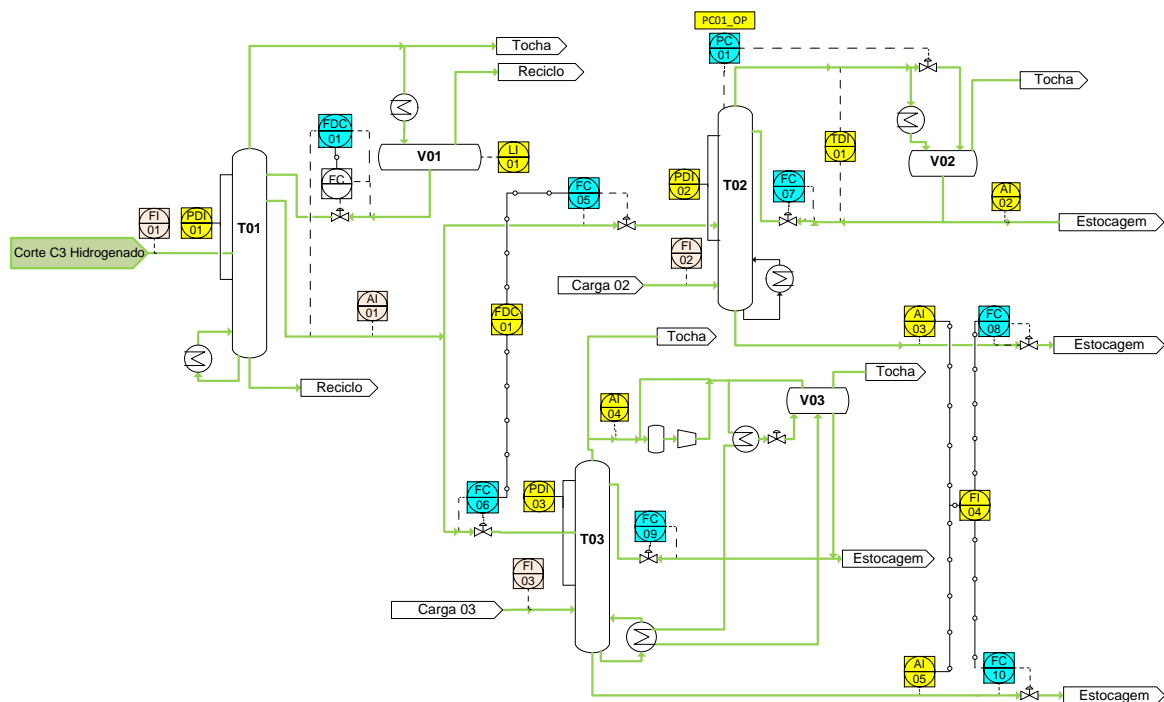


Figura 5.2: Diagrama simplificado da estrutura do MPC aplicado ao processo de fracionamento de propeno/propano. As variáveis manipuladas estão indicadas em azul, variáveis distúrbio em rosa e variáveis controladas estão indicadas em amarelo.

Tabela 5.1: Descrição das variáveis do controlador MPC

Variável	Tipo	Descrição	Unidade de Engenharia
AI01	DV	Teor de propano na carga das colunas T02 e T03	% mol
AI02	CV	Teor de impurezas no propeno da T02	% mol
AI03	CV	Teor de propeno na vazão de fundo da T02	% mol
AI04	CV	Teor de impurezas no propeno da T03	% mol
AI05	CV	Teor de propeno na vazão de fundo da T03	% mol
FC05	MV	Setpoint de vazão de carga para a T02	t/h
FC06	MV	Setpoint de vazão de carga para a T03	t/h
FC07	MV	Setpoint de vazão de refluxo para a T02	t/h
FC08	MV	Setpoint de vazão de retirada de fundo da T02	t/h
FC09	MV	Setpoint de refluxo para a T03	t/h
FC10	MV	Setpoint de vazão de retirada de fundo da T03	t/h
FDC01	MV	Setpoint de vazão de refluxo interno para a T01	t/h
FDI01	CV	Diferença entre as cargas das colunas T03 e T02	t/h
FI01	DV	Vazão de carga para a T01	t/h
FI02	DV	Vazão de carga adicional à T02	t/h
FI03	DV	Vazão de carga adicional à T03	t/h
FI04	CV	Vazão total de propeno na vazão de fundo (T02 + T03)	t/h
LI01	CV	Nível do vaso de topo da T01	%
PC01	MV	Setpoint de pressão da T02	kgf/cm ² _g
PC01_OP	CV	Abertura da válvula de controle de pressão da T02	%
PDI01	CV	ΔP da T01	kgf/cm ²
PDI02	CV	ΔP da T02	kgf/cm ²
PDI03	CV	ΔP da T03	kgf/cm ²
TDI01	CV	ΔT entre as correntes de topo e refluxo da T02	°C

A aplicação está organizada em três subcontroladores, um para cada coluna. A variável controlada LI01, nível do vaso de topo da coluna *TO1*, é uma variável integradora e possui *setpoint* definido. Os limites operacionais, tanto para as *MVs* quanto para as *CVs*, são atualizados pelos operadores de acordo com as restrições de plantas ou decisões de negócio.

A Figura 5.3 apresenta um esquema da matriz de controle e ilustra como as variáveis controladas estão distribuídas entre os subcontroladores (SUBs 1, 2 e 3). Os canais com modelos não nulos estão marcados em azul, evidenciando a estrutura descentralizada do controlador.

		FDC01	FC05	FC06	FC07	FC08	PC01	FC09	FC10	FI01	FI02	AI01	FI03
SUB1	LI01	■	■	■						■			
	PDI01	■								■			
	FDI01		■	■									
	FI04					■			■				
SUB2	AI02		■		■	■					■	■	
	AI03		■			■					■	■	
	PDI02				■								
	PC01_OP				■		■						
	TDI01				■		■						
SUB3	AI04			■				■	■			■	■
	AI05								■			■	
	PDI03			■				■					■

Figura 5.3: Representação matriz dinâmica do controlador, exibindo os canais modelados (em azul) e o agrupamento das variáveis controladas por subcontroladores (SUBs 1, 2 e 3).

5.3 RESULTADOS E DISCUSSÃO

5.3.1 Roteiro de aplicação do método

A Figura 5.4 apresenta um diagrama de blocos do fluxo de realização da auditoria do controlador, identificação de modelos que necessitavam ser melhorados e avaliação preliminar dos modelos antes da implantação das atualizações em ambiente de produção.

Trata-se de uma combinação dos métodos propostos por BOTELHO, TRIERWEILER *et al.* (2015a,b,2016) para identificar as variáveis controladas que estavam afetando o desempenho do controlador com a metodologia NMDI para localização do canal mais correlacionado ao problema de modelagem de cada CV identificada.

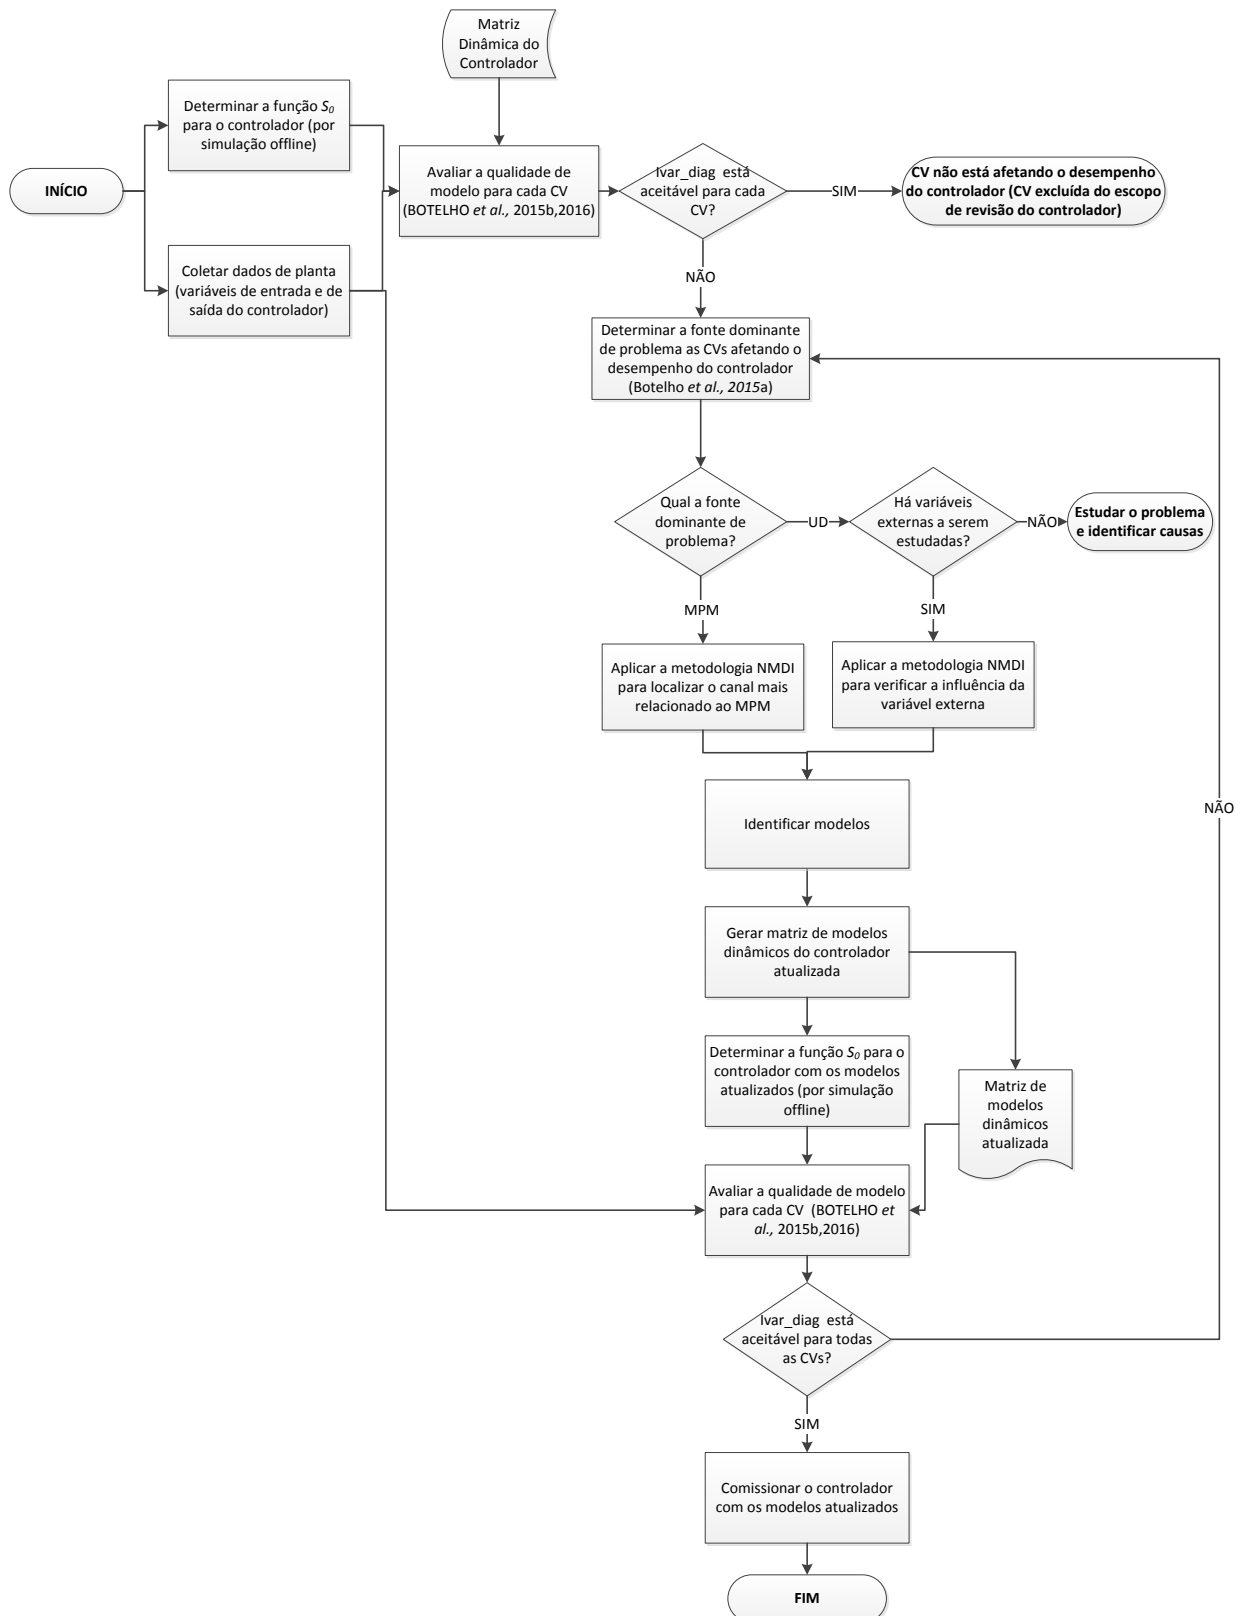


Figura 5.4: Fluxo de trabalho utilizada na auditoria e revisão do controlador, integrando os métodos propostos por BOTELHO, TRIERWEILER *et al.* (2015 a,b,2016) com a metodologia NMDI proposta.

Os pré-requisitos para realizar a avaliação do controlador são a seleção de dados históricos de processo das variáveis de entrada e saída do controlador, referentes ao período a

ser utilizado na auditoria e a determinação da função de sensibilidade nominal do controlador, S_0 , através de simulação do controlador *off-line*.

Os dados coletados e a função de sensibilidade são utilizados para avaliar a Qualidade dos Modelos de acordo com o método proposto por BOTELHO, TRIERWEILER *et al.* (2015b, 2016). A matriz de modelos dinâmicos do controlador também é necessária para simular os canais, obtendo-se y_{sim} , necessário para calcular a saída nominal do controlador, y_0 .

As variáveis controladas que apresentarem o indicador $Ivar_{diag}$ aceitável não possuem discrepâncias de modelo afetando o desempenho do controlador e devem ser excluídas do escopo de revisão de modelos. O critério de aceitabilidade para indicador $Ivar_{diag}$ é o teste de hipótese F de Levene para igualdade de variâncias, implementado no MATLABTM conforme Equação 4.10.

Para cada CV que esteja afetando o desempenho do controlador, aplicar o método proposto por BOTELHO, TRIERWEILER *et al.* (2015a) para determinar a fonte dominante do problema. Este é o início do processo iterativo que terminará apenas quando todas as CVs apresentarem modelos com qualidade aceitável, medida através do indicador $Ivar_{diag}$.

A metodologia NMDI pode ser aplicada aos casos em que a fonte dominante de incerteza de modelo é MPM, ou para estudar a influência de variáveis externas para resolver problemas de desempenho relacionados a distúrbios não medidos, caso o engenheiro tenha variáveis candidatas para a análise. Caso contrário, o engenheiro deverá estudar o problema com maior profundidade.

Após aplicar a metodologia NMDI, realizar a identificação dos modelos que necessitem melhoria. É importante ressaltar que o processo de identificação pode demandar ajustes nos outros modelos para a mesma variável controlada, já que esse processo distribui o erro de modelagem entre todas as variáveis. Esta observação é importante, principalmente no caso de inclusão de modelos em canais anteriormente nulos.

A seguir, determina-se a função de sensibilidade para a matriz de controle com os modelos atualizados e repete-se a etapa de Avaliação da Qualidade do Modelo. O processo iterativo termina quando todas as variáveis apresentarem qualidade, medida através do indicador $Ivar_{diag}$, aceitável. A partir desse momento, pode-se comissionar o controlador com os modelos atualizados.

5.3.2 Auditoria do Controlador

Para garantir que a auditoria do controlador representasse toda a faixa de operação da planta de interesse, foram utilizados dados referentes a três períodos do primeiro semestre de 2015, considerando os seguintes critérios:

- planta estável na condição de processo selecionada;
- controlador com os três subcontroladores ligados por um tempo de pelo menos sessenta horas, garantindo mais de três vezes o tempo para atingir o estado estacionário do processo.
- todas as variáveis do controlador em operação (para poderem ser auditadas).
- Seleção de dados contínuos (sem exclusão de dados ao longo do período selecionado).

As Figuras 5.5, 5.7 e 5.9 apresentam os gráficos de tendência das variáveis controladas para cada período, enquanto as Figura 5.6, 5.8 e 5.10 apresentam gráficos das variáveis de manipuladas e variáveis distúrbio para cada um dos três períodos.

Observa-se, nas Figuras 5.5 e 5.6, o primeiro conjunto de dados selecionado para análise, que corresponde a 4411 dados coletados com intervalo de amostragem $T_s=1$ minuto e reflete um cenário de carga e composição (FI01 e AI01) estáveis e condizentes com a operação da planta na época de projeto do controlador. A distribuição de carga entre as torres priorizou elevar a carga da coluna T03, conforme mostram FDI01, FC05 e FC06. As alterações no limite inferior de refluxo da coluna (FC09) apontam que, por algum motivo, a operação queria forçar uma vazão de refluxo (mantendo uma faixa estreita para manipulação do controlador), embora a composição de topo, AI04, estivesse bem controlada. Outra constatação é que o operador receia que o controlador atue abrindo demasiadamente a FC10, pois o gráfico dessa variável aponta o trabalho do operador em restringir o limite superior de operação dessa variável em boa parte do período. A priorização de carga para a coluna T03 em relação à T02 provavelmente está ligada à limitação de carga térmica no condensador da T02, pois a variável controlada PC01_OP permaneceu saturada fechada.

As Figuras 5.7 e 5.8 apresentam o segundo conjunto de dados selecionado para análise, correspondente a um período de 5341 minutos com dados coletados com intervalo de amostragem $T_s=1$ minuto. Esse período apresentou uma maior variação da vazão e composição da carga geral do sistema, que são distúrbios medidos. Adicionalmente, o sistema operava em um patamar de carga superior àquele referente ao projeto do controlador. Observa-se que a coluna T02 operou no limite de capacidade de condensação (PC01_OP em zero) e de

capacidade de fracionamento (PDI02 no valor máximo), explicando a distribuição de carga preferencial para a coluna T03, conforme mostram os medidores FDI01, FC05 e FC06. O controle da especificação do propeno produto (AI02 e AI04) foi possível apenas aumentando a vazão de fundo das colunas (FC08 e FC10), o que explica os elevados teores de propeno na corrente de fundo das torres T02 e T03 (AI03 e AI05, respectivamente), principalmente na primeira metade do período. Neste período não houve evidência de a operação limitar refluxo nem vazão de fundo da torre T03.

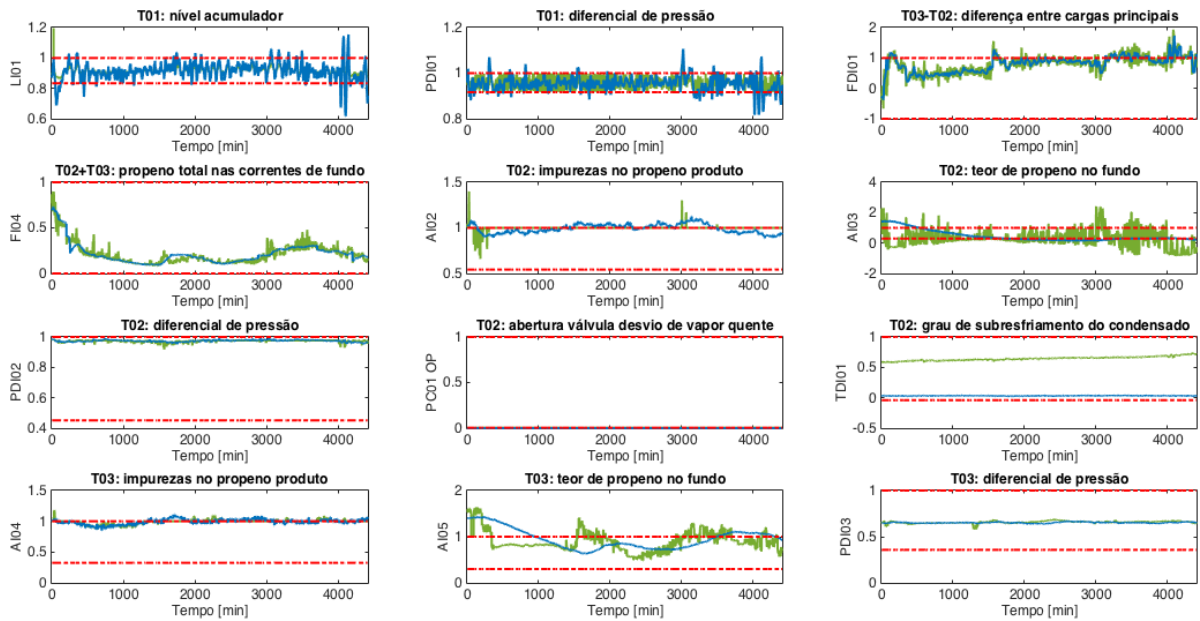


Figura 5.5: Comportamento das variáveis de saída no primeiro período de avaliação do controlador

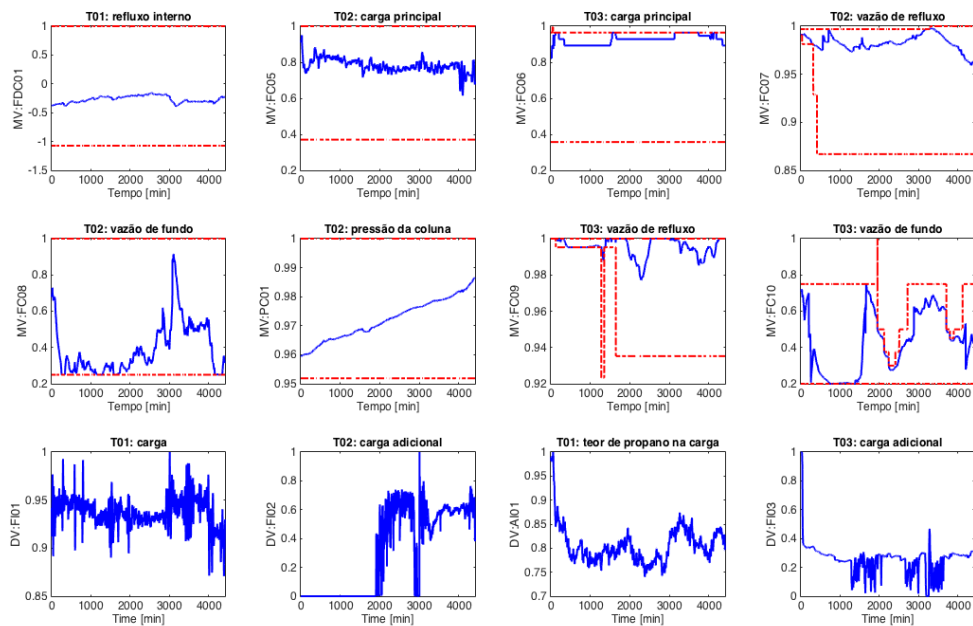


Figura 5.6: Comportamento das variáveis de entrada (variáveis manipuladas e variáveis-distúrbio) no primeiro período de avaliação do controlador

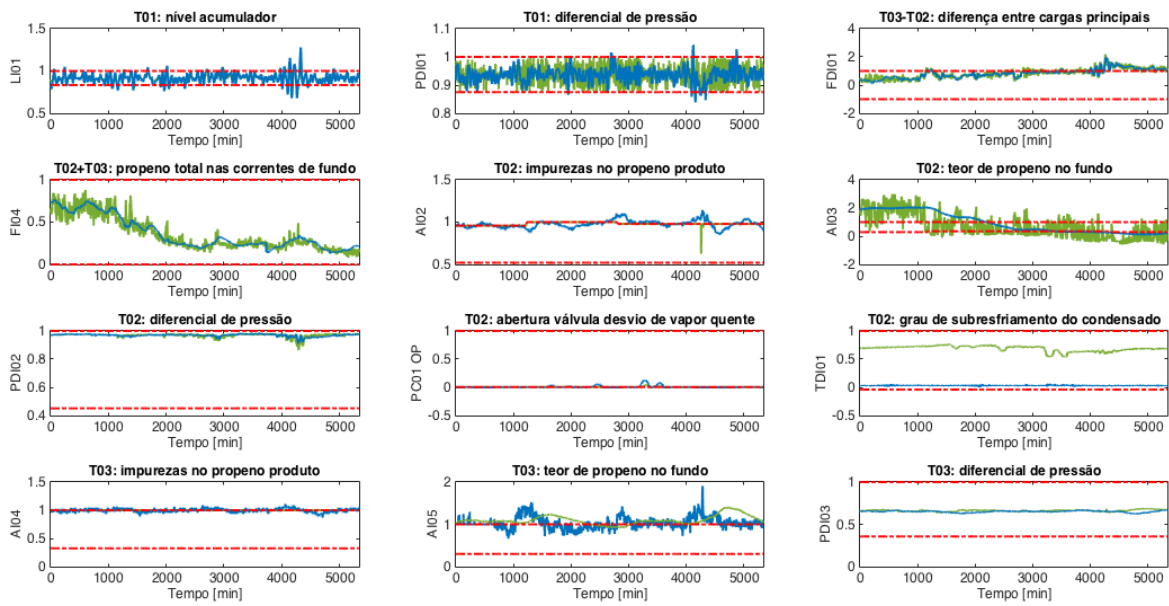


Figura 5.7: Comportamento das variáveis de saída no segundo período de avaliação do controlador

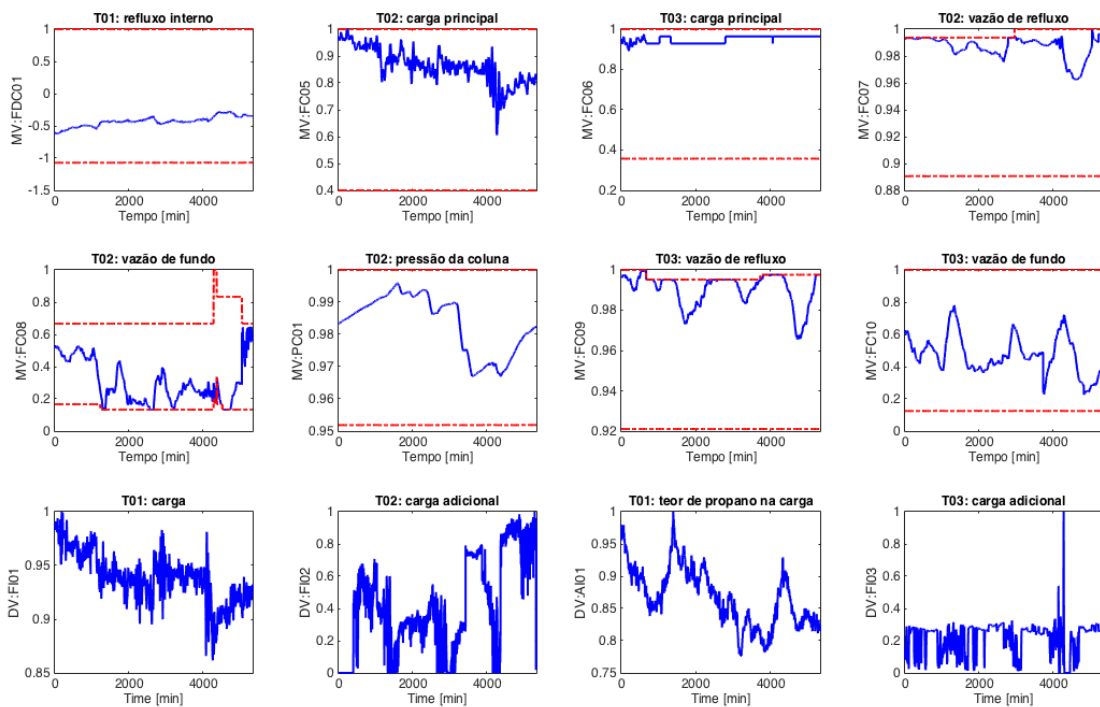


Figura 5.8: Comportamento das variáveis de entrada (variáveis manipuladas e variáveis-distúrbio) no segundo período de avaliação do controlador

As Figuras 5.9 e 5.10 apresentam o terceiro conjunto de dados selecionado para análise, correspondente a 4021 minutos de dados coletados com período de amostragem $T_s=1$ minuto. O sistema também operava em um patamar de carga intermediário em relação aos dois períodos anteriores, porém foi sujeito a um pico de composição da carga geral do sistema, AI01, por volta do instante de tempo de 3000 minutos. Observa-se que o operador restringiu o limite

superior de refluxo das duas colunas, e o controlador usou a vazão de fundo para manter o sistema sob controle. Esta atuação do operador significa que o operador não entende ou não concorda com o plano de movimentos do controlador. Talvez o controlador não enxergue restrições relevantes, referentes a limitações de carga térmica das torres, por exemplo, que limitem o aumento de refluxo.

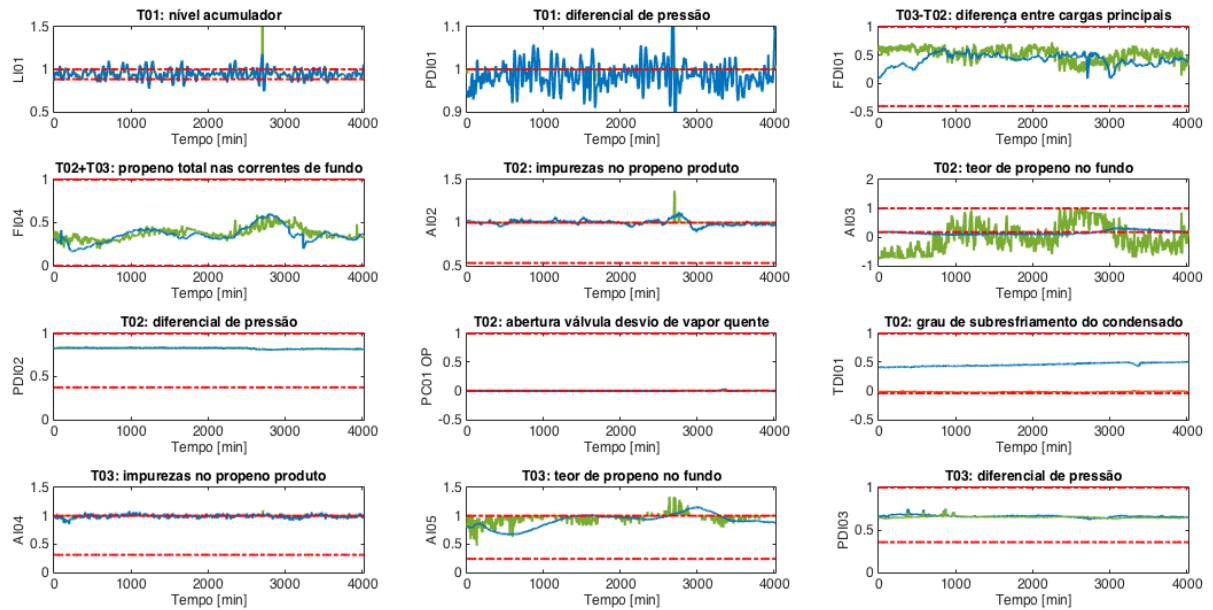


Figura 5.9: Comportamento das variáveis de saída no terceiro período de avaliação do controlador

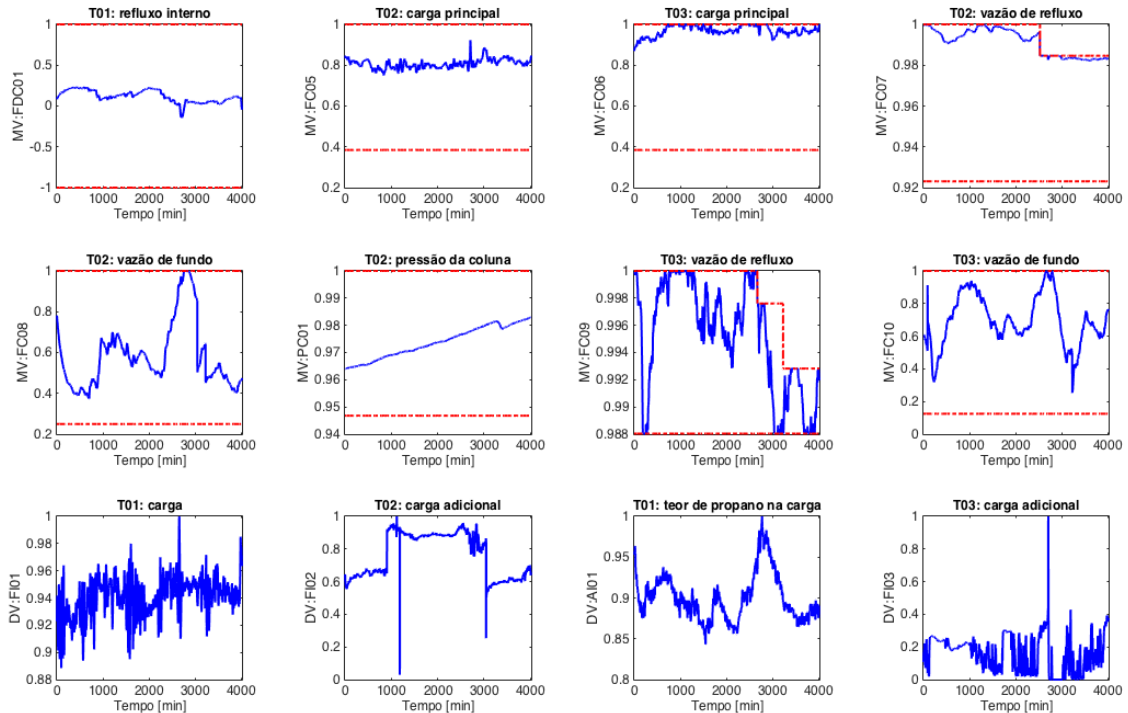


Figura 5.10: Comportamento das variáveis de entrada do controlador (variáveis manipuladas e variáveis-distúrbio) no terceiro período de avaliação do controlador.

A identificação das variáveis controladas que necessitavam ser remodeladas foi realizada através da metodologia proposta por BOTELHO, TRIERWEILER *et al.* (2015 a, b, 2016). Os resultados dessa análise foram apresentados em CLARO, BOTELHO, *et al.* (2016).

No entanto, ao longo do desenvolvimento do presente trabalho foi ocorrendo um aprofundamento do entendimento do método proposto por BOTELHO, TRIERWEILER *et al.* (2015a,b,2016), o que resultou em algumas alterações na sua implementação para esta seção da dissertação em relação ao trabalho citado. Isto resultou em diferença entre os resultados apresentados neste capítulo e aqueles publicados no referido trabalho (CLARO, BOTELHO, *et al.*, 2016).

A mais importantes das constatações é que variáveis que estejam sendo controladas dentro da faixa e que não demandem ações de controle enquanto não atingirem nem ultrapassarem o limite de operação não devem ter o erro de simulação filtrado por S_0 para se determinar y_0 . Ou seja, S_0 deve ser considerado igual a um, de forma que o erro nominal do controlador, e_0 , corresponda ao próprio erro de simulação, pois tudo se passa como se o controlador estivesse em malha aberta, já que aquela variável, dentro da faixa, não demanda ações de controle.

Para implantar esse critério, utilizaram-se as Figuras 5.5, 5.7 e 5.9, para identificar visualmente se cada variável era tratada predominantemente como otimizada ou controlada entre faixas para cada período. Para as variáveis controladas entre faixa, S_0 diagonal foi considerada igual a 1. A Tabela 5.2 resume como cada variável foi tratada em cada período:

Tabela 5.2: Classificação das variáveis controladas por período.

Variável	Período I	Período II	Período III
LI01	Otimizada	Otimizada	Otimizada
PDI01	Em faixas	Em faixas	Otimizada
FDI01	Otimizada	Otimizada	Em faixas
FI04	Em faixas	Em faixas	Em faixas
AI02	Otimizada	Otimizada	Otimizada
AI03	Otimizada	Otimizada	Otimizada
PDI02	Em faixas	Em faixas	Em faixas
PC01_OP	Otimizada	Otimizada	Otimizada
TDI01	Em faixas	Em faixas	Em faixas
AI04	Otimizada	Otimizada	Otimizada
AI05	Otimizada	Otimizada	Otimizada
PDI03	Em faixas	Em faixas	Em faixas

Nota-se que as variáveis FDI01, PDI02, TDI01 e PDI03 foram classificadas como predominantemente controladas entre faixas nos três períodos. Já as variáveis PDI01 e FDI01 alternaram de comportamento dependendo do caso.

A Figura 5.11 apresenta os resultados da avaliação da qualidade de modelo por variável controlada, para cada período avaliado. A linha vermelha corresponde ao valor unitário do indicador e serve como referência para análise. Nesta avaliação, utilizou-se o indicador $Ivar_{diag}$, pois priorizaram-se os impactos das discrepâncias de modelo de cada variável causadas nela mesma. A variação dos resultados referentes aos três períodos para uma mesma variável controlada ratifica a decisão de auditar o controlador em mais de um cenário de planta. Já a diferença de resultados entre variáveis controladas comprova que o problema de incerteza de modelagem não está uniformemente distribuído pelo controlador, fortalecendo a ideia de priorizar variáveis para reduzir o escopo da revisão do controlador.

Observando-se a Figura 5.11, nota-se que o segundo período, no qual o sistema estava trabalhando próximo ao limite de capacidade, foi aquele que apresentou as maiores discrepâncias para as variáveis AI02 e AI04, as quais correspondem ao controle de especificação de pureza do propeno produto e são variáveis controladas muito importantes.

A variável PC01_OP, que corresponde à abertura da válvula de desvio de vapor quente do condensador diretamente ao vaso acumulador também apresentou grandes discrepâncias, pois, nessa condição limite, essa válvula já estava saturada na posição fechada por limitação na capacidade de condensação do sistema, não respondendo ao comportamento de modelo linear esperado entre o *setpoint* e a abertura da válvula.




Figura 5.11: Indicador $Ivar$, resultado da auditoria da qualidade de modelo por CV para cada um dos períodos auditados.

A definição das variáveis controladas a serem avaliadas para localização de problemas de modelos foi feita com base na média do indicador $Ivar_{diag}$ para os três períodos, conforme mostrado na com a Figura 5.12. Os resultados dessa Figura sugerem que a variável FDI01 possui a média do indicador $Ivar_{diag}=1$, indicando não haver problemas de modelagem afetando o desempenho do controle. A confirmação dessa hipótese foi obtida aplicando-se o teste F de Levene para igualdade de variâncias, cujos resultados, para todas as variáveis, estão apresentados na Tabela 5.3. Dessa forma, a variável FDI01 foi excluída das demais análises.




Figura 5.12: Indicador $Ivar_{diag}$, resultado da auditoria da qualidade de modelo por variável controlada para cada um dos períodos auditados.

Tabela 5.3: Resultados da probabilidade (p-value) do teste F de Levene para as variáveis controladas

Variável	Período I	Período II	Período III	Conclusão
LI01	5,71E-04	5,05E-05	2,94E-28	$Ivar_{diag} \neq 1$
PDI01	0	3,30E-243	8,25E-264	$Ivar_{diag} \neq 1$
FDI01	0,855	0,6633	0,8112	$Ivar_{diag} = 1$
FI04	1,46E-64	0	0,146	$Ivar_{diag} \neq 1$
AI02	1,20E-142	6,11E-213	8,28E-181	$Ivar_{diag} \neq 1$
AI03	1,57E-11	3,18E-141	0	$Ivar_{diag} \neq 1$
PDI02	1,18E-51	2,83E-94	0	$Ivar_{diag} \neq 1$
PC01_OP	0	6,39E-255	0,2486	$Ivar_{diag} \neq 1$
TDI01	0	0	0	$Ivar_{diag} \neq 1$
AI04	9,96E-21	0	1,15E-195	$Ivar_{diag} \neq 1$
AI05	8,27E-92	1,33E-41	1,69E-05	$Ivar_{diag} \neq 1$
PDI03	0	4,67E-180	7,20E-174	$Ivar_{diag} \neq 1$

Cabe ressaltar que a diferença na classificação das variáveis como otimizada ou controlada em faixas, já explicada, é a causa deste gráfico estar distinto daquele apresentado em (CLARO, BOTELHO, *et al.*, 2016).

A Figura 5.13 apresenta os resultados da análise da causa predominante de incerteza de modelagem, conforme BOTELHO, TRIERWEILER, *et al.* (2015a). A linha de referência corresponde ao intervalo de confiança da correlação ($CI=0,03$), obtido pela Equação 2.24 considerando um nível de confiança de 95%. Considerando-se que basta um dos indicadores de correlação ultrapassar o intervalo de confiança para considerar a discrepância de modelo como causa predominante de incerteza de modelo para a variável controlada em questão, optou-se por considerar o valor máximo dentre eles:

$$c_{dmax} = \text{máximo}\{c_{dks}, c_{dskn}\} \quad (5.1)$$




Figura 5.13: Resultados de correlação máxima entre y_0 e e_0 com base nas estatísticas de curtose e assimetria para as variáveis controladas.

Os resultados apresentados na Figura 5.13 apontam que há um problema predominante de modelo em pelo menos um dos períodos para cada uma das variáveis analisadas, pois para todas elas o coeficiente de correlação máximo ultrapassou a linha de referência em pelo menos um dos períodos. Por esse motivo, realizou-se a terceira etapa da auditoria buscando identificar o canal mais correlacionado à discrepância antes de considerar a influência de variáveis externas ao controlador. A aplicação da metodologia NMDI foi realizada para todas as variáveis controladas, exceto a variável FDI01. Para manter consistência com a estrutura do controlador, as variáveis de entrada consideradas para cada variável controlada ficaram restritas àquelas disponíveis na estrutura do subcontrolador.

A Figura 5.14 apresenta o canal identificado mais correlacionado ao problema de cada variável controlada para cada período (identificados como Períodos I, II e III). Cabe lembrar

que os canais da matriz de controle com modelos não nulos estão sinalizados em azul. Observa-se que, na maioria dos casos, a incerteza de modelo que mais afeta o controlador depende do ponto operacional, variando conforme o caso. A partir da análise dos três períodos, a auditoria identificou vinte e três canais como aqueles mais correlacionados às incertezas de modelos das variáveis controladas. Desses canais, apenas cinco correspondem a canais já modelados. Os demais são modelos que devem ser incluídos na matriz, pois sua ausência está afetando o desempenho do controlador.

		FDC01	FC05	FC06	FC07	FC08	PC01	FC09	FC10	FI01	FI02	AI01	FI03
SUB1	LI01	I, II, III											
	PDI01	I,II		III									
	FDI01												
	FI04		II				III					I	
SUB2	AI02				II,III	I							
	AI03				III		I,II						
	PDI02		II				III					I	
	PC01_OP					I						II,III	
	TDI01					III					I	II	
SUB3	AI04												I,III
	AI05			III				II					I
	PDI03								I,II,III				

Figura 5.14: Resumo dos canais da matriz que mais afetando no desempenho do controlador para os Períodos (I, II e III) avaliados.

A Tabela 5.4 apresenta um resumo da tratativa dada a cada variável controlada, com base nos resultados da Figura 5.14. Cabe destacar que os resultados dessa figura foram um direcionador para o trabalho de modelagem, mas nem todos os canais sugeridos foram identificados em algumas situações específicas, por exemplo em situações em não se obteve um modelo satisfatório, conforme os relatórios de análise de incerteza disponíveis no ambiente de modelagem do controlador.

Tabela 5.4: Resumo das identificações executadas por variável.

<i>CV</i>	<i>Modelos</i>	
	<i>Identificados</i> <i>(Saída – Entrada)</i>	<i>Análise Crítica</i>
LI01	(LI01 - FDC01)	A análise dos três períodos localizou o problema em um modelo existente, o qual foi identificado.
PDI01	(PDI01 - FDC01)	Dois períodos apontaram par (PDI01 - FDC01), enquanto o terceiro localizou o problema no canal (PDI01 - FC03). Como a FC03, que é carga para a coluna T03, está indiretamente considerada no refluxo interno (FDC01), optou-se por não incluir esse modelo devido à colinearidade entre as variáveis.
FI04	(FI04 - AI01)	Auditoria localizou modelos diferentes como os mais relacionados ao problema de modelagem para cada período. Optou-se por não incluir o modelo entre as variáveis (FI04 - FC02), pois isso demandaria também a inclusão do modelo entre (FI04 - FC03), pois as variáveis FC02 e FC03 são colineares, nem como o modelo entre (FI04 - PC01), por se tratar de uma situação sazonal.
AI02	(AI02 - FC05), (AI02 - FC06)	Os três períodos apontaram para remodelagem de canais existentes, os quais foram identificados.
AI03	(AI03 - FC05), (AI03 - PC01)	Os três períodos apontaram para a inclusão de novos canais, os quais foram identificados.
PDI02	(PDI02 - FC05), (PDI02 - AI01)	Os três períodos apontaram para a inclusão de novos canais. O modelo (PDI02 - PC01) não foi incluído, pois não se conseguiu identificar um modelo com qualidade aceitável.
PC01_OP	(PC01_OP - FC08), (PC01_OP - AI01)	- Os três períodos apontaram para a inclusão de novos canais (modelos do grau de subresfriamento do refluxo em função da vazão de refluxo e composição do propeno grau químico)
TDI01	(TDI01 - FC08), (TDI01 - FI02), (TDI01 - AI01)	Os três períodos apontaram para a inclusão de novos canais, os quais foram identificados.
AI04	(AI04 - FI03)	Dois períodos apontaram para o mesmo canal, o qual foi identificado.
AI05	(AI05 - FI03) (AI05 - FI03) (AI05 - FI03)	Os três períodos apontaram para a inclusão de novos canais, os quais foram identificados.
PDI03	(PDI03 - FC10)	Os três períodos apontaram o mesmo canal, o qual foi identificado.

A Figura 5.15 representa um resumo da matriz dinâmica após a identificação dos modelos necessários. Os canais marcados em azul são aqueles que apresentam modelos não nulos. Os canais alterados neste trabalho estão identificados com as letras R, caso correspondam a canais já existente da matriz, ou N, para os casos em que os canais que possuísse modelos nulos no controlador original.

		FDC01	FC05	FC06	FC07	FC08	PC01	FC09	FC10	FI01	FI02	AI01	FI03	TI01
SUB1	LI01	R												
	PDI01	R												
	FDI01													
	FI04											N		
SUB2	AI02				R	R								
	AI03				N		N							
	PDI02		N									N		
	PC01_OP					N						N		
	TDI01					N					N	N		
SUB3	AI04												R	N
	AI05			N				N					N	
	PDI03								R					

Figura 5.15: Representação da matriz dinâmica do controlador após trabalho de identificação de variáveis.

Após a identificação dos modelos e atualização da matriz dinâmica do controlador, efetuou-se a identificação da função de sensibilidade nominal do controlador remodelado, S_0 , e realizou-se a avaliação da qualidade de modelos de duas formas:

- Avaliação do controlador com os modelos atualizados, utilizando os dados referentes os mesmos três períodos usados na auditoria, e calculando-se a média do resultado do indicador $Ivar_{diag}$ para os três períodos, analogamente ao trabalho realizado na auditoria;
- Avaliação do controlador utilizando um conjunto de dados de agosto/2016, período posterior à implantação do controlador. Neste caso foram coletados dados contínuos, com 5760 minutos de duração e período de amostragem $T_s = 1$ min. A seleção deste conjunto de dados seguiu os mesmos critérios da auditoria (todas as

variáveis ligadas por um tempo maior ou igual a três vezes o tempo para estado estacionário e planta estável, sem distúrbios operacionais atípicos)

A Figura 5.16 apresenta os resultados dessa avaliação da qualidade de modelo para as três situações: avaliação de auditoria do controlador, avaliação do controlador revisado utilizando os mesmos dados da auditoria, avaliação do controlador revisado operando após implantação. Observa-se uma redução significativa do indicador de variância para as variáveis que apresentavam o indicador $Ivar_{diag}$ acima de 2, tanto para o caso em que foram usados os dados próprios dados de auditoria, quando para o período posterior. Os resultados para o caso pós implantação do controlador confirmam uma melhora considerável de desempenho do controlador, pois não se encontram discrepâncias tão relevantes quanto no controlador original. Entretanto, o indicador $Ivar_{diag}$ apresenta-se próximo a 2 para as variáveis AI05 (análise de fundo da coluna T03) e PC01_OP (abertura da válvula de controle de pressão da T02). A repetição sistemática dessa análise permitirá monitorar a degradação do desempenho do controle, indicando o momento adequado para a próxima revisão do controlador.




Figura 5.16: Comparação entre o indicador médio $Ivar_{diag}$ obtido: na auditoria do controlador, com o controlador revisado utilizando os próprios dados da auditoria e com o controlador revisado em operação.

É ainda pertinente ao trabalho uma análise adicional da aplicação da metodologia para a variável AI04 no segundo período. Retomando a Figura 5.14, observa-se que não foi apresentado resultado para essa variável referente ao segundo período. A razão é que o método não encontrou nenhum canal da matriz com correlação significativa em relação ao problema de modelo (as correlações calculadas para todos os canais não ultrapassaram os limites da estimativa de intervalo de confiança). Conclui-se que o problema de modelagem que afetava o

desempenho nesse período estivesse associado a um distúrbio não medido, embora o indicador de correlação máximo, $c_{d\max}$ tenha apresentado valor ligeiramente superior à referência de 0,03, conforme Figura 5.13.

Este resultado é compatível com os resultados de (CLARO, BOTELHO, *et al.*, 2016), em que foi inserida uma entrada adicional ao controlador (identificada na Figura 5.17 como variável distúrbio número cinco, DV5) para melhorar a modelagem dessa variável.




Figura 5.17: Comparação entre os modelos original (a) e novos (b) para a variável AI04 (CV10). Fonte: (CLARO, BOTELHO, *et al.*, 2016).

A coluna T03 possui um sistema de recompressão da corrente de topo da coluna, que é parcialmente utilizada como carga térmica de refervimento. A variável DV5 da Figura 5.17 corresponde à temperatura da parcela da corrente de topo que está retornando para o vaso acumulador após ter sido utilizada no refervimento da coluna. Ela tem uma importância relevante na temperatura da vazão de refluxo da torre e, portanto, deve impactar a composição de topo da coluna. Essa temperatura está representada na Figura 5.19 como TI01.

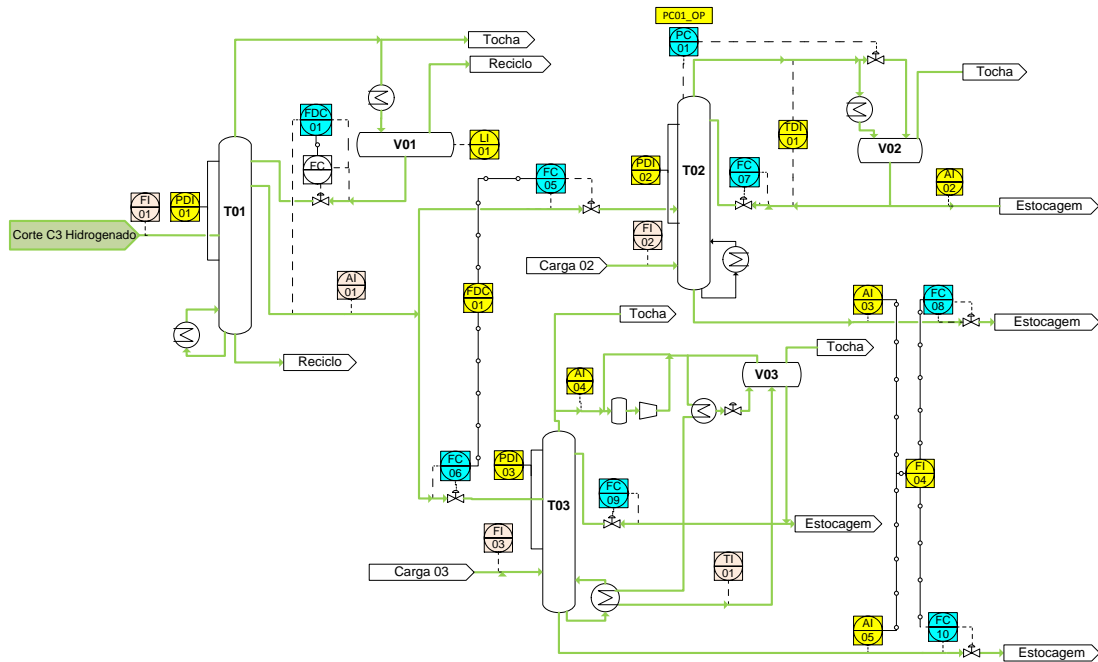


Figura 5.18: Sistema de fracionamento de propeno incluindo a variável TI01.

A Figura 5.19 apresenta o gráfico de tendência das duas variáveis, AI04 e TI01, referente ao segundo período de auditoria. As variáveis já estão transformadas em variáveis-desvio e padronizadas para facilitar a comparação independente da unidade de engenharia. A sobreposição dos gráficos de tendência evidencia que existe alguma correlação entre elas.




Figura 5.19: Gráfico de tendência das duas variáveis AI04 e TI01.

Aplicou-se a metodologia NMDI para avaliar a influência da variável TI01 nos modelos da variável controlada AI04, obtendo-se os resultados da Figura 5.20. Observa-se que o método apontou a correlação entre as variáveis TI01 e AI04 como relevante, ratificando a inclusão da variável no controlador, conforme resultado do artigo.




Figura 5.20: Resultados da metodologia NMDI para avaliar a correlação da variável externa TI01 com a incerteza de modelo da variável AI04

O outro ponto relevante também aparece sutilmente na Figura 5.21, refere-se ao ajuste nos modelos das demais variáveis que podem ser necessários ao inserir um novo modelo na matriz. Para explicar essa necessidade, é preciso entender como o processo de identificação normalmente ocorre.

É usual identificar todos os modelos entre as variáveis de entrada e uma determinada variável de saída simultaneamente, de forma que o erro de modelagem seja distribuído entre todas as variáveis. Ao adicionar uma variável de entrada, o comportamento desta tentará explicar parte do comportamento da variável controlada, impactando no ajuste dos modelos das demais, demandando principalmente ajustes de ganho. A conclusão é que, mesmo sabendo os modelos que efetivamente estão degradando o desempenho do controlador e que são foco do processo de identificação, é natural que ocorram pequenos ajustes de ganhos nos demais modelos da matriz.

Um exemplo dessa situação pode ser retomando-se as Figuras 5.18 (a) e (b). Nota-se que houve ajuste de ganhos nos modelos de todas as variáveis de entrada do controlador após a inclusão da nova variável. Além disso, o modelo referente à variável de entrada FC09, representada como MV7 na referida figura, também sofreu uma alteração de dinâmica, devido à interação entre essa e a nova variável. Ou seja, a parcela da variável controlada que é explicada pela variável TI01 era distribuída entre as demais variáveis utilizadas no modelo original.

6. CONSIDERAÇÕES FINAIS

6.1 CONTRIBUIÇÕES

Com base nos estudos de caso realizados, as principais vantagens da metodologia NMDI apresentada para localização de modelos que estejam afetando o desempenho de controladores preditivos multivariáveis incluem:

- A auditoria dos modelos do controlador é efetuada com base em dados históricos, sem perturbar a planta com testes em linha, de forma que o controlador possa ser monitorado sistematicamente;
- O método é adequado para aplicação em controladores MPC lineares, com variáveis otimizadas ou operando por faixas, implementados em um ambiente de programação, como o MATLABTM (conforme Estudo de Caso do Sistema de Quatro Tanques), ou em pacotes comerciais (conforme aplicação de Caso Industrial);
- Foco na atualização apenas dos modelos que estão afetando o desempenho do controlador, promovendo também um entendimento mais aprofundado das restrições às quais o sistema está submetido.
- Redução da necessidade de testes para identificação de modelos (caso a identificação não seja viável a partir de dados históricos), reduzindo tempo e necessidade de recursos de engenharia e operação para realizar a revisão.
- Minimização do tempo do controlador com desempenho insatisfatório, tanto por detectar os problemas rapidamente devido a um monitoramento sistemático, quanto pelo fato de minimizar o tempo de atualização do controlador, por limitar o escopo necessário.

Os estudos de caso apresentados e discutidos neste trabalho mostram que a combinação do método proposto por BOTELHO, TRIERWEILER *et al.* (2015 a, b, 2016) com o método com base no indicador NMDI, proposto neste trabalho, constitui uma metodologia de avaliação de desempenho do modelo completo para controladores MPC.

No estudo de caso do Sistema de Quatro Tanques, a metodologia NMDI apresentou resultados compatíveis com aqueles obtidos pelo método proposto por BADWE, GUDI e PATWARDHAN (2009) para os cenários de discrepâncias de ganho entre modelo e planta,

identificação de canais nulos que deveriam ser considerados na matriz e para o cenário de avaliação da influência de uma variável externa no desempenho do controlador.

No cenário de discrepância de dinâmica (constante de tempo), a metodologia proposta apresentou bons resultados, embora não se tenha tido sucesso na aplicação do método proposto por BADWE, GUDI e PATWARDHAN (2009), o qual tem a maior dificuldade na sua aplicação decorrente da influência da seleção de ordem dos modelos para descorrelação entre as variáveis nos resultados. Ordens diferentes apresentaram resultados bastantes discrepantes.

O estudo de Caso Industrial comprovou que a utilização em conjunto da metodologia de avaliação da qualidade de modelos proposta por BOTELHO, TRIERWEILER *et al.* (2015a,b,2016) para identificar as variáveis do controlador com incertezas de modelagem relevantes, seguida da metodologia NMDI proposta por este trabalho para localizar o modelo da matriz dinâmica mais correlacionado ao problema de cada variável controlada permite e organizar o escopo do trabalho de revisão de controladores existentes, concentrando o esforço de modelagem apenas naquelas variáveis controladas cujos modelos efetivamente degradem o desempenho do controlador.

O resultado prático foi a identificação de vinte modelos (de uma matriz de cento e quarenta e quatro possibilidades) que estavam afetando o desempenho do controlador, sendo que treze deles correspondiam a modelos nulos no controlador original. Além disso, foi identificada a necessidade da inclusão de uma variável adicional como distúrbio não medido.

A redução do escopo de revisão do controlador propiciou tempo adequado para aprofundar a análise de engenharia nos modelos que estavam efetivamente impactando o desempenho do controlador, aumentando o domínio dos engenheiros sobre o sistema e as restrições a que está submetido. Esse domínio sobre o sistema certamente facilitará a detecção e solução de problemas do controlador em operação e é um diferencial em relação aos mecanismos semi-automatizados de identificação completa do controlador, no qual o aprendizado do engenheiro sobre o sistema acaba sendo mais limitado.

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

- 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 e realizar a atualização do controlador considerando toda a faixa operacional de interesse.

- Obter a matriz S_0 através de simulação no ambiente nativo do controlador para capturar o efeito da sintonia do controlador multivariável, penalidades consideradas no otimizador, etc..
- Definir um ponto de corte para priorizar a revisão das variáveis com maiores discrepâncias (por exemplo: revisar apenas as variáveis com $Ivar_{diag}$ acima de 2). Após, reavaliar o impacto da qualidade dos modelos no desempenho do controlador visando excluir do escopo de revisão aquelas variáveis que estavam mais impactadas pelo reflexo dos problemas de modelagens das demais.
- Utilizar o método para identificação da fonte predominante de incerteza de modelo para as variáveis controladas (BOTELHO, TRIERWEILER, *et al.*, 2015a) para fornecer uma visão geral da causa predominante de incerteza de modelos no controlador e realizar a análise da influência de variáveis externas à matriz de controle após executar as oportunidades de melhoria com as variáveis do controlador identificadas no método, conforme realizado com a variável AI04 do estudo de caso industrial.
- Realizar a avaliação da qualidade de modelos (análise dos indicadores $Ivar$) do controlador revisado, pois ela fornece uma referência de desempenho do controlador que pode ser útil para comparação com as auditorias realizadas ao longo do seu ciclo de vida. Além disso, a função nominal de sensibilidade de saída do controlador, S_0 , cuja determinação constitui o trabalho mais dispendioso para a auditoria, já estará disponível.
- Similarmente ao item anterior, utilizar a metodologia para localização de modelos que ainda precisem ser refinados no projeto de um novo 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 de controladores preditivos baseados em modelo:

- Desenvolver um método padronizado e automatizado para a identificação de função de sensibilidade nominal do controlador. Esta é a etapa mais dispendiosa em relação a tempo e recursos para a aplicação da metodologia e a qualidade deste modelo é fundamental para sucesso da auditoria.

- Avaliar a utilização da metodologia em controladores preditivos multivariáveis industriais não lineares.
- Aumentar a abrangência do método para automaticamente selecionar os períodos em que a variável controlada esteja otimizada ou controlada por faixas dentro de um mesmo período de auditoria (neste trabalho selecionou-se o padrão dominante para cada variável por período).
- Explorar se o uso de técnicas matemáticas para regressão de dados correlacionados possa agregar valor à análise.
- Desenvolver um método para propor um novo modelo para os canais que estejam apresentando problemas de modelagem a partir dos mesmos dados empregados para nas etapas de auditoria e diagnóstico do problema. Esse procedimento irá acelerar consideravelmente a melhoria operacional, uma vez que não será mais necessário se perturbar a planta visando se obter dados para se aprimorar os modelos que estejam causando o mau funcionamento do controlador.
- Caso ainda seja necessário se perturbar a planta que a mesma seja perturbada em malha fechada de forma a tirar a planta o mínimo possível de sua operação normal. Neste se faz necessário o desenvolvimento de um método de projeto de perturbação minimamente invasivo.

7. REFERÊNCIAS

ÅSTROM, K. J.; MURRAY, R. **Feedback systems: an introduction for scientists and engineers**. New Jersey: Princeton University Press, 2002.

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

BADWE, A.; GUDI, R.; PATWARDHAN, R. Detection of model-plant mismatch in mpc applications. **Journal of Process Control**, n. 19, p. 31305-1313, 2009.

BELFIORE, P. **Estatística aplicada a administração, contabilidade e economia com Excel e SPSS**. 1a. ed. Rio de Janeiro: Elsevier Editora Ltda., 2015. 480 p.

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

BOTELHO, V. et al. Assessment of Model-Plant Mismatch by the Nominal Sensitivity Function for Unconstrained MPC. **IFAC-PapersOnLine**, v. 48, n. 8, p. 753-758, Dezembro 2015b.

BOTELHO, V. et al. Estudo comparativo de metodologias para avaliação de modelos de controladores preditivos aplicadas a uma unidade de coqueamento retardado. **Engevista**, v. 17, n. 4, p. 463-476, Dezembro 2015c.

BOTELHO, V. et al. Perspectives and Challenges in Performance Assessment of Model Predictive Control. **The Canadian Journal of Chemical Engineering**, 94, n. 7, Abril 2016.

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time Series Analysis: Forecasting and Control**. 3ª. ed. Englewood Cliffs: Prentice Hal, 1994. 746 p.

CAMPOS, M. C. M. M.; GOMES, M. V. C.; PEREZ, J. M. G. T. **Controle Avançado e Otimização na Indústria do Petróleo**. Rio de Janeiro: Interciência, 2013. 486 p.

CARLSSON, R. **A practical approach to detection of plant model mismatch for mpc**. **Dissertação (Mestrado em Engenharia Elétrica)**. Department of Electrical Engineering, Linköpings Universitet: [s.n.], 2010.

CLARO, É. R. P. et al. Model Performance Assessment of a Predictive Controller for Propylene/Propane Separation. **IFAC-PapersOnLine**, 49, n. 7, 2016. 978-983.

CONNER, J. S.; SEBORG, D. E. Assessing the Need for Process Re-identification. **Industrial & Engineering Chemistry Research**, v. 44, n. 8, p. 2767-2775, 2005.

DAI, C.; YANG, S. H. **Controller performance assessment with a LQG benchmark obtained by using the subspace method**. Proceedings of the Control 2004. University of Bath, UK: [s.n.]. 2004.

DARBY, M. L.; NIKOLAOU, M. MPC: Current Practice and Challenges. **Control Engineering Practice**, v. 20, p. 328-342., 2012.

DECARLO, L. T. On the Meaning and Use of Kurtosis. **Psychological Methods**, 2, n. 3, 1997. 292-307.

DRAPER, N. R.; SMITH, H. **Applied Regression Analysis**. 3a. ed. [S.l.]: Wiley, 1998. 736 p.

DUMONT, G. A. et al. Control system performance monitoring: New developments and practical issues. **IFAC Proceedings Volumes**, v. 35, n. 1, p. 387-392, 2002.

FARENZENA, M.; TRIERWEILER, J. O. Uma visão geral das tecnologias atualmente empregadas em controle avançado de processos industriais. **Revista C&I. Controle & Instrumentação**, São Paulo, SP, v. 123, p. 65-78, 2007.

FORBES, M. G. et al. Model Predictive Control in Industry: Challenges and Opportunities. **IFAC-PapersOnLine**, 48, n. 8, 2015. 531-538.

FUCHS, S. **Desenvolvimento de uma estratégia de controle para colunas de separação de propeno-propano. Trabalho de Conclusão de Curso (Graduação em Engenharia Química)**. Porto Alegre, RS: Universidade Federal do Rio Grande do Sul, 2010.

GARCÍA; C. E. PRETT, D. M.; MORARI, M. Model Predictive Control: Theory and Practice - a Survey. **Automatica**, v. 25, n. 3, p. 335-348, 1989.

GUDI, R. D.; RAWLINGS, J. B. Identification for decentralized model predictive control. **AIChE Journal**, v. 52, n. 6, p. 2198–2210, 2006.

HARRIS, T. Assessment of closed loop performance. **The Canadian Journal of Chemical Engineering**, n. 67, p. 856–861, 1989.

HUANG, B. et al. An investigation into the poor performance of a model predictive control system on an industrial CGO coker. **Control Engineering Practice**, v. 8, p. 619-631, 2000.

HUANG, B.; SHAH, S. L. **Performance Assessment of Control Loops**. Berlin: Springer, 1999.

HUGO, A. Process Controller Performance Monitoring and Assessment. **Control Arts Inc.**, 2002. Disponível em:

<<http://www.controlartsinc.com/Support/Articles/PerformanceAssessment.PDF>>. Acesso em: 18 Abril 2016.

IQBAL, N. H. K.; YUSOFF, N.; TUFA, L. D. Comparison between ARX and FIR Decorrelation Models in Detecting Model-plant Mismatch. **Journal of Applied Sciences**, v. 14, p. 1711-1719, 2014.

JELALI, M. An overview of control performance assessment technology and industrial applications. **Control Engineering Practice**, n. 14, p. 441–466, 2006.

JOHANSSON, K. H. The Quadruple-Tank Process: A Multivariable Laboratory Process with an Adjustable Zero. **IEEE Transactions on Control Systems Technology**, p. 456–465, 2000.

JULIEN, R. H.; FOLEY, M. W.; CLUETT, W. R. Performance assessment using a model predictive control benchmark. **Journal of Process Control**, 2004. 441-456.

LJUNG, L. **System Identification**. 2a. ed. New Jersey: Prentice Hall, 1999.

LOEFF, M. V. **Detecção de divergências entre o processo e o modelo usado no controlador preditivo. Dissertação (Mestrado em Engenharia Química)**. Escola Politécnica da Universidade de São Paulo: Sao Paulo, 2014.

MATHWORKS. **MATLAB Central - Newsgroup: difference between xcorr and crosscorr?**, 2012. Disponível em: <http://www.mathworks.com/matlabcentral/newsreader/view_thread/316589?requestedDomain=www.mathworks.com>. Acesso em: 10 abril 2016.

MATHWORKS. **MATLAB R2016a Documentation: sample cross correlation (crosscorr)**, 2016a. Disponível em: <<http://www.mathworks.com/help/econ/crosscorr.html>>. Acesso em: 18 Abril 2016.

MATHWORKS. **MATLAB R2016a Documentation: cross-correlation (xcorr)**, 2016b. Disponível em: <<http://www.mathworks.com/help/signal/ref/xcorr.html?searchHighlight=xcorr>>. Acesso em: 18 Abril 2016.

MATHWORKS. **MATLAB R2016a Documentation: quadratic programming (quadprog)**, 2016c. Disponível em: <<http://www.mathworks.com/help/optim/ug/quadprog.html>>. Acesso em: Maio 2016.

MATHWORKS. **MATLAB R2016a Documentation: Sawtooth or triangle wave (sawtooth)**, 2016d. Disponível em: <<http://www.mathworks.com/help/signal/ref/sawtooth.html?searchHighlight=sawtooth>>. Acesso em: Abril 2016.

MCNABB, C. A.; QIN, S. J. Projection based MIMO control performance monitoring: II-measured disturbances and setpoint changes. **Journal of Process Control**, 15, n. 1, 2005. 89–102.

MCNABB, C. A.; QIN, A. S. J. Projection based MIMO control performance monitoring: I-covariance monitoring in state space. **Journal of Process Control**, 13, n. 8, 2003. 739–757.

QIN, S. J.; BADGEWELL, T. A. A survey of model predictive control technology. **Control Engineering Practice**, v. 11, p. 733-764, 2003.

SCHÄFER, J.; ÇINAR, A. Multivariable MPC system performance assessment, monitoring, and diagnosis. **Journal of Process Control**, n. 14, 2004. 113-129.

SUN, Z. et al. Performance monitoring of model-predictive controllers via model residual. **Journal of Process Control**, n. 23, 2013. 473– 482.

TIAN, X.; CHEN, G.; CHEN, S. A data-based approach for multivariate model predictive control performance monitoring. **Neurocomputing**, v. 74, p. 588-597, 2011.

TSAI, Y. et al. A Novel Algorithm for Model-Plant Mismatch Detection for Model Predictive Controllers. **IFAC-PapersOnLine**, 48, n. 8, 2015. 746-752.

YU, J.; QIN, S. J. Statistical MIMO controller performance monitoring, partI: data-driven covariance benchmark. **Journal of Process Control**, 18, n. 3-4, 2008a. 277-296.

YU, J.; QIN, S. J. Statistical MIMO controller performance monitoring, partII: performance diagnosis. **Journal of Process Control**, 18, n. 3-4, 2008b. 297-319.

YUAN, Q.; LENNOX, B.; MCEWAN, M. Analysis of multivariable control performance assessment techniques. **Journal of Process Control**, n. 19, 2009. 751–760.

ZAGROBELNY, M. A. **MPC performance monitoring and disturbance model identification. Tese (Doutorado em Engenharia Química). UNIVERSITY OF WISCONSIN-MADISON. 2014.**