

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

**METODOLOGIA PARA ESTIMAR DISTÚRBIOS NÃO MEDIDOS  
APLICADA A SISTEMAS SISO**

DISSERTAÇÃO DE MESTRADO

*Maria Andressa Ferro de Lima*

**Porto Alegre**

**2016**



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

# **METODOLOGIA PARA ESTIMAR DISTÚRBIOS NÃO MEDIDOS APLICADA A SISTEMAS SISO**

*Maria Andressa Ferro de Lima*

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

*Área de concentração:*

Pesquisa e Desenvolvimento de Processos

*Linha de Pesquisa:*

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

**Orientadores:**

**Prof. Dr. Jorge Otávio Trierweiler**

**Prof. Dr. Marcelo Farenzena**

**Porto Alegre**

**2016**



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 *Metodologia para Estimar Distúrbios Não Medidos Aplicada a Sistemas SISO*, elaborada por Maria Andressa Ferro de Lima, como requisito parcial para obtenção do Grau de Mestre em Engenharia.

Comissão Examinadora:



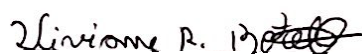
---

Prof. Dr. Celso José Munaro – PPGEE/UFES



---

Profa. Dra. Lucíola Campestrini – PPGEE/UFRGS



---

Dra. Viviane Rodrigues Botelho – DEQUI/UFRGS



## Resumo

Os processos industriais, em geral, estão sujeitos à presença de distúrbios não medidos, estas perturbações influenciam diretamente na eficiência do processo de produção e na qualidade de seus produtos finais. Essas razões tornam a presença de distúrbios não medidos um dos principais problemas de controle tornando-os, assim, um importante elemento na teoria de controle. Porém, existe um problema fundamental no que envolve o estudo destes sinais uma vez que o comportamento temporal dos distúrbios não medidos não é precisamente conhecido nem é possível sua medição direta em tempo real. Em virtude desses aspectos o presente trabalho propõe uma metodologia capaz de estimar o distúrbio não medido presente em uma malha de controle SISO a partir de dados de processo em condição normal de operação, da estrutura e dos parâmetros de ajuste do controlador. São propostas também outras duas metodologias que utilizam o conhecimento do distúrbio não medido estimado, uma delas realiza a identificação do modelo da planta e a outra prediz o potencial de redução de variabilidade, levando em consideração o distúrbio não medido estimado, o modelo da planta identificado e a real estrutura do controlador em operação. A metodologia foi analisada através de estudos de casos envolvendo modelos de planta de primeira e segunda ordem com e sem tempo morto. Através dos resultados foi possível observar uma boa capacidade de estimação dos distúrbios não medidos assim como uma boa qualidade no modelo da planta identificado, via metodologia proposta, medida através de sua capacidade em reprodutibilidade do modelo real da planta e uma boa capacidade de predição da redução de variabilidade das malhas de controle decorrentes de alterações no ajuste do controlador.

**Palavras-chave:** Distúrbios não medidos, Monitoramento de malhas de controle, Auditoria de desempenho, Variabilidade.





## Abstract

Industrial processes are subject to the presence of unmeasured disturbances and their consequent effects. These disturbances have direct influence on the production process progress and the quality of their products. These reasons make the presence of unmeasured disturbances a problem into control theory. However, there is a fundamental problem to study these signals, since the temporal behavior of unmeasured disturbances is not precisely known and its measurement is not possible directly in real time. Due to these aspects, this paper proposes a methodology to estimate the unmeasured disturbance present in a SISO control loop from normal operating data, the controller structure and its tuning parameters. It proposes also two other methodologies that use the knowledge of the unmeasured disturbance estimate. One of these approaches performs the identification of the plant model and the second computes the potential variability reduction estimated taking account the unmeasured disturbance estimate, the identified plant model and the real controller structure. The methodology was analyzed by some case studies involving plant models of first and second order with and without dead time and different unmeasured disturbances. Through the results we observed a good ability to estimate the unmeasured disturbances, as well as a good quality of the identified plant model, measured by its ability to reproduce the actual plant model and a good ability to predict the reduction of the control loop variability obtained by changes on the controller tuning.

**Keywords:** Performance Monitoring, Variability, Loop Maintenance, Unmeasured Disturbance.



*“Para ter algo que você nunca teve é preciso fazer algo que você nunca fez.”  
(Chico Xavier)*



## Agradecimentos

Meus agradecimentos vão para as diversas pessoas que de alguma forma influenciaram na realização desta dissertação.

À Universidade Federal do Rio Grande do Sul e ao departamento de Engenharia Química, pela estrutura disponibilizada e pelo corpo-técnico de excelente qualidade.

Aos meus orientadores Prof. Jorge Otávio Trierweiler e Prof. Marcelo Farenzena, pela sugestão do tema e todo o acompanhamento realizado ao longo do desenvolvimento deste trabalho.

À minha família que mesmo longe sempre me deu força e incentivo para que eu conseguisse alcançar meus objetivos.

A todos os meus amigos de mestrado pela convivência e apoio, em especial ao amigos Adam, Camila, Giovani, José, Juliano e Melissa, que me acompanharam em todos os momentos.

Ao meu companheiro, Leonardo, pela paciência e compreensão com minhas dificuldades e minhas muitas ausências, por me aguentar e, simplesmente, por fazer parte da minha vida.

A todo o pessoal do grupo GIMSCOP, pelas sugestões e momentos de descontração, que tornaram os dias de trabalho mais leves.



## SUMÁRIO

<b>Capítulo 1 – Introdução .....</b>	<b>1</b>
1.1 Motivação.....	2
1.2 Objetivos do Trabalho .....	3
1.3 Estrutura da Dissertação .....	3
<b>Capítulo 2 – Revisão Bibliográfica .....</b>	<b>5</b>
2.1 Distúrbio em Sistemas de Controle.....	5
2.2 Observadores e Estruturas de Compensação de Distúrbios.....	6
2.2.1 Controle Feedback e Feedforward .....	6
2.2.2 Observadores de Distúrbios .....	7
2.3 <i>Internal Model Control (IMC)</i> .....	12
2.4 Estimação de Sinais .....	13
2.4.1 Séries Temporais.....	14
2.4.2 Correlação.....	14
2.4.3 Causalidade.....	15
2.4.4 Regressão Linear.....	17
2.5 Identificação de Sistemas.....	18
2.6 Auditoria de Desempenho em Malhas de Controle .....	22
2.6.1 Variabilidade: Causas e Efeitos.....	23
2.6.2 Índices Baseados em Controladores de Variância Mínima .....	24
2.6.3 Modelo de Inferência para Desempenho e Robustez .....	26
2.6.4 Modelo de Inferência de Variabilidade .....	27
<b>Capítulo 3 – Metodologia Proposta.....</b>	<b>29</b>
3.1 Estimador de Distúrbios não Medidos.....	29
3.2 Identificação Do Modelo Nominal Da Planta.....	35
3.2.1 Identificação Direta em Malha Fechada utilizando o Distúrbio não Medido Estimado – Não intrusiva.....	37
3.2.2 Identificação Direta em Malha Fechada com Perturbação .....	38
3.3 Potencial de Redução de Variabilidade Estimado ( <i>VRE</i> ) .....	39
<b>Capítulo 4 – Estudo de Casos .....</b>	<b>40</b>
4.1 Descrição dos Estudo de Casos .....	40
4.2 Resultados e Discussões.....	42
4.2.1 Estimador de Distúrbios não Medidos .....	43
4.2.2 Identificação do Modelo do Processo .....	52
4.2.3 Determinação do Potencial de Redução de Variabilidade ( <i>VRE</i> ) .....	59
<b>Capítulo 5 – Considerações Finais .....</b>	<b>66</b>
5.1 Conclusões.....	66
5.2 Sugestões para Trabalhos Futuros .....	67
<b>Apêndice A. Métodos de Identificação .....</b>	<b>68</b>
A.1 Métodos Discretos .....	68
A.1.1 Modelo FIR (Finite Impulse Response) .....	69
A.1.2 Modelo ARX .....	70
A.1.3 Modelo ARMAX .....	70
A.1.4 Modelo ARMA .....	71
A.1.5 Modelos de Erro na Saída.....	72
A.1.6 Modelo Box-Jenkins.....	72

A.2	Métodos em Espaço de Estado .....	73
A.3	Métodos com Modos de Operação de Plantas Industriais .....	76
A.3.1	Modo Malha Aberta .....	76
A.3.2	Modo Malha Fechada .....	77
A.3.3	Método Direto .....	77
A.3.4	Métodos Indiretos .....	77
<b>Apêndice B.</b>	<b>Funções de Restrição para os Modelos .....</b>	<b>79</b>
B.1	Modelo Primeira Ordem .....	81
B.2	Modelo Segunda Ordem .....	81
B.3	Modelo Primeira Ordem com Tempo Morto .....	82
B.4	Modelo Segunda Ordem com Tempo Morto .....	82
<b>Apêndice C.</b>	<b>Resultados Gerais .....</b>	<b>84</b>
C.1	Resultados das Análises sobre a eficiência da estimação dos <i>DNMs</i> .....	84
C.1.1	Modelos de Filtro encontrados através do problema de otimização .....	84
C.1.2	Valores da função objetivo do problema de otimização avaliada no ponto inicial e no ponto ótimo .....	87
C.1.3	Valores do índice <i>Fit</i> para as estruturas ARX, Box-Jenkins, N4SID e Filtros identificados .....	90
C.1.4	Valores do índice <i>Fit</i> para as estruturas ARX, Box-Jenkins, N4SID e Filtros identificados através de dados com perturbação .....	114
C.1.5	Valores estimados para a alteração de variabilidades dos sistemas comparados a real alteração de variabilidade .....	116
C.1.6	Erros percentuais entre as máximas alterações de variabilidade estimadas ( <i>VRE1</i> , <i>VRE2</i> e <i>Harris</i> ) e as reais máximas alterações de variabilidade .....	120
<b>Referências</b>	.....	<b>125</b>



## LISTA DE FIGURAS

<b>Figura 2.1:</b> Esquema representativo (a) de uma estrutura de controle <i>feedback</i> . (b) de uma estrutura de controle <i>feedforward</i> . (c) de uma estrutura de controle <i>feedforward-feedback</i> . .....	6
(a).....	8
(b).....	9
<b>Figura 2.2:</b> Diagrama representativo de um observador de distúrbios linear no domínio da frequência para um sistema linear em fase mínima. (a) Formato original. (b) Forma equivalente. (Fonte: Chen <i>et al.</i> , 2015).....	9
<b>Figura 2.3:</b> Estrutura de controle <i>feedback</i> clássica. ....	12
<b>Figura 2.4:</b> Estrutura de controle <i>IMC</i> . ....	12
<b>Figura 2.5:</b> Fluxograma representativa das possibilidades de um modelo bem identificado. ....	22
<b>Figura 2.6:</b> Variabilidade de um processo antes e depois de uma modificação de ajuste. (Fonte: Farenzena, 2008).....	24
<b>Figura 2.7:</b> Representação esquemática do modelo de inferência de variabilidade. (Fonte: Brand, 2009) .....	28
<b>Figura 3.1:</b> Sistema de controle <i>feedback</i> . ....	30
<b>Figura 3.2:</b> Esquema representativo da geração do sinal <i>dud</i> . ....	30
<b>Figura 3.3:</b> Esquema representativo do processo simulado. ....	34
<b>Figura 3.4:</b> Esquema representativo para obtenção do sinal <i>dudi</i> .....	35
<b>Figura 3.5:</b> Esquema representativo do processo simulado iterativo. ....	35
<b>Figura 3.6:</b> Representação da escolha da ordem do modelo <i>N4SID</i> . ....	37
<b>Figura 4.1:</b> Sinais utilizados para representar o <i>DNM d</i> . ....	42
<b>Figura 4.2:</b> Distúrbio estimado, por cada um dos filtros encontrados, comparado ao distúrbio real para a condição de operação OP1. ....	47
<b>Figura 4.3:</b> Distúrbio estimado, por cada um dos filtros encontrados, comparado ao distúrbio real para a condição de operação OP1. ....	47
<b>Figura 4.4:</b> Distúrbio estimado, por cada um dos filtros encontrados, comparado ao distúrbio real para a condição de operação OP2. ....	48
<b>Figura 4.5:</b> Distúrbio estimado, por cada um dos filtros encontrados, comparado ao distúrbio real para a condição de operação OP2. ....	48
<b>Figura 4.6:</b> Distúrbio estimado, por cada um dos filtros encontrados, comparado ao distúrbio real para a condição de operação OP3. ....	49
<b>Figura 4.7:</b> Distúrbio estimado, por cada um dos filtros encontrados, comparado ao distúrbio real para a condição de operação OP3. ....	49
<b>Figura 4.8:</b> Comparação entre a resposta à uma perturbação degrau unitário nos modelos identificados. ....	54
<b>Figura 4.9:</b> Comparação entre a resposta à uma perturbação degrau unitário nos modelos identificados. ....	55
<b>Figura 4.10:</b> Comparação entre a resposta à uma perturbação degrau unitário nos modelos identificados. ....	55
<b>Figura 4.11:</b> Comparação entre a resposta à uma perturbação degrau unitário nos modelos identificados. ....	56
<b>Figura 4.12:</b> Perturbações em malha fechada no processo V. Gráfico superior: <i>setpoint</i> (linha cheia) e saída do processo (linha tracejada). Gráfico intermediário: ação de controle calculada pelo controlador (linha tracejada) e ação total de controle (linha cheia). Gráfico inferior: perturbação adicional aplicada ao <i>u-bias</i> do controlador.....	57

<b>Figura 4.13:</b> Resposta ao degrau unitário dos modelos identificados e do modelo do processo.....	58
<b>Figura 4.14:</b> Resposta ao degrau unitário dos modelos identificados e do modelo do processo.....	59
<b>Figura 4.15:</b> Resposta degrau na mudança de <i>setpoint</i> para as malhas consideradas admitindo $Kp2$ três vezes mais rápido do que $Kp1$ .....	61
<b>Figura 4.16:</b> Comparação de $VRE2$ com a alteração real de variabilidade para o processo VII na presença de $d5$ para alterações somente no parâmetro $Ti$ do controlador.....	64
<b>Figura 4.17:</b> Comparação do perfil de $VRE1$ com o perfil de alteração real de variabilidade para o processo I na presença de $d2$ .....	64
<b>Figura A.1:</b> Representação em diagrama de blocos da estrutura de modelo FIR. ....	69
<b>Figura A.2:</b> Representação em diagrama de blocos da estrutura de modelo ARX. (a) É equivalente ao modelo expresso na Equação A.7 que após algumas manipulações pode ser representado na forma apresentado em (b) que evidencia que o erro não aparece na saída.....	70
<b>Figura A.3:</b> Representação em diagrama de blocos da estrutura de modelo ARMAX. (a) expressa como na Equação A.8 e em (b) após sofrer algumas modificações.....	71
<b>Figura A.4:</b> Representação em diagrama de blocos da estrutura de modelo de erro na saída.....	72
<b>Figura A.5:</b> Representação em diagrama de blocos da estrutura de modelo Box-Jenkins.....	73
<b>Figura A.6:</b> Representação do sistema em malha aberta.....	76
<b>Figura A.7:</b> Representação do sistema em malha fechada.....	77

## LISTA DE TABELAS

<b>Tabela 3.1:</b> Formatos de função de transferência para representar o processo, utilizados para determinação de $Gns$ .....	33
<b>Tabela 3.2:</b> Algoritmo de determinação de $Gn(s)$ e estimação de $d$ .....	35
<b>Tabela 4.1:</b> Modelos de processos utilizados nas análises e suas respectivas sintonias....	41
<b>Tabela 4.2:</b> Modelos de Filtros encontrados para serem aplicados na obtenção de $d$ para os $DNM$ $d1$ , $d2$ , $d3$ e $d4$ no ponto de operação OP3. ....	45
<b>Tabela 4.3:</b> Valor da função objetivo obtida como resultado da otimização para os ponto de operação OP3 com os $DNMs$ $d1$ , $d2$ , $d3$ e $d4$ .....	46
<b>Tabela 4.4:</b> Acuracidade entre os sinais $d$ e $\hat{d}$ , medida através do valor do $RMSE$ para o ponto de operação OP1.....	50
<b>Tabela 4.5:</b> Acuracidade entre os sinais $d$ e $\hat{d}$ , medida através do valor do $RMSE$ para o ponto de operação OP2.....	51
<b>Tabela 4.6:</b> Acuracidade entre os sinais $d$ e $\hat{d}$ , medida através do valor do $RMSE$ para o ponto de operação OP3.....	51
<b>Tabela 4.7:</b> Índice $Fit$ e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal $y$ , para os processos sob o efeito do distúrbio $d1$ .....	53
<b>Tabela 4.8:</b> Índice $Fit$ e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal $w$ , para os processos sob o efeito do distúrbio $d1$ .....	53
<b>Tabela 4.9:</b> Índice $Fit$ para cada um dos modelos identificados, no ponto de operação OP3 sob o efeito de $d1$ , $d2$ , $d3$ e $d4$ .....	58
<b>Tabela 4.10:</b> Valores utilizados para geração de dados utilizados nas análises de validação do $VRE$ . ....	60
<b>Tabela 4.11:</b> Alteração de $Kp$ utilizada para obteção da Figura 4.15.....	61
<b>Tabela 4.12:</b> Percentual de máxima redução de variabilidade estimados comparados à índice de Harris e Alteração real para os processos no ponto de operação OP3 sob os efeitos dos $DNMs$ $d1$ e $d2$ .....	62
<b>Tabela 4.13:</b> Erro relativo percentual entre a máxima redução de variabilidade estimada e a Alteração real para os processos no ponto de operação OP3 sob os efeitos dos $DNMs$ $d1$ e $d2$ . ....	63
<b>Tabela B.1:</b> Relações de sintonia para um controlador PID ideal (Seborg, 2004). ....	79
<b>Tabela C.1:</b> Modelos de Filtros encontrados para serem aplicados na obtenção de $d$ para os $DNM$ $d1$ , $d2$ , $d3$ e $d4$ no ponto de operação OP1. ....	84
<b>Tabela C.2:</b> Modelos de Filtros encontrados para serem aplicados na obtenção de $d$ para os $DNM$ $d5$ , $d6$ , $d7$ e $d8$ no ponto de operação OP1. ....	85
<b>Tabela C.3:</b> Modelos de Filtros encontrados para serem aplicados na obtenção de $d$ para os $DNM$ $d1$ , $d2$ , $d3$ e $d4$ no ponto de operação OP2. ....	85
<b>Tabela C.4:</b> Modelos de Filtros encontrados para serem aplicados na obtenção de $d$ para os $DNM$ $d5$ , $d6$ , $d7$ e $d8$ no ponto de operação OP2. ....	86
<b>Tabela C.5:</b> Modelos de Filtros encontrados para serem aplicados na obtenção de $d$ para os $DNM$ $d1$ , $d2$ , $d3$ e $d4$ no ponto de operação OP3. ....	86
<b>Tabela C.6:</b> Modelos de Filtros encontrados para serem aplicados na obtenção de $d$ para os $DNM$ $d5$ , $d6$ , $d7$ e $d8$ no ponto de operação OP3. ....	87
<b>Tabela C.7:</b> Valor da função objetivo obtida como resultado da otimização para os ponto de operação OP1 com os $DNMs$ $d1$ , $d2$ , $d3$ e $d4$ .....	87
<b>Tabela C.8:</b> Valor da função objetivo obtida como resultado da otimização para os ponto de operação OP1 com os $DNMs$ $d5$ , $d6$ , $d7$ e $d8$ .....	88

<b>Tabela C.9:</b> Valor da função objetivo obtida como resultado da otimização para os ponto de operação OP2 com os <i>DNMs</i> $d_1, d_2, d_3$ e $d_4$ .....	88
<b>Tabela C.10:</b> Valor da função objetivo obtida como resultado da otimização para os ponto de operação OP2 com os <i>DNMs</i> $d_5, d_6, d_7$ e $d_8$ .....	89
<b>Tabela C.11:</b> Valor da função objetivo obtida como resultado da otimização para os ponto de operação OP3 com os <i>DNMs</i> $d_1, d_2, d_3$ e $d_4$ .....	89
<b>Tabela C.12:</b> Valor da função objetivo obtida como resultado da otimização para os ponto de operação OP3 com os <i>DNMs</i> $d_5, d_6, d_7$ e $d_8$ .....	90
<b>Tabela C.13:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal $y$ , para os processos sob o efeito do distúrbio $d_1$ .....	90
<b>Tabela C.14:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal $w$ , para os processos sob o efeito do distúrbio $d_1$ .....	91
<b>Tabela C.15:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal $y$ , para os processos sob o efeito do distúrbio $d_2$ .....	91
<b>Tabela C.16:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal $w$ , para os processos sob o efeito do distúrbio $d_2$ .....	92
<b>Tabela C.17:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal $y$ , para os processos sob o efeito do distúrbio $d_3$ .....	92
<b>Tabela C.18:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal $w$ , para os processos sob o efeito do distúrbio $d_3$ .....	93
<b>Tabela C.19:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal $y$ , para os processos sob o efeito do distúrbio $d_4$ .....	93
<b>Tabela C.20:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal $w$ , para os processos sob o efeito do distúrbio $d_4$ .....	94
<b>Tabela C.21:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal $y$ , para os processos sob o efeito do distúrbio $d_5$ .....	94
<b>Tabela C.22:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal $w$ , para os processos sob o efeito do distúrbio $d_5$ .....	95
<b>Tabela C.23:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal $y$ , para os processos sob o efeito do distúrbio $d_6$ .....	95
<b>Tabela C.24:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal $w$ , para os processos sob o efeito do distúrbio $d_6$ .....	96
<b>Tabela C.25:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal $y$ , para os processos sob o efeito do distúrbio $d_7$ .....	96

<b>Tabela C.26:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal $w$ , para os processos sob o efeito do distúrbio $d7$ .....	97
<b>Tabela C.27:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal $y$ , para os processos sob o efeito do distúrbio $d8$ .....	97
<b>Tabela C.28:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal $w$ , para os processos sob o efeito do distúrbio $d8$ .....	98
<b>Tabela C.29:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal $y$ , para os processos sob o efeito do distúrbio $d1$ .....	98
<b>Tabela C.30:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal $w$ , para os processos sob o efeito do distúrbio $d1$ .....	99
<b>Tabela C.31:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal $y$ , para os processos sob o efeito do distúrbio $d2$ .....	99
<b>Tabela C.32:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal $w$ , para os processos sob o efeito do distúrbio $d2$ .....	100
<b>Tabela C.33:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal $y$ , para os processos sob o efeito do distúrbio $d3$ .....	100
<b>Tabela C.34:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal $w$ , para os processos sob o efeito do distúrbio $d3$ .....	101
<b>Tabela C.35:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal $y$ , para os processos sob o efeito do distúrbio $d4$ .....	101
<b>Tabela C.36:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal $w$ , para os processos sob o efeito do distúrbio $d4$ .....	102
<b>Tabela C.37:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal $y$ , para os processos sob o efeito do distúrbio $d5$ .....	102
<b>Tabela C.38:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal $w$ , para os processos sob o efeito do distúrbio $d5$ .....	103
<b>Tabela C.39:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal $y$ , para os processos sob o efeito do distúrbio $d6$ .....	103
<b>Tabela C.40:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal $w$ , para os processos sob o efeito do distúrbio $d6$ .....	104
<b>Tabela C.41:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal $y$ , para os processos sob o efeito do distúrbio $d7$ .....	104

<b>Tabela C.42:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal $w$ , para os processos sob o efeito do distúrbio $d7$ .....	105
<b>Tabela C.43:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal $y$ , para os processos sob o efeito do distúrbio $d8$ .....	105
<b>Tabela C.44:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal $w$ , para os processos sob o efeito do distúrbio $d8$ .....	106
<b>Tabela C.45:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal $y$ , para os processos sob o efeito do distúrbio $d1$ .....	106
<b>Tabela C.46:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal $w$ , para os processos sob o efeito do distúrbio $d1$ .....	107
<b>Tabela C.47:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal $y$ , para os processos sob o efeito do distúrbio $d2$ .....	107
<b>Tabela C.48:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal $w$ , para os processos sob o efeito do distúrbio $d2$ .....	108
<b>Tabela C.49:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal $y$ , para os processos sob o efeito do distúrbio $d3$ .....	108
<b>Tabela C.50:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal $w$ , para os processos sob o efeito do distúrbio $d3$ .....	109
<b>Tabela C.51:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal $y$ , para os processos sob o efeito do distúrbio $d4$ .....	109
<b>Tabela C.52:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal $w$ , para os processos sob o efeito do distúrbio $d4$ .....	110
<b>Tabela C.53:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal $y$ , para os processos sob o efeito do distúrbio $d5$ .....	110
<b>Tabela C.54:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal $w$ , para os processos sob o efeito do distúrbio $d5$ .....	111
<b>Tabela C.55:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal $y$ , para os processos sob o efeito do distúrbio $d6$ .....	111
<b>Tabela C.56:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal $w$ , para os processos sob o efeito do distúrbio $d6$ .....	112

<b>Tabela C.57:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal $y$ , para os processos sob o efeito do distúrbio $d7$ .....	112
<b>Tabela C.58:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal $w$ , para os processos sob o efeito do distúrbio $d7$ .....	113
<b>Tabela C.59:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal $y$ , para os processos sob o efeito do distúrbio $d8$ .....	113
<b>Tabela C.60:</b> Índice <i>Fit</i> e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal $w$ , para os processos sob o efeito do distúrbio $d8$ .....	114
<b>Tabela C.61:</b> Índice <i>Fit</i> para cada um dos modelos identificados, no ponto de operação OP1 sob o efeito de $d1$ , $d2$ , $d3$ e $d4$ .....	114
<b>Tabela C.62:</b> Índice <i>Fit</i> para cada um dos modelos identificados, no ponto de operação OP1 sob o efeito de $d5$ , $d6$ , $d7$ e $d8$ .....	114
<b>Tabela C.63:</b> Índice <i>Fit</i> para cada um dos modelos identificados, no ponto de operação OP2 sob o efeito de $d1$ , $d2$ , $d3$ e $d4$ .....	115
<b>Tabela C.64:</b> Índice <i>Fit</i> para cada um dos modelos identificados, no ponto de operação OP2 sob o efeito de $d5$ , $d6$ , $d7$ e $d8$ .....	115
<b>Tabela C.65:</b> Índice <i>Fit</i> para cada um dos modelos identificados, no ponto de operação OP3 sob o efeito de $d1$ , $d2$ , $d3$ e $d4$ .....	115
<b>Tabela C.66:</b> Índice <i>Fit</i> para cada um dos modelos identificados, no ponto de operação OP3 sob o efeito de $d5$ , $d6$ , $d7$ e $d8$ .....	116
<b>Tabela C.67:</b> Percentual de máxima redução de variabilidade estimados comparados a índice de Harris e Alteração real para os processos no ponto de operação OP1 sob os efeitos dos <i>DNMs</i> $d1$ e $d2$ .....	116
<b>Tabela C.68:</b> Percentual de máxima redução de variabilidade estimados comparados a índice de Harris e Alteração real para os processos no ponto de operação OP1 sob os efeitos dos <i>DNMs</i> $d3$ e $d4$ .....	116
<b>Tabela C.69:</b> Percentual de máxima redução de variabilidade estimados comparados a índice de Harris e Alteração real para os processos no ponto de operação OP1 sob os efeitos dos <i>DNMs</i> $d5$ e $d6$ .....	117
<b>Tabela C.70:</b> Percentual de máxima redução de variabilidade estimados comparados a índice de Harris e Alteração real para os processos no ponto de operação OP1 sob os efeitos dos <i>DNMs</i> $d7$ e $d8$ .....	117
<b>Tabela C.71:</b> Percentual de máxima redução de variabilidade estimados comparados a índice de Harris e Alteração real para os processos no ponto de operação OP2 sob os efeitos dos <i>DNMs</i> $d1$ e $d2$ .....	117
<b>Tabela C.72:</b> Percentual de máxima redução de variabilidade estimados comparados a índice de Harris e Alteração real para os processos no ponto de operação OP2 sob os efeitos dos <i>DNMs</i> $d3$ e $d4$ .....	118
<b>Tabela C.73:</b> Percentual de máxima redução de variabilidade estimados comparados a índice de Harris e Alteração real para os processos no ponto de operação OP2 sob os efeitos dos <i>DNMs</i> $d5$ e $d6$ .....	118
<b>Tabela C.74:</b> Percentual de máxima redução de variabilidade estimados comparados a índice de Harris e Alteração real para os processos no ponto de operação OP2 sob os efeitos dos <i>DNMs</i> $d7$ e $d8$ .....	118

<b>Tabela C.75:</b> Percentual de máxima redução de variabilidade estimados comparados a índice de Harris e Alteração real para os processos no ponto de operação OP3 sob os efeitos dos <i>DNMs</i> <i>d1</i> e <i>d2</i> .	119
<b>Tabela C.76:</b> Percentual de máxima redução de variabilidade estimados comparados a índice de Harris e Alteração real para os processos no ponto de operação OP3 sob os efeitos dos <i>DNMs</i> <i>d3</i> e <i>d4</i> .	119
<b>Tabela C.77:</b> Percentual de máxima redução de variabilidade estimados comparados a índice de Harris e Alteração real para os processos no ponto de operação OP3 sob os efeitos dos <i>DNMs</i> <i>d5</i> e <i>d6</i> .	119
<b>Tabela C.78:</b> Percentual de máxima redução de variabilidade estimados comparados a índice de Harris e Alteração real para os processos no ponto de operação OP3 sob os efeitos dos <i>DNMs</i> <i>d7</i> e <i>d8</i> .	120
<b>Tabela C.79:</b> Erro relativo percentual entre a máxima redução de variabilidade estimada e a Alteração real para os processos no ponto de operação OP1 sob os efeitos dos <i>DNMs</i> <i>d1</i> e <i>d2</i> .	120
<b>Tabela C.80:</b> Erro relativo percentual entre a máxima redução de variabilidade estimada e a Alteração real para os processos no ponto de operação OP1 sob os efeitos dos <i>DNMs</i> <i>d3</i> e <i>d4</i> .	121
<b>Tabela C.81:</b> Erro relativo percentual entre a máxima redução de variabilidade estimada e a Alteração real para os processos no ponto de operação OP1 sob os efeitos dos <i>DNMs</i> <i>d5</i> e <i>d6</i> .	121
<b>Tabela C.82:</b> Erro relativo percentual entre a máxima redução de variabilidade estimada e a Alteração real para os processos no ponto de operação OP1 sob os efeitos dos <i>DNMs</i> <i>d7</i> e <i>d8</i> .	121
<b>Tabela C.83:</b> Erro relativo percentual entre a máxima redução de variabilidade estimada e a Alteração real para os processos no ponto de operação OP2 sob os efeitos dos <i>DNMs</i> <i>d1</i> e <i>d2</i> .	122
<b>Tabela C.84:</b> Erro relativo percentual entre a máxima redução de variabilidade estimada e a Alteração real para os processos no ponto de operação OP2 sob os efeitos dos <i>DNMs</i> <i>d3</i> e <i>d4</i> .	122
<b>Tabela C.85:</b> Erro relativo percentual entre a máxima redução de variabilidade estimada e a Alteração real para os processos no ponto de operação OP2 sob os efeitos dos <i>DNMs</i> <i>d5</i> e <i>d6</i> .	122
<b>Tabela C.86:</b> Erro relativo percentual entre a máxima redução de variabilidade estimada e a Alteração real para os processos no ponto de operação OP2 sob os efeitos dos <i>DNMs</i> <i>d7</i> e <i>d8</i> .	123
<b>Tabela C.87:</b> Erro relativo percentual entre a máxima redução de variabilidade estimada e a Alteração real para os processos no ponto de operação OP3 sob os efeitos dos <i>DNMs</i> <i>d1</i> e <i>d2</i> .	123
<b>Tabela C.88:</b> Erro relativo percentual entre a máxima redução de variabilidade estimada e a Alteração real para os processos no ponto de operação OP3 sob os efeitos dos <i>DNMs</i> <i>d3</i> e <i>d4</i> .	123
<b>Tabela C.89:</b> Erro relativo percentual entre a máxima redução de variabilidade estimada e a Alteração real para os processos no ponto de operação OP3 sob os efeitos dos <i>DNMs</i> <i>d5</i> e <i>d6</i> .	124



<b>Tabela C.90:</b> Erro relativo percentual entre a máxima redução de variabilidade estimada e a Alteração real para os processos no ponto de operação OP3 sob os efeitos dos <i>DNMs</i> <i>d7</i> e <i>d8</i> . .....	124
--	-----



## NOTAÇÃO E SIMBOLOGIA

ADRC	<i>Active Disturbance Rejection Control</i>
$CV_{AR}$	Área da curva da variável controlada
$MV_{AR}$	Área da curva da variável manipulada
AR	Auto regressivo
ARX	Auto regressivo com entrada exógena
ARMA	Auto regressivo com média móvel
ARMAX	Auto regressivo com média móvel e entrada exógena
$r$	Coefficiente de correlação linear de Person
PI	Controlador com ação proporcional e integral
PID	Controlador com ação proporcional, integral e derivativa
CVM	Controlador de variância mínima
$\Delta G(s)$	Discrepância de modelos
DOBC	<i>Disturbance Observer Based Control</i>
DUEA	<i>Disturbance/Uncertain Estimation and Attenuation</i>
$DNM$	Distúrbio não medido
$\hat{d}$	Distúrbio não medido estimado
ESO	<i>Extend State Observer</i>
FCOR	<i>Filtering and Correlation</i>
FIR	<i>Finite Impulse response</i>
$V$	Função perda
$H(q)$	Função racional que representa o modelo da dinâmica do processo
$G(q)$	Função racional que representa o modelo do ruído do processo
$t_{uni}$	Índice de ajuste
$\eta(\Phi)$	Índice de Harris
$n_{ose}$	Índice de ruído
$d_{eli}$	Índice de tempo morto
$\kappa(\Phi)$	Índice de Variância Mínima
IMC	<i>Internal Model Control</i>
$Gp(s)$	Modelo da planta
$C(s)$	Modelo de controlador
MIV	Modelo de Inferência de Variabilidade
DOB	Observadores de distúrbios

$A, B, C, D$ e $F$	Polinômios dos modelos discretos
$V_A$	Potencial de alteração de variabilidade
$VRE$	Potencial de redução da variabilidade estimado
$RMSE$	<i>Root mean squared error</i>
$v(t)$	Ruído
PRBS	Sequência pseudoaleatória binária
$u(t)$	Sinal de entrada
$y(t)$	Sinal de saída
SISO	Sistema monovariável (Single-Input-Single-Output)
$\Phi$	Tempo de atraso
$\sigma_y^2$	Variância atual do processo
$\sigma_{MV}^2$	Variância mínima

## Capítulo 1 – Introdução

Distúrbios não medidos estão presentes amplamente nos processos industriais e isto influencia diretamente na eficiência e na qualidade do produto final destes processos. O termo distúrbio pode ser encontrado como uma notação generalizada para simbolizar efeitos sobre a planta, de natureza tanto interna como externa, o que pode gerar algum tipo de confusão, porém, em geral esse termo refere-se à ação de forças externas sobre a malha de controle (Gao, 2014). Neste trabalho o termo distúrbio não medido (*DNM*) será utilizado somente para expressar sinais oriundos de fontes externas ao sistema e que não podem ser controladas pelo sistema de controle, tais como mudanças de temperatura causadas por mudanças climáticas, alterações de composição de alimentação ou nas taxas de fluxo, etc.

A presença de distúrbios não medidos pode gerar efeitos adversos dentro do sistema de controle podendo comprometer o desempenho e até a estabilidade das malhas de controle (Chen *et al.*, 2015). A utilização de *DNMs* de forma explícita poderia permitir melhorias no desempenho de malhas de controle (Åström e Hägglund, 1995). Neste ponto, porém, existem problemas fundamentais uma vez que este tipo de distúrbio não pode ser diretamente predito (Ljung, 1998), ou seja, não é possível como base em modelo estimado prever de forma confiável seu comportamento.

Uma forma intuitiva para conseguir utilizar os *DNMs* explicitamente é através de sua estimação através de variáveis mensuráveis. Essa possibilidade tem encorajado pesquisas que buscam, em geral, minimizar o efeito dos *DNMs* sobre os sistemas de controle (Johnson, 2008; Han, 2009; Guo e Cao, 2014; Li *et al.*, 2014). Na literatura, estes tipos de técnicas podem ser agrupadas como *Disturbance/Uncertain Estimation and Attenuation* (Chen *et al.*, 2015), dentre as quais é possível destacar o grupo dos observadores de distúrbios. Essas técnicas usam um sinal estimado do distúrbio para auxiliar a ação de controle tornando o sistema mais insensível à ação desses distúrbios. A ação de compensação, para amortizar o efeito do distúrbio, é calculada através de uma estrutura acoplada à estrutura de controle *feedback*, a qual é basicamente formado por um filtro estável baseado no modelo da planta (Li *et al.*, 2014). Essas técnicas vem sendo desenvolvidas desde a década de 60 e podem ser encontradas na literatura como ferramentas capazes de estimar *DNMs*, porém são na verdade estruturas compensadoras acopladas à malha de controle principal onde a estimação do *DNM* é realizada através de ação direta na malha de controle.

A característica intrusiva e a necessidade de alterações na estrutura de controle acabam limitando e até mesmo inviabilizando a aplicação dessas técnicas nos sistemas de controle que já se encontram em operação.

Uma estimativa confiável do *DNM* pode ser utilizada, também, para auditoria de malhas de controle. Uma vez que esses sinais tem influência direta na saída do processo seria possível utilizar de seu conhecimento no desenvolvimento de índices de desempenho, tais como os baseados na variabilidade das malhas de controle. Dentre os índices de auditoria de desempenho em malhas de controle que utilizam a variabilidade como métrica é possível destacar os índices baseados em controladores de variância mínima, tais como o índice de *Harris* (Harris, 1989) que permite uma estimativa da variância mínima através de dados de processo em operação normal e do conhecimento do tempo morto do processo. Porém, índices baseados na teoria de controladores de variância mínima podem não expressar realisticamente o potencial de redução de variabilidade uma vez que não levam em consideração as reais limitações do processo tal como a estrutura do controlador em operação e o efeito dos *DNMs* que atuam na malha.

Uma estimativa do *DNM* pode ser utilizada, também, em técnicas de identificação, uma vez que as técnicas tradicionais de identificação de sistemas são realizadas a partir de dados de entrada e saída assumindo que todas as entradas do sistema são conhecidas e que qualquer entrada desconhecida é caracterizada como ruído branco puro ou filtrado. Entretanto essas premissas tornam estes métodos ineficazes em casos onde nem todas as entradas do sistema são conhecidas ou também nas situações onde o tipo de distúrbio em atuação não pode ser aproximado como um ruído branco puro ou filtrado. Esses distúrbios podem, por exemplo, possuir intensidade suficiente para dominar a resposta do sistema, não existindo assim garantias de modelos identificados coerentes com o processo quando *DNMs* destes tipos estão presentes no sistema. Neste caso, os modelos identificados através destas técnicas podem não conseguir expressar realisticamente as características, dinâmica e estática, do processo que se deseja identificar.

Devido ao impacto dos *DNMs* nos processo e possíveis aplicações para a estimação destes sinais o presente trabalho apresenta uma ferramenta capaz de estimar o sinal referente ao *DNM* de forma não intrusiva, em sistemas lineares monovariáveis (SISO, do inglês - *Single-Input-Single-Output*). Com base no *DNM* estimado propõe-se um método de identificação de sistemas dinâmicos, livre de distúrbios (i.e., é pretendido identificar o modelo da planta) quando na presença de distúrbios não medidos. Além disso, é proposto também uma técnica de auditoria de controladores que visa predizer o potencial de redução de variabilidade da variável controlada, decorrente de alterações no desempenho do controlador. Para estes objetivos o trabalho desenvolvido assume que as únicas informações conhecidas são as medidas de um sinal de excitação de controle, neste caso a ação do controlador e a resposta do sistema, coletadas sem qualquer ação intrusiva. A resposta do sistema por sua vez é corrompida devido a um distúrbio não medido.

## 1.1 Motivação

Os distúrbios não medidos são responsáveis por grande parte dos problemas de controle, o que evidencia a importância de estudos relacionados à sua investigação e o

desenvolvimento de ferramentas que auxiliem ações que minimizem seus efeitos prejudiciais nos processos.

Devido ao impacto dos *DNMs* nas variáveis de processo seu conhecimento pode ser visto como uma peça fundamental na avaliação do desempenho do sistema e de grande utilidade em auditoria de malhas de controle. A partir do conhecimento do comportamento (tendência) e de características (como amplitude, frequência, média, variância, etc.) dos *DNMs* é possível então estabelecer estratégias de controle que visam uma melhoria nos sistemas de controle que, por sua vez, pode ser diretamente convertida em um maior retorno econômico para este processo.

## 1.2 Objetivos do Trabalho

O presente trabalho ilustra a influência e a importância da identificação dos distúrbios não medidos dentro dos processos, tendo como foco principal o desenvolvimento de uma ferramenta capaz de realizar a estimação destes distúrbios, de forma não intrusiva, dispensando assim qualquer tipo de perturbação no processo. Esta ferramenta é denominada de estimador de distúrbios não medidos.

O trabalho apresenta também outras duas metodologias que utilizam o conhecimento do *DNM* estimado e podem ser utilizadas para o aperfeiçoamento do sistema de controle visando um aumento da eficiência do processo. A primeira descreve uma alternativa para identificação do modelo de planta em malha fechada, nas atuais condições operacionais.

A segunda metodologia apresenta a obtenção de um índice capaz de estimar o potencial de redução da variabilidade (*VRE*) da malha de controle tendo como métrica base a variância da variável de saída do processo. O índice é calculado através de uma relação direta entre a variância atual do sinal de saída do processo e a variância predita para esta variável, obtida por simulação através de uma mudança específica nos parâmetros do controlador. Devido à relação existente entre variabilidade, desempenho e eficiência é possível obter, por meio do índice *VRE*, uma estimativa para o potencial de melhoria ou deterioramento do processo, decorrentes de alterações no controlador sem a necessidade de nenhum tipo de ação intrusiva. Vale ressaltar que índices deste tipo são de natureza intrusiva em sua maioria.

Todas as metodologias que serão apresentadas foram desenvolvidas visando uma aplicação simples, rápida e de forma não intrusiva, que dispensasse a necessidade de qualquer tipo de perturbações no sistema.

## 1.3 Estrutura da Dissertação

Este trabalho está dividido em cinco capítulos. O Capítulo 1 descreve a motivação por trás do desenvolvimento deste trabalho. Traz também o objetivo e a estruturação dos capítulos constituintes.

O Capítulo 2 apresenta a importância dos distúrbios dentro do cenário industrial e descreve os principais conceitos encontrados na literatura, que estão relacionados ou foram utilizados para elaboração dos métodos apresentados. Esses englobam métodos de identificação, estruturas de controle e índices de desempenho e robustez.

No Capítulo 3 é descrito o método proposto para estimação de distúrbios não medidos. Nele também são detalhadas outras duas metodologias complementares

utilizadas a partir do sinal estimado do distúrbio não medido. O primeiro método apresenta uma alternativa para identificação do modelo do processo de forma não intrusiva. A segunda metodologia complementar descreve a obtenção do índice de redução de variabilidade estimado (*VRE*).

No Capítulo 4 são testadas e validadas as metodologias desenvolvidas e apresentadas neste trabalho. Utilizando estruturas de controle *feedback* com controladores do tipo proporcional integral derivativo (PID - do inglês *proportional integrate derivative*), através de cenários formados por dois tipos de distúrbios não medidos aplicados separadamente em quatro modelos de processo pré-definidos.

O Capítulo 5 reúne as principais conclusões obtidas através das análises dos resultados obtidos, dispostos no Capítulo 4. Apresenta também algumas sugestões que podem ser realizadas com o intuito de aperfeiçoar as técnicas aqui desenvolvidas, servindo como temas para possíveis trabalhos futuros.



## Capítulo 2 – Revisão Bibliográfica

Este capítulo traz uma revisão bibliográfica acerca dos principais tópicos relacionados e utilizados para o desenvolvimento deste trabalho.

### 2.1 Distúrbio em Sistemas de Controle

De acordo com Ljung (1998) o termo distúrbio reúne os sinais desconhecidos, que afetam de forma indesejada a saída do sistema, os quais resultam em excitações externas, podendo ser representados como sinais de entrada no sistema. O efeito dos distúrbios sobre o sistema é difícil de ser quantificado, e conseqüentemente controlado, devido a sua natureza estocástica (Ljung, 1998). Åström e Wittenmark (2013) trazem algumas soluções para redução dos efeitos de distúrbios em processos, dentre as quais se pode destacar a utilização de controle *feedback* ou *feedforward* (a partir de distúrbios medidos), a utilização de predições para estimação de distúrbios não medidos, ações sobre suas fontes causadoras (tais como redução em variações de composição de mistura, reposicionamento dos sensores para posições onde existem perturbações menores ou a troca do sensor eletrônico para reduzir o ruído, etc.), entre outras medidas.

#### Distúrbios Não Medidos

Os distúrbios não medidos (*DNMs*) compreendem aqueles fatores que interferem no processo, porém sua quantificação ou medição não se faz de forma direta, seja por apresentar uma medição onerosa ou por uma medição direta não realizável (Duraiski, 2001). Nestes casos, o controlador deve ter a robustez necessária para compensar os efeitos destes eventos levando em conta apenas as variáveis que são medidas. Uma medida bastante comum para amenizar o efeito de distúrbios não medidos é realizar o projeto objetivando um controlador capaz de manter o sistema estável considerando a ação de um distúrbio na carga, em outras palavras um distúrbio na variável manipulada.

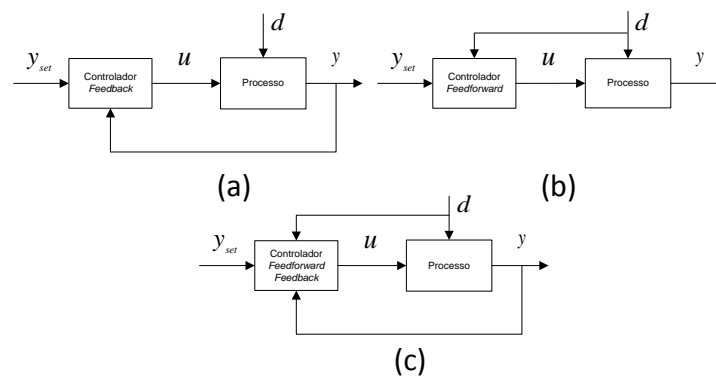
A sensibilidade dos processos industriais em relação à ação dos *DNMs* e seus efeitos motivam o estudo de técnicas que viabilizem a estimação destes sinais. O que, dentre outras possibilidades, permitiria a utilização deste conhecimento para o reajuste do controlador buscando minimizar o seu efeito na variável de saída (Åström e Wittenmark, 2013).

## 2.2 Observadores e Estruturas de Compensação de Distúrbios

Em teoria clássica de controle, uma série de técnicas foram desenvolvidas para modelar e acomodar a presença de distúrbios através das estruturas de controle (Johnson, 1986). Um dos principais motivos da utilização de controladores em processos industriais é devido à necessidade de manter o processo estável e respeitando suas faixas operacionais. Como bem sabido, a presença de distúrbios influencia na atividade do processo o que traz a necessidade de um sistema de controle capaz de rejeitar tal influência, sendo este um dos motivos de se trabalhar com controle *feedback* e/ou *feedforward*. No entanto com a teoria de controle moderna de sistemas multivariáveis, tais técnicas tornaram-se limitadas, fazendo despertar novas pesquisas. A necessidade de modelar e acomodar distúrbios multivariáveis em problemas de controle em espaço de estados levou a uma série de pesquisas (Johnson, 1971; Skelton e Likins, 1978; Kelly, 1979), que culminaram em uma ampla teoria geral conhecida como *Disturbance Accomodation Control* (DAC). Dentro dessa teoria nasceram os observadores de distúrbios. A seguir será apresentado um pouco mais a respeito das teorias clássicas e modernas para o tratamento de distúrbios não medidos.

### 2.2.1 Controle Feedback e Feedforward

Dentre as principais estratégias de controle clássico estão a configuração de controle *feedback* (retroalimentável) e *feedforward* (antecipativo). Por definição a primeira destas utiliza apenas o valor medido da variável controlada para o ajuste da variável manipulada, conforme esquematizado na Figura 2.1 (a). Uma importante vantagem do controle *feedback* é que a ação corretiva ocorre independentemente da fonte de distúrbio. A capacidade de lidar com distúrbios de origem desconhecida é uma das principais razões pela qual esta estratégia é uma das mais aplicadas. A segunda configuração, esquematizada na Figura 2.1 (b), utiliza a medida de uma variável que representa o distúrbio para o ajuste da variável manipulada, neste tipo de configuração são tomadas medidas corretivas antes da variável controlada ser desviada de seu *setpoint*, uma vez que a ação corretiva é calculada para cancelar os efeitos do distúrbio de modo que a variável controlada não seja afetada. Este tipo de cancelamento, em geral, não pode ser feito de forma ideal, porém ainda assim o controle *feedforward* pode reduzir significativamente os efeitos dos distúrbios medidos.



**Figura 2.1:** Esquema representativo (a) de uma estrutura de controle *feedback*. (b) de uma estrutura de controle *feedforward*. (c) de uma estrutura de controle *feedforward-feedback*.

Uma abordagem mais prática é a utilização de um sistema de controle *feedforward* combinado com o sistema de controle *feedback*, onde o controle *feedback* fornece uma ação corretiva para distúrbios não medidos. O controle *feedforward* reage para eliminar os distúrbios medidos antes da variável controlada ser perturbada. Este tipo de configuração de estrutura de controle pode ser representado conforme mostrado na Figura 2.1 (c).

O controle *feedback* pode ser usado para reduzir os efeitos de distúrbios não medidos no desempenho do sistema de controle. Quando o sistema de controle não cumpre os seus objetivos de projeto, então as causas para tal comportamento devem ser investigadas. De acordo com Harris, Seppala e Desborough (1999) estas causas podem incluir:

- I. O fato do sistema de controle em malha fechada não conseguir atingir o desempenho desejado devido a presença de distúrbios, limitações das variáveis manipuladas, tempo morto, ou outras características dinâmicas tais como fatores de fase não mínima.
- II. O ajuste do controlador, ter se tornado inapropriado devido a mudanças na dinâmica do processo ou à presença de distúrbios.
- III. Desgaste, mau funcionamento ou falha de *hardware* no sistema de controle, por exemplo, sensores ou elementos de controle.

Como soluções reparadoras a fim de reestabelecer um bom desempenho do sistema de controle pode-se incluir (Harris *et al.*, 1999):

- I. Ajuste dos parâmetros do controlador;
- II. Manutenção de *hardware* do controlador;
- III. Implementação de algoritmos alternativos de controle *feedback*;
- IV. Modificações no processo a fim de reduzir ou eliminar o tempo morto, o uso de controle *feedforward*, o uso de variáveis manipuladas alternativas, ou a eliminação de distúrbios do processo através de modificações no processo.

### 2.2.2 Observadores de Distúrbios

Os observadores de distúrbios (DOB) (Ohishi *et al.*, 1987) têm como principal função a extração de informações a respeito de variáveis não medidas, ao longo do processo, para um vasto número de aplicações, incluindo controle retroalimentado (Chen, 1995) e monitoramento de sistemas (Gertler, 1988). Nos últimos 90 anos, duas classes de estruturas de observadores surgiram. Uma se baseia na utilização de modelos matemáticos das plantas para estimar estados e outra usa o conhecimento da planta para estimar a parte do processo físico que não é descrita no modelo da planta, ou seja, os distúrbios não medidos e as incertezas de modelo (Radke, 2006).

A primeira classe contou, nos últimos anos, com aperfeiçoamentos graduais na estrutura de seus observadores. De forma geral, uma melhor estimação de estados pode ser obtida através da incorporação de informações mais precisas sobre a planta no observador. Tais informações incluem o conhecimento de ruídos e distúrbios

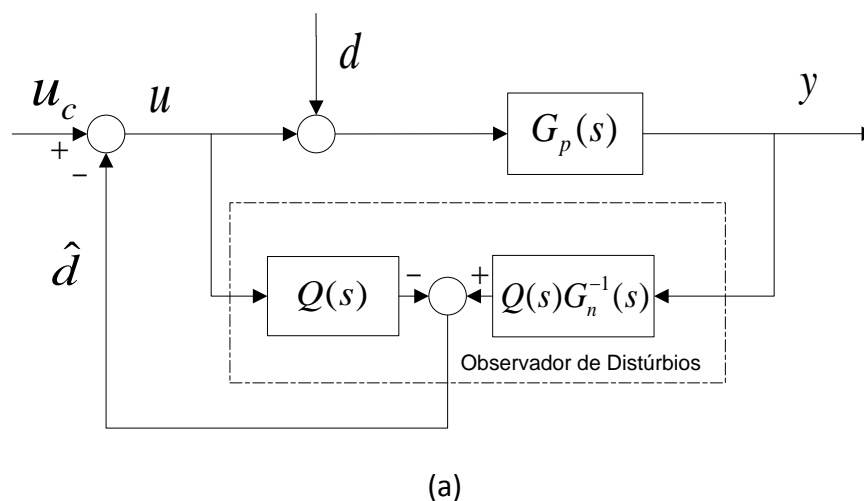
caracterizados através de descrições determinísticas, diferenciais, polinomiais e estocásticas. Consequentemente muitos destes conhecimentos foram propostos sob o custo de informações detalhadas do modelo (Radke, 2006).

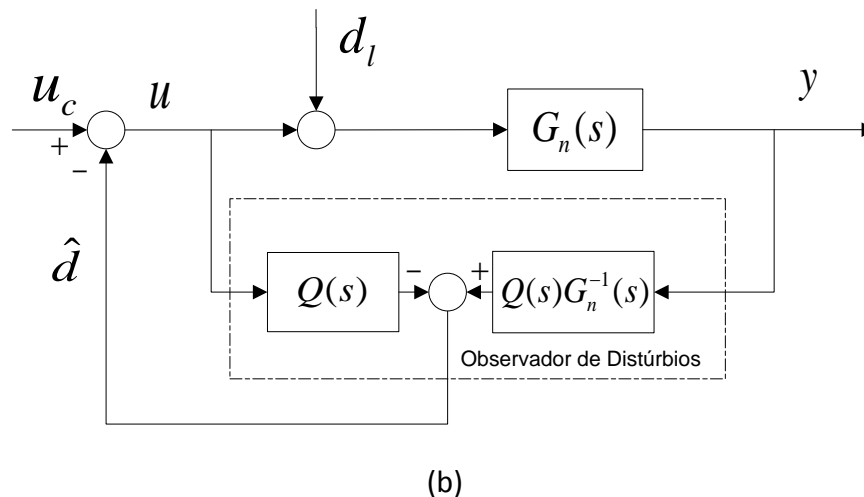
No entanto, a presunção a respeito desta classe de observadores não reflete na prática a realidade da indústria, pois em muitos casos um modelo matemático preciso de uma planta é indisponível. Este dilema motiva a pesquisa por métodos que reduzam a dependência da modelagem matemática nos estimadores de distúrbios (Han, 1989).

A segunda classe, baseada em estimadores de distúrbios, apresentou pouco investimento nos últimos anos em comparação com a primeira classe (Radke, 2006). Alguns trabalhos discutem as classes (Kwon e Chung, 2002; Schrijver e Van Dijk, 2002; Kwon e Chung, 2003), porém não mencionam as diferenças entre elas.

Dentre os modelos de observadores de distúrbios encontrados na literatura pode-se destacar o *Disturbance Observer Based Control* (DOBC), *Active Disturbance Rejection Control* (ADRC), *Disturbance Accommodation Control* (Johnson, 1986) e o *Composite Hierarchical Anti-Disturbance Control* (CHADC). Em todos estes métodos as incertezas são, em geral, admitidas como um sinal aglomerado constituído das incertezas internas, tal como erros de modelagem, e dos distúrbios não medidos, onde seus efeitos são somados sendo representados através de um único sinal. Desta forma o mecanismo de observação é construído para estimar a incerteza total (Li *et al.*, 2014). Alguns autores denotam frequentemente estas incertezas simplesmente como distúrbios, no entanto como já discutido anteriormente é possível encontrar uma distinção entre estes termos.

O conceito envolvido por trás da formulação de um compensador/estimador de distúrbios/incertezas pode ser ilustrada através do conceito aplicado a um DOBC linear simples representado conforme a Figura 2.2.





**Figura 2.2:** Diagrama representativo de um observador de distúrbios linear no domínio da frequência para um sistema linear em fase mínima. (a) Formato original. (b) Forma equivalente. (Fonte: Chen *et al.*, 2015)

onde  $u_c$  representa ação de controle calculada pelo controlador *feedback*,  $G_p(s)$  representa a planta física,  $G_n(s)$  é o modelo nominal usado no projeto do controlador,  $Q(s)$  é um filtro estável,  $c$  é a saída do controlador *feedback*,  $u$  é o sinal da variável manipulada,  $y$  é o saída do sistema,  $d$  é o distúrbio não medido,  $d_l$  é o distúrbio total, e  $\hat{d}_l$  é o distúrbio total estimado.

Pode ser visto da Figura 2.2 que na ausência de  $d$  e incertezas de modelo (ou seja  $G_n(s)$  é igual a  $G(s)$ ) o ciclo interno com a estimativa do distúrbio e o correspondente mecanismo de compensação não está ativo. Desta forma, o controlador pode ser ajustado, de acordo com o desempenho desejado e critérios de estabilidade enquanto a malha interna é desenhada para rejeição de distúrbios e compensação de incertezas. Estes dois requisitos podem ser satisfeitos através da concepção separada da malha *feedback* normal e o mecanismo de atenuação na malha interna. Por exemplo, a ação integral foi introduzida aos controladores PID para melhorar a rejeição a distúrbios e a robustez, mas isto também aumenta o *overshoot* comprometendo a estabilidade do sistema. Além disto, a maior parte dos métodos de controle robusto é baseada nos piores casos onde o desempenho nominal é sacrificado para uma melhor robustez. Como mostrado na Figura 2.2, o desempenho nominal é preservado no caso de ausência de distúrbios desde que a malha interna não seja ativada, reduzindo o sistema a um estrutura clássica *feedback* (Chen *et al.*, 2015).

Como a metodologia por trás de um DOB é bastante intuitiva e eficaz, alguns pesquisadores desenvolveram técnicas que se baseiam neste conceito. Dentre as quais é possível destacar *Disturbance Accommodation Control* (DAC) (Johnson, 1986), *Perturbation Observer* (Kwon e Chung, 2003), *Equivalent Input Disturbance* (She *et al.*, 2008) baseado em estimadores, *Extend State Observer* (ESO) (Han, 1995), *Uncertainty and Disturbance Estimator* (Zhong *et al.*, 2011) e o *Generalized Proportional Integral Observer* (Sira-Ramirez e Oliver-Salazar, 2013).

O DOB foi proposto por Ohishi, Ohnishi e Miyachi (1983) com o objetivo de melhorar a velocidade do sistema de controle através da estimação do torque presente no processo. O ESO por sua vez foi inicialmente proposto por Han (1995) em sua busca pelo desenvolvimento de uma alternativa prática para o método de controle clássico PID. Este

método é geralmente considerado como uma parte fundamental da chamada *Active Disturbance Rejection Control*, a qual foi desenvolvida para estimar o distúrbio total do sistema, consistindo de incertezas de modelo e distúrbios não medidos (Han, 2009).

De acordo com Chen et al. (2015) todas as técnicas mencionadas anteriormente podem ser agrupadas como técnicas de *Disturbance/Uncertain Estimation and Attenuation* (DUEA). O autor ainda informa que para estimativa de distúrbios o DOB, DAC e ESO são as mais estudadas e aplicadas.

Como mencionado, existem muitas técnicas de estimadores lineares de distúrbios e incertezas. A seguir é apresentada a metodologia desenvolvida para observadores de distúrbios no domínio da frequência.

### Observadores de Distúrbios no domínio da frequência

O DOB no domínio da frequência foi proposto por Ohishi *et al.* (1987) como mostrado na Figura 2.2. Assumindo que o sistema controlado possui um modelo de planta de fase mínima, a saída do processo pode ser representada como:

$$y = G_p(s)[u + d] \quad (2.1)$$

O diagrama de blocos do DOB no domínio da frequência representado na Figura 2.2, onde  $G_n(s)$  é o modelo nominal da planta e  $Q(s)$  é o filtro do DOB. Note que o DOB pode estimar não somente o distúrbio externo como também o distúrbio interno causado por incertezas de modela (erros de modelagem). Para mostrar como o DOB estima o distúrbio total (composto de ambos os distúrbios) um diagrama de blocos equivalente ao diagrama de blocos mostrado na Figura 2.2 (a) é dado na Figura 2.2 (b), onde o distúrbio total pode ser decomposto como:

$$d_l = G_n^-(s)G_p(s)d + [G_n^{-1}(s)G_p(s) - 1]u \quad (2.2)$$

Da Figura 2.2 (b) pode-se deduzir que:

$$\begin{aligned} \hat{d} &= Q(s)G_n^{-1}(s)y - Q(s)u \\ &= Q(s)G_n^{-1}(s)G_n(s)(u + d_l) - Q(s)u \\ &= Q(s)d_l \end{aligned} \quad (2.3)$$

onde

$$e_d = \hat{d} - d_l = [Q(s) - 1]d_l \quad (2.4)$$

O erro de estimação do distúrbio total,  $e_d$ , tenderá a zero quando o tempo tender ao infinito se o filtro  $Q(s)$  é selecionado como um filtro passa-baixas, isto é,  $\lim_{s \rightarrow 0} Q(s) = 1$ .

Isto é também derivado a partir da Figura 2.2 (a) onde a saída pode ser representada como:

$$y = G_{uy}(s)u_c + G_{dy}(s)d \quad (2.5)$$

onde

$$G_{uy}(s) = \frac{G_p(s)G_n(s)}{G_n(s)+Q(s)[G_p(s)-G_n(s)]} \quad (2.6)$$

$$G_{dy}(s) = \frac{G_p(s)G_n(s)[1-Q(s)]}{G_n(s)+Q(s)[G_p(s)-G_n(s)]} \quad (2.7)$$

Se o filtro  $Q(s)$  é selecionado como um filtro passa-baixas, i.e.,  $\lim_{\omega \rightarrow 0} Q(j\omega) = 1$ , assim para as Equações 2.6 e 2.7

$$\lim_{\omega \rightarrow 0} G_{uy}(j\omega) = G_n(j\omega) \quad (2.8)$$

e

$$\lim_{\omega \rightarrow 0} G_{dy}(j\omega) = 0 \quad (2.9)$$

A Equação 2.6 implica que o sistema com DOB no domínio da frequência se comporta como se fosse a planta nominal em baixas frequências. É possível concluir a partir da Equação 2.9 que distúrbios com baixa frequência são eliminados pelo sistema *feedforward* de compensação.

Das Equações 2.4 e 2.9 pode-se constatar que a qualidade da estimação do distúrbio é fortemente dependente do modelo do filtro passa-baixas  $Q(s)$ , sendo este de grande importância dentro do DOB. Idealmente, para estimar os distúrbios, o filtro  $Q(s)$  deve ser projetado para estar próximo de 1 em toda faixa de frequências. No entanto, isto pode amplificar o ruído do sensor e também tornar o DOB não implementável devido à necessidade de inversão do modelo nominal da planta  $G_n(s)$ . De modo geral o filtro  $Q(s)$  deve ser modelado como um filtro passa-baixas onde:


- o grau de  $Q(s)$ , i.e., o valor referente à diferença entre as ordens do denominador e do numerador, não pode ser menor do que a do modelo nominal  $G_n(s)$ . Este fato torna a estrutura de controle possível, i.e., faz com que  $Q(s)G_n^-(s)$  seja própria;
- em baixas frequências  $Q(s)$  tende a 1 garantindo que o distúrbio total estimado seja aproximadamente igual ao distúrbio total real. Isto significa que o efeito do distúrbio pode ser atenuado por uma estrutura *feedforward* de compensação baseada no observador de distúrbios.

A escolha de  $Q(s)$  como um filtro passa-baixas é feita pois o distúrbio  $d$  a ser estimado é, frequentemente, de baixa ou média frequência. Desta forma o DOB é capaz de estimar distúrbios/incertezas em baixas e médias faixas de frequências e filtrar ruídos de medição em alta frequência. Esta escolha pode ser justificada devido a duas implicações: a primeira é o fato da planta controlada poder estar sujeita a distúrbios de alta frequência, a influência dos componentes em alta frequência é normalmente filtrada pela inércia do sistema físico; a segunda é o fato do distúrbio de alta frequência, mesmo que pudesse ser estimado, seria muito difícil ser atenuado devido às limitações de largura de banda de atenuadores (Chen *et al.*, 2015).

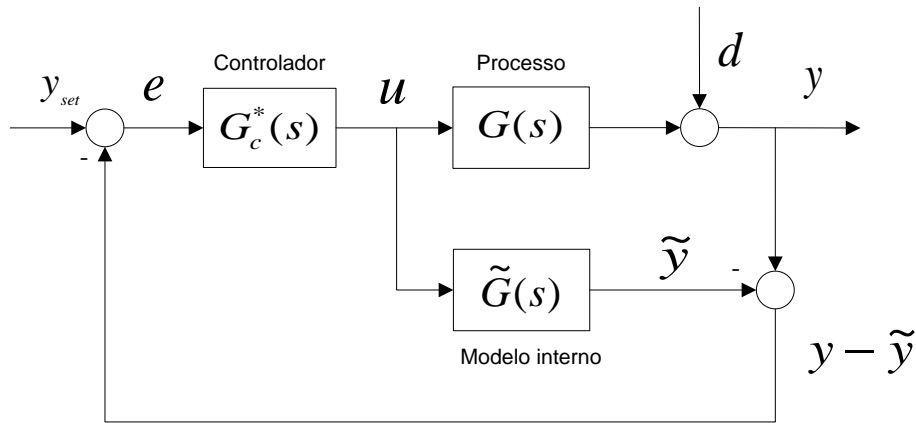
### 2.3 Internal Model Control (IMC)

O método foi desenvolvido por Garcia e Morari (1982) como um método para sintonia de controladores que toma como base um modelo de processo. A abordagem IMC tem a vantagem de tolerar incertezas de modelo e ainda assim permitir um bom compromisso entre desempenho e robustez para o sistema de controle (Seborg, 2004).

O referido método é baseado no diagrama de blocos apresentado nas Figuras 2.3 e 2.4.



**Figura 2.3:** Estrutura de controle *feedback* clássica.



**Figura 2.4:** Estrutura de controle IMC.

Ao comparar os diagramas de blocos mostrados nas Figuras 2.3 e 2.4 pode-se verificar que as duas configurações são equivalentes uma vez que  $G_c(s)$  e  $G_c^*(s)$  satisfazem a relação:

$$G_c(s) = \frac{G_c^*(s)}{1 - G_c^*(s)\tilde{G}(s)} \quad (2.10)$$

Então, qualquer controlador IMC  $G_c^*(s)$  é equivalente ao controlador *feedback*  $G_c(s)$  e vice e versa. A relação entre a malha-fechada para o IMC pode ser dada, a partir do diagrama de blocos mostrado na Figura 2.4, pela relação:

$$y = \frac{G_c^*(s)G(s)}{1 + G_c^*(s)[G(s) - \tilde{G}(s)]} y_{set} + \frac{1 - G_c^*(s)\tilde{G}(s)}{1 + G_c^*(s)[G(s) - \tilde{G}(s)]} d \quad (2.11)$$

Para o caso onde não há incerteza de modelo, ou seja  $\tilde{G}(s) = G(s)$ , a Equação 2.11 pode ser reduzida a



$$y = G_c^*(s)G(s)y_{set} + [1 - G_c^*(s)G(s)]d \quad (2.12)$$

A sintonia do controlador *IMC* pode ser realizada em duas etapas:

1. O modelo do processo é fatorado como:

$$\tilde{G}(s) = \tilde{G}_+(s)\tilde{G}_-(s) \quad (2.13)$$

onde  $\tilde{G}_+(s)$  contém fatores de fase não-mínima, tais como tempo morto e zeros. Adicionalmente,  $\tilde{G}_+(s)$  deve ter ganho estacionário igual à unidade, a fim de assegurar que  $\tilde{G}_+(s)$  e  $\tilde{G}_-(s)$  sejam únicos.

2. O controlador é especificado como:

$$G_c^*(s) = \frac{1}{\tilde{G}_-(s)}f(s) \quad (2.14)$$

onde  $f(s)$  é um filtro passa-baixas com ganho estacionário igual a um, sendo tipicamente definido como:

$$f(s) = \frac{1}{(\tau_{cl}s+1)^r} \quad (2.15)$$

onde  $\tau_{cl}$  é definido como a constante de tempo em malha-fechada e o parâmetro  $r$  é um inteiro positivo, usualmente igual a um.

Note que o controlador *IMC* é definido através da parte inversível do modelo do processo,  $\tilde{G}_-(s)$ , ao invés do modelo completo,  $\tilde{G}(s)$ . Se  $\tilde{G}(s)$  for usado, o controlador pode conter um termo de predição  $e^{+\theta s}$  (se  $\tilde{G}_+(s)$  contém um tempo morto  $\theta$ ), ou um pólo instável (se  $\tilde{G}_+(s)$  contém um zero no semi-plano direito). Então, através da aplicação da fatoração mostrada na Equação 2.13 e usando o filtro na forma apresentada na Equação 2.15, o controlador  $G_c^*(s)$  resultante é sempre fisicamente possível e estável. Em geral, a parte não inversível do modelo,  $\tilde{G}_+(s)$ , impõe limitações no desempenho que podem ser alcançadas. Devido ao método IMC ser baseado no cancelamento de zeros e polos, a abordagem IMC deve ser modificada para processos instáveis em malha aberta. Para uma situação ideal onde não há incerteza, substituindo a Equação 2.14 na Equação 2.12 obtém-se a expressão, para malha fechada:

$$\frac{y}{y_{set}} = \tilde{G}_+(s)f(s) \quad (2.16)$$

O método IMC pode ser utilizado para auxiliar o ajuste dos parâmetros de um controlador PID para uma variedade de funções de transferência. Diferentes relações de ajuste podem ser obtidas, a depender do tipo de filtro  $f(s)$  e da aproximação de tempo morto que sejam selecionadas. A tabela completa, para as relações de sintonia, encontra-se no Apêndice B.

## 2.4 Estimação de Sinais

A estrutura de controle *feedforward* utiliza a informação do distúrbio medido para o cálculo da ação de controle necessária. No entanto na maioria das situações esta informação não é conhecida, ou seja, os distúrbios são caracterizados como não medidos. Uma alternativa para implementação deste tipo de configuração é a utilização do

conhecimento do modelo do processo para estimação do sinal externo, como no caso dos observadores de distúrbios, porém nem sempre se tem informações suficientes sobre o modelo atual que descreve o processo. Um fator comum aos dois casos mencionados é a necessidade de um sinal conhecido para representar o distúrbio. Desta forma é possível constatar a importância de métodos capazes de estimar os sinais que representam os distúrbios não medidos.

Na literatura existem metodologias que permitem a estimação de sinais, as quais podem ser aplicadas com o interesse de conhecer o comportamento dos distúrbios não medidos. Esta seção apresenta alguns conceitos importantes utilizados para estimação de sinais, dando foco para a estimação através de regressão linear.

#### 2.4.1 *Séries Temporais*

Os sinais podem ser caracterizados como séries temporais, que são um conjunto de observações medidas em sequências através do tempo. Essas medições podem ser efetuadas de forma contínua ao longo do tempo, ou ser tomada em um conjunto discreto de pontos no tempo (Chatfield, 2000). Através dos dados coletados é possível encontrar modelos capazes de descrever estes dados. Este tipo de conhecimento auxilia na descrição, previsão e controle dos efeitos destes sinais.

Uma classificação importante dentro das séries temporais é quanto sua capacidade de predição em função de valores passados podendo ser classificadas em determinísticas e estocásticas. A primeira classificação engloba as séries temporais capazes de serem preditas de forma exata a partir de valores passados. No entanto, muitas séries podem ser ditas puramente ou parcialmente aleatórias, ou seja, são função de um fator aleatório, sendo assim não possíveis de serem exatamente preditas a partir de seus valores passados (Aguirre, 2007). Se um modelo apropriado para descrever o comportamento aleatório pode ser encontrado, então o modelo pode ser capaz de calcular boas previsões para valores futuros a partir de valores passados (Chatfield, 2000).

Existem diversos métodos encontrados na literatura, desenvolvidos com o intuito de recriar o sinal analisado por meio de uma representação matemática, estas representações ou modelos como podem também ser chamados, descrevem o comportamento temporal de uma dada variável em função de dados suficientes, coletados ao longo do tempo. Além dos dados, é necessário também o conhecimento de outras características estáticas destes dados, que terão influência sob o modelo que se deseja obter. Algumas destas características serão descritas a seguir.

#### 2.4.2 *Correlação*

Uma vez que se necessita obter um modelo capaz de descrever o comportamento de uma determinada variável a partir de variáveis conhecidas é importante conhecer o grau de correlação que existe entre estas variáveis e a variável em questão.

A correlação mede o nível de associação entre duas variáveis quantitativas,  $X$  e  $Y$ . Este grau de correlação pode ser quantificado por meio do coeficiente de correlação linear de Pearson ( $r$ ), calculado para o conjunto de amostras de tamanho  $n$ , conforme apresentado na Equação 2.17.

$$r = \frac{\sum_{i=1}^n [(X_i - \bar{X})(Y_i - \bar{Y})]}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (2.17)$$

O coeficiente de correlação linear de Pearson varia entre -1 e 1. Valores próximos de 1 indicam uma forte relação positiva entre as variáveis. Quando este valor é exatamente 1, as duas variáveis serão exatamente iguais em termos de escores padronizados, isto é, um elemento apresentando um escore padronizado de 1,5 em uma das variáveis vai apresentar o mesmo escore padronizado na outra variável. Valores de correlação negativos indicam uma correlação negativa, como no caso anterior, os escores padronizados das variáveis analisadas são exatamente iguais e valores absolutos, diferindo apenas do sinal. Uma correlação de 1 ou -1 é raramente observada. O mais comum é que o coeficiente fique situado no intervalo entre estes dois valores. Um coeficiente de correlação próximo à zero indica fraca relação, ou até mesmo ausência de relação (Naghttini e Pinto, 2007).

A correlação não implica necessariamente uma relação de causalidade. Ou seja, um dos eventos não necessariamente causa a ocorrência do outro. Todavia, a correlação pode ser um artifício utilizado em investigações desta natureza. Por exemplo, não é porque A acontece juntamente com B que podemos afirmar que A causa B. Por outro lado, se A e B apresentam relação de causalidade, então eles apresentam correlação. Assim determinar se existe de fato uma relação de causalidade requer investigação adicional, pois podem acontecer as seguintes situações:

- i. A causa realmente B;
- ii. B pode ser a causa de A;
- iii. Um terceiro fator C pode ser causa tanto de A, quanto de B;
- iv. A correlação pode ser apenas uma coincidência, ou seja, os dois eventos não terem qualquer relação para além do fato de ocorrerem ao mesmo tempo.

### 2.4.3 Causalidade

A análise do modelo obtido através da regressão pura e simples de variáveis temporais não implica em causalidade. A identificação de uma relação estatística (modelo), entre duas ou mais variáveis, por mais forte que seja não pode nunca estabelecer uma relação causal entre elas (Bartlett, 1947). Convicções a respeito de qualquer relação de causalidade devem se originar de fora da estatística, baseando-se, fundamentalmente, em alguma teoria já estabelecida ou até mesmo no senso comum.

No entanto, é possível se defrontar com uma situação na qual, duas variáveis quaisquer,  $X$  e  $Y$  podem ter efeito mútuo entre si, dependendo da estrutura de defasagens distribuídas entre elas. Esse é o ponto para se responder às seguintes questões:

- (1) É possível dizer que  $X$  causa  $Y$  ( $X \rightarrow Y$ );
- (2) É possível dizer que  $Y$  causa  $X$  ( $Y \rightarrow X$ );
- (3) Existe simultaneidade entre as duas ( $X \rightarrow Y$  e  $Y \rightarrow X$ )?

A princípio, deseja-se descobrir se existe relação de causa e efeito entre  $X$  e  $Y$  ao passo que existe uma relação de *precedência temporal* entre as duas variáveis, ou seja, uma ocorre antes da outra, e ainda ser capaz, com base nos dados das mesmas, de determinar esta relação.

É importante lembrar que o termo causalidade não é sinônimo de endogeneidade (uma variável mesmo que preceda a outra não implica ser a causadora desta muito menos ser capaz de predizê-la), conforme apresentado anteriormente. Apesar do termo causalidade ser um termo já estabelecido e amplamente utilizado, o mesmo dá uma ideia errônea quanto à interpretação de seus resultados, uma vez que através dos testes de causalidade determina-se a precedência de variáveis umas em relação as outras. Em virtude disto Leamer (1985) sugere o uso do termo *precedência temporal* ao invés do termo *causalidade*. Deve-se frisar que as expressões *precedência temporal* e *causalidade* significam a mesma coisa.

### Teste de Causalidade de Granger

O teste está baseado no princípio de que existe uma relação causal entre as séries temporais analisadas, ou seja, uma delas ocorre antes da outra. Por exemplo, se o evento A ocorre depois do evento B pode-se presumir que A não pode causar B. Ao mesmo tempo, se A ocorre antes de B, isso não signifique, necessariamente, que A cause B. Na prática o que se tem são duas séries temporais A e B e se está interessado em saber se A precede B, B precede A ou A e B ocorrem simultaneamente.

De acordo com Granger (1969) dadas duas séries temporais estacionárias com média zero e variância finita,  $X_t$  e  $Y_t$  é dito que a variável  $X$  causa a variável  $Y$  uma vez que é possível prever de forma mais precisa, estatisticamente, os valores futuros de  $Y$  através da inclusão de valores defasados de  $X$  aos valores defasados de  $Y$ , e vice e versa. Em termos práticos, o teste envolve estimar as seguintes regressões:

$$X_t = \sum a_i Y_{t-1} + \sum b_i X_{t-1} + u_{1t} \quad (2.18)$$

$$Y_t = \sum c_i Y_{t-1} + \sum d_i X_{t-1} + u_{2t} \quad (2.19)$$

onde  $u_{it}$  (com  $i = 1$  para  $X_t$  e  $i = 2$  para  $Y_t$ ), são resíduos assumidos não correlacionados. A Equação 2.18 postula que valores correntes de  $X$  estão relacionados a valores passados do próprio  $X$  assim como a valores defasados de  $Y$ . A Equação 2.19, postula um comportamento similar para a variável  $Y$ . Nada impede que as variáveis  $X$  e  $Y$  sejam representadas na forma de taxas de crescimento, o que, aliás, tem sido quase que a regra geral na literatura, uma vez que é difícil achar variáveis que sejam estacionárias em seus níveis. Após a estimação dos modelos, pode-se distinguir em quatro casos, levando as seguintes interpretações (Carneiro, 1997):

- I. Causalidade unilateral de  $Y$  para  $X$ : quando os coeficientes estimados para Equação 2.18 para a variável defasada  $Y$  são conjuntamente diferentes de zero ( $\sum a_i \neq 0$ ), e quando o conjunto de coeficientes estimados na Equação 2.19 para a variável  $X$  não forem estatisticamente diferentes de zero ( $\sum d_i = 0$ ).

- II. Causalidade unilateral de  $X$  para  $Y$ : quando o conjunto de coeficientes defasados para variável  $Y$  na Equação 2.18 não for estatisticamente diferente de zero ( $\sum a_i = 0$ ) e o conjunto de coeficientes defasados para a variável  $X$  na Equação 2.19 o for ( $\sum d_i \neq 0$ ).
- III. Bicausalidade ou Simultaneidade: quando os conjuntos de coeficientes defasados de  $X$  e  $Y$  forem estatisticamente diferentes de zero em ambas as regressões.
- IV. Independência: quando, em ambas as regressões, os conjuntos de coeficientes defasados de  $X$  e  $Y$  não forem estatisticamente diferentes de zero.

As análises de causalidade temporais estão baseadas na hipótese de que o futuro não pode prever o passado. Se a variável  $X$  causa à variável  $Y$ , então mudanças em  $X$  devem *preceder temporalmente* mudanças em  $Y$ .

#### 2.4.4 Regressão Linear

Muitas séries temporais podem ser representadas através de sua equação de diferença linear (Ljung, 1998), que pode ser dada como uma representação da relação ao longo do tempo ( $t$ ) entre sinais de entrada  $u(t)$  com  $n$  amostras e de saída  $y(t)$  com  $m$  amostras. Esta relação pode ser expressa conforme apresentado na Equação 2.20.

$$y(t) = a_1 y(t-1) - \dots - a_n y(t-n) + b_1 u(t-1) + \dots + b_m u(t-m) \quad (2.20)$$

A representação utilizada na Equação 2.20 representa o sistema em tempo discreto, uma vez que dados são sempre coletados por amostragem. É, portanto, mais simples representar os dados observados através de modelos em tempo discreto. Na Equação 2.20 foi assumido como intervalo de amostragem uma unidade de tempo, o que não é obrigatório, mas torna a notação mais simples. A saída  $y(t)$  pode ser, então, representada por:

$$y(t) = \varphi^T(t)\theta \quad (2.21)$$

onde

$$\theta = [a_1 \dots a_n \ b_1 \dots b_m]^T$$

$$\varphi(t) = [-y(t-1) \dots -y(t-n) \ u(t-1) \dots u(t-m)]^T \quad (2.22)$$

Desta forma a determinação de  $y(t)$  a partir de dados passados, como apresentado na Equação 2.22, depende dos parâmetros expressos por  $\theta$ . Este processo por sua vez pode ser dito como uma estimação dos possíveis valores de variável de saída, sendo escrita como:

$$\hat{y}(t|\theta) = \varphi^T(t)\theta \quad (2.23)$$

#### Estimativa dos Parâmetros de Regressão: Método dos Mínimos Quadrados

O método dos mínimos quadrados (MMQ) pode ser dito como um dos mais aplicados quando se objetiva determinar os parâmetros de ajuste da regressão linear (Naghetini e Pinto, 2007). De acordo com Ljung (1998) o método pode ser sintetizado da seguinte forma:

Supondo um sistema no qual não se conhece os valores dos parâmetros em  $\theta$ , mas se possuem entradas e saídas, avaliadas em instantes de tempos passados, dentro de um intervalo de  $1 \leq t \leq N$ :

$$Z^N = \{u(1), y(1) \dots \dots u(N), y(N)\} \quad (2.24)$$

É possível então realizar a determinação dos valores dos parâmetros  $\theta$ , através da minimização entre os valores medidos  $y(t)$  e os valores estimados  $\hat{y}(t|\theta)$ , o que é equivalente a:

$$\min_{\theta} V_N(\theta, Z^N) \quad (2.25)$$

onde

$$V_N(\theta, Z^N) = \frac{1}{N} \sum_{t=1}^N (y(t) - \hat{y}(t|\theta))^2 = \frac{1}{N} \sum_{t=1}^N (y(t) - \varphi^T(t)\theta)^2 \quad (2.26)$$

Pode-se então denotar o valor de  $\theta$  que minimiza a Equação 2.25 como  $\hat{\theta}_N$ :

$$\hat{\theta}_N = \arg \min_{\theta} V_N(\theta, Z^N) \quad (2.27)$$

Uma vez que  $V_N$  é quadrática em relação a  $\theta$ , é possível encontrar o valor que minimiza a função expressa na Equação 2.26 derivando-a em função de  $\theta$  e igualando-a a zero:

$$0 = \frac{d}{d\theta} V_N(\theta, Z^N) = \frac{2}{N} \sum_{t=1}^N \varphi(t)(y(t) - \varphi^T(t)\theta) \quad (2.28)$$

Que fornece:

$$\sum_{t=1}^N \varphi(t)y(t) = \sum_{t=1}^N \varphi(t)\varphi^T(t)\theta \quad (2.29)$$

Ou

$$\hat{\theta}_N = [\sum_{t=1}^N \varphi(t)\varphi^T(t)]^{-1} \sum_{t=1}^N \varphi(t)y(t) \quad (2.30)$$

Uma vez que o vetor  $\varphi(t)$  é definido, a solução pode facilmente ser encontrada por um *software* numérico. O ajuste obtido através do MMQ não é, necessariamente, o “melhor” ajuste possível, mas possui muitas propriedades estatísticas que são desejáveis.

## 2.5 Identificação de Sistemas

A presença de *DNMs* é um dos principais problemas encontrados nos procedimentos de identificação de processos, uma vez que corrompe a saída do processo, geralmente utilizada como saída para o modelo identificado. Este fato pode, a depender das características do *DNM*, levar a modelos identificados que não expressem satisfatoriamente o processo que se deseja identificar. A identificação de um modelo, de forma geral, consiste na determinação de uma equação matemática que seja capaz de reproduzir as principais características observadas para o sistema que descreve o processo, em análise. De acordo com Aguirre (2007) um modelo de um determinado

sistema é apenas uma representação aproximada, conseqüentemente, não existe o modelo do sistema, mas sim uma família de modelos com características e desempenhos variados capazes de representar os fenômenos associados aos dados analisados.

Os modelos, que representam o processo, podem ser classificados como lineares ou não lineares. Apesar dos modelos não lineares apresentarem uma maior capacidade de representação dos processos, a maioria dos controladores ativos nas plantas industriais utilizam modelos lineares devido à facilidade de cálculo das ações de controle. Admitir que um determinado sistema pode ser aproximado por um modelo linear é algo frequente, e tal suposição pode ser verificada observando-se o comportamento de um sistema numa faixa relativamente estreita de operação. Na prática, quando desejado trabalhar com controladores lineares os modelos não lineares identificados são linearizados e opera-se em torno do ponto onde o sistema foi linearizado (Aguirre, 2007).

Os modelos não lineares, ao contrário dos modelos lineares, são de natureza posicional, ou seja, a mesma variação nas entradas em diferentes pontos de operação pode produzir resultados significativamente distintos. Em alguns casos, a não linearidade de um sistema pode ser confundida com a presença de distúrbios não medidos na carga, os quais são componentes estocásticos que precisam ser contemplados pelo modelo, da mesma forma que os ruídos de medição. Modelos que contemplam estes efeitos são ditos modelos estocásticos. Por outro lado, se o interesse da identificação é obter a relação entre a entrada e a saída, ignorando os distúrbios, o modelo é chamado de determinístico (Ljung, 1998).

Outra característica importante de um modelo é a possibilidade ou não de ser representado através de parâmetros. A distinção entre estes dois tipos de modelos não é totalmente universal: em geral pode-se dizer que um modelo paramétrico é aquele possível de ser representado por números ou coeficientes que os caracterizam. Os modelos que não apresentam esta capacidade estabelecem algum tipo de relação entre a variável dependente e a independente, sendo esta última pertencente ao domínio do tempo ou da frequência. No caso dos modelos não-paramétricos os mais simples analisados no domínio do tempo podem ser obtidos através da resposta do sistema mediante uma perturbação impulso ou degrau (Aguirre, 2007).

As principais etapas que envolvem um problema de identificação são:

1. *Testes dinâmicos e coleta de dados:* Esta etapa envolve a geração ou a coleta dos dados que serão utilizados para identificação. Muitas vezes os únicos dados disponíveis são os dados em “operação normal”. A escolha do sinal de excitação, execução do teste e a escolha do tempo de amostragem são problemas importantes relacionados a essa etapa (Aguirre, 2007);
2. *Escolha da representação matemática a ser usada:* A representação de um modelo pode ser feita através de modelos lineares, como funções de transferência ou modelos em espaço de estados, modelos estocásticos entre outras possibilidades de modelos (Aguirre, 2007);
3. *Determinação da estrutura do modelo:* No caso de sistemas lineares, a escolha da sua estrutura se restringe a escolha do número de polos e zeros, bem como à determinação do atraso puro de tempo. Para os modelos não lineares esta escolha se torna mais complexa, em virtude do grande número de estruturas

possíveis e também ao fato de que termos redundantes neste tipo de modelo *destroem* a dinâmica original do sistema (Aguirre, 2007);

4. *Estimação dos parâmetros*: Esta etapa consiste basicamente na escolha e aplicação do algoritmo a ser utilizado para estimação dos parâmetros que caracterizam o modelo matemático escolhido, como o método de mínimos quadrados ou método de máxima verossimilhança que podem ser encontrados com mais detalhes em (Ljung, 1998);
5. *Validação do modelo*: Tendo obtido um conjunto de candidatos a modelos, é necessário verificar se eles possuem a capacidade de representar satisfatoriamente as características de interesse do sistema original. O resultado da validação dependerá fortemente da aplicação pretendida para o modelo e da quantidade de informação disponível sobre o sistema original (Aguirre, 2007).

As etapas de determinação da estrutura e de estimação dos parâmetros, bem como a qualidade do modelo obtido, estão fortemente atreladas ao nível de informações disponíveis a respeito do sistema em estudo, tal como a qualidade dos dados utilizados para a identificação, uma vez que estes devem permitir a identificação das principais características do processo a ser identificado. No entanto, a aquisição de dados suficientemente ricos (i.e., dados que capturem, de forma satisfatória, as características principais do processo, permitindo assim uma identificação coerente) não é de fácil obtenção em situações nas quais o processo encontra-se em operação. Nestes casos são necessárias técnicas de identificação em malha fechada minimamente intrusivas, ou seja, que impactem sobre o sistema de forma a não comprometer o processo que está em operação. O estudo de técnicas de identificação em malha fechada apresenta grande relevância uma vez que permite o estudo de sistemas que se encontram já em operação na presença de um controlador, pré-existente, que apresentam comportamento integrador ou que são instáveis em malha aberta. Uma das metodologias propostas, no presente trabalho, tem como um dos objetivos fornecer uma alternativa à identificação do modelo da planta neste tipo de situação realizando a identificação em malha fechada a partir de dados em condição normal.

Quanto à etapa de escolha da estrutura do modelo. Entende-se por estrutura do modelo a presença ou não das parcelas determinísticas (resposta do sistema decorrente das entradas), estocásticas (resposta do sistema decorrente apenas das variáveis estocásticas, incertezas externas) e mistas (modelo que apresenta as duas parcelas). Na literatura existe uma gama de estruturas de modelos propostas, elaboradas com a finalidade de identificação de sistemas. De forma geral a maioria destas estruturas foram derivadas da Equação 2.31, para representar um sistema em tempo discreto:

$$A(q)y(k) = \frac{B(q)}{F(q)}u(k) + \frac{C(q)}{D(q)}v(k) \quad (2.31)$$

em que a variável  $q^{-1}$  é o operador de atraso no domínio do tempo e  $k$  é um número inteiro que representa o instante de tempo em questão, de forma que  $y(k)q^{-1} = y(k - 1)$ . Os polinômios  $A$ ,  $B$ ,  $C$ ,  $F$  e  $D$  são funções de  $q$  e contém os parâmetros a serem estimados. As variáveis  $u(k)$  e  $y(k)$  representam a entrada e a saída, respectivamente, e



$v(k)$  é o ruído branco (Aguirre, 2007). Na literatura existe uma gama de modelos discretos utilizados para identificação de processos, dos quais se pode destacar os modelos *FIR* (do inglês – *finite impulse response*), *ARX* (auto regressivo com entradas exógenas), *ARMAX* (auto regressivo com média móvel e entradas exógenas) e *ARMA* (auto regressivo com média móvel) estes modelos encontram-se melhor discutidos no Apêndice A.

Os testes de identificação, para a coleta dos dados, podem ser realizados em malha aberta ou malha fechada. A identificação em malha fechada pode ser feita de forma direta ou indireta. A identificação direta consiste em aplicar um método de predição do erro aos dados de observação sem considerar a presença do controlador, ou seja, os valores de entrada e saída são tratados como se tivessem sido obtidos em malha aberta. Os modelos utilizados por este método, geralmente seguem a Equação 2.32 que é uma forma alternativa da Equação 2.31.

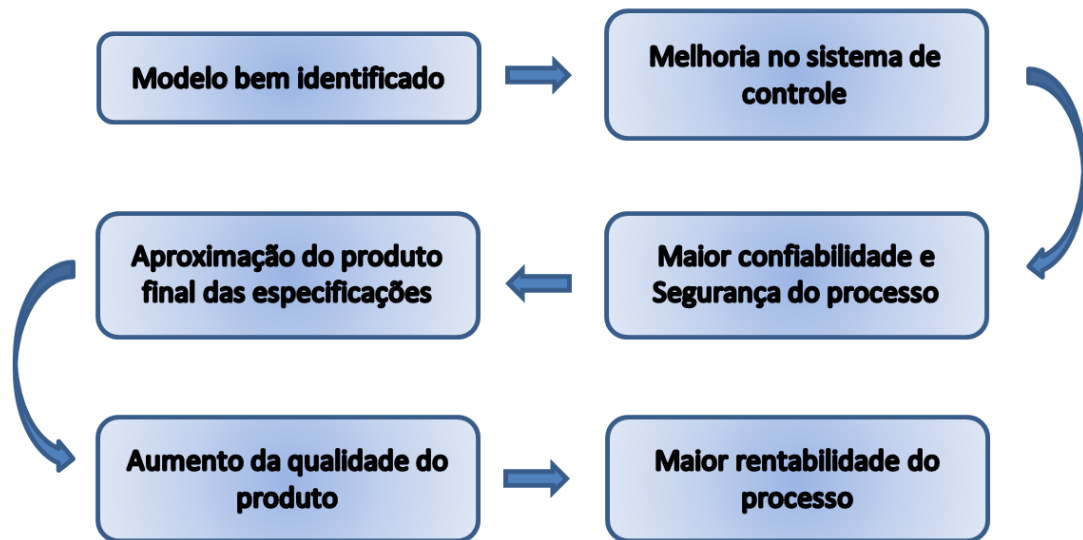
$$y(k) = G(q)u(k) + H(q)v(k) \quad (2.32)$$

onde  $y(k)$  representa o sinal de saída,  $u(k)$  é o sinal de entrada,  $v(k)$  é o ruído branco e  $G(q)$  e  $H(q)$  são funções racionais que representam o modelo da dinâmica do processo e do ruído, respectivamente.

A identificação indireta, por sua vez, identifica o modelo do processo através de uma identificação da função de sensibilidade complementar (definida como a função de transferência que relaciona de forma direta a variação da variável de saída do processo em relação à uma variação de *setpoint*). Maiores detalhes a respeito da função de sensibilidade complementar podem ser encontrados em Skogestad e Postlethwaite (2005). Sequencialmente, após a obtenção de um modelo que descreve o comportamento do sistema em malha fechada, é possível, então, obter o modelo do processo a partir do conhecimento do controlador em funcionamento. Modelos consistentes podem ser obtidos através desse método sob condições nas quais o controlador é linear e exatamente conhecido Agüero *et al.*(2011). Algumas variações da aplicação desse método podem ser encontradas em Van Donkelaar e Van Den Hof (1997), Van Den Hof (1998) e Zheng e Feng (1995).

Após a realização das etapas de coleta de dados, escolha da representação matemática a ser usada, escolha da estrutura do modelo e estimação dos parâmetros do modelo é feito, então, um levantamento de possíveis candidatos a modelo do processo, escolhidos pela capacidade de representatividade do processo, a partir dos dados coletados. Para a escolha do modelo é importante, então, a definição de critérios tais como considerações estatísticas e análises de erro obtido na predição da resposta ao degrau, resposta em frequência, ou ainda, pela localização de polos e zeros.

Um modelo bem identificado viabiliza, por exemplo, determinar estratégias de melhoria no rendimento do processo obtidas através de modificações nos parâmetros de ajuste do controlador impactando diretamente no produto final. Esta melhoria pode ser refletida como apresentado na Figura 2.5.



**Figura 2.5:** Fluxograma representativa das possibilidades de um modelo bem identificado.

Uma vez que a presença de distúrbios interfere na identificação do modelo, existe então a motivação de estudar técnicas capazes de identificar os modelos de forma satisfatória, mesmo diante da presença de distúrbios.

## 2.6 Auditoria de Desempenho em Malhas de Controle

A qualidade do produto final e a eficiência do processo podem ser vistos como objetivos principais dos processos produtivos. No entanto para atender tais objetivos é fundamental a realização de um constante monitoramento de cada variável constituinte do processo ou daquelas que apresentem maior impacto na qualidade do produto. Tal monitoramento pode ser realizado através de uma auditoria das malhas de controle, que busca avaliar propriedades específicas do sistema de controle que possam vir a refletir em seu desempenho.

O termo auditoria é utilizado de uma forma mais ampla, não significando apenas identificar um desempenho insatisfatório, mas também diagnosticar seus causadores. Cada vez mais são investidos esforços para o desenvolvimento de ferramentas capazes de permitir um diagnóstico e localizar a causa raiz, avaliar a saúde da malha, quantificar o impacto econômico de cada controlador de forma automática, sem a necessidade de testes invasivos (Harris *et al.*, 1999). Tais ferramentas ajudam a identificar de forma mais eficiente os possíveis pontos de melhoria auxiliando na tomada de ações corretivas capazes de elevar a rentabilidade do processo. A auditoria das malhas de controle é de fundamental importância no gerenciamento da saúde do processo, sendo um dos responsáveis por manter as condições operacionais em um nível capaz de obter a máxima eficiência possível para o processo. Existe uma gama de ferramentas na literatura utilizadas para tal finalidade e que podem ser encontradas em, por exemplo, Åström (1967), Devries e Wu (1978), etc.

Na literatura é possível encontrar uma variedade de métricas desenvolvidas para auxiliar o monitoramento dos sistemas de controle. Estas métricas de forma geral utilizam

informações do processo e variáveis medidas, de fácil obtenção, para obter índices que permitem por meio de suas interpretações avaliar a saúde do sistema de controle.

Dentre estas ferramentas é possível destacar aquelas que fornecem indicadores que permitem uma avaliação do desempenho do sistema de controle, a partir de dados em condições normais de operação, possíveis de se determinar sem a necessidade de testes intrusivos. Estes indicadores podem ser classificados como índices estocásticos, dentre os quais existem aqueles índices que buscam avaliar a variabilidade dentro do processo tais como os índices baseados no controlador de variância mínima (CVM).

A seguir serão abordados alguns índices que buscam avaliar a variabilidade do processo a partir de apenas dados operacionais em condições normais de forma não intrusivas, assim como uma breve definição do que seria a variabilidade em processos de produção suas causas e efeitos.

### 2.6.1 Variabilidade: Causas e Efeitos


Qualquer processo produtivo está sujeito à presença de variabilidade, independentemente de quão bem tenha sido projetado ou venha a estar sendo operado. Ao compararem-se duas unidades quaisquer, produzidas pelo mesmo processo, elas jamais serão exatamente idênticas. A variabilidade pode advir e agir de forma diferente sobre o sistema. Para o gerenciamento do processo e redução da variabilidade, é importante investigar as causas geradoras desta variabilidade, que podem ser classificadas de duas formas: causas comuns e causas especiais.

As causas comuns englobam as fontes de variabilidade que atuam de forma aleatória no processo, ou seja, de forma inerente ao processo. A variabilidade proveniente destas causas representa o padrão natural do processo, por ser resultado do efeito cumulativo de pequenas fontes ao longo da linha de produção em condição normal de operação. Um processo que apresenta apenas as causas comuns atuando é dito um processo estável ou sob controle, pois apresenta a mesma variabilidade ao longo do tempo, podendo então, ser previsível (Ribeiro e Caten, 2012). Em virtude disto as medidas individuais de uma característica de qualidade são todas diferentes entre si, mas quando agrupadas podem apresentar certo padrão. De forma geral causas comuns são resolvidas mediante ações globais sobre o sistema, o que em muitos casos é algo dispendioso, tornando-se inviável economicamente.

As causas especiais não são pequenas e não seguem algum tipo de padrão, estas são consideradas falhas operacionais, que fazem com que o processo saia do padrão natural de operação. Estas causas conferem um comportamento instável e não previsível, reduzindo a eficiência do processo e devem ser identificadas e neutralizadas, pois sua correção se justifica economicamente. O que evidencia que o conhecimento da atual condição do processo é fundamental para um aperfeiçoamento e melhorias no procedimento de produção. Em sua maioria podem ser corrigidas mediante alguma ação local, sendo então de responsabilidade dos operadores.

Em muitos casos, o desempenho indesejado do sistema de controle pode aumentar a variabilidade do processo (Yan *et al.*, 2015), diminuindo a eficiência do mesmo. Em malhas de controle, a variabilidade pode advir de oscilações normalmente causadas por agarramento ou histerese de válvulas, má sintonia dos controladores, ruídos de medição, perturbações e não-linearidades do processo, entre outros fatores (Brand, 2009). A

variabilidade pode ser quantificada através da variância de um sinal de interesse, tal como a variância correspondente à variável de saída do processo.



**Figura 2.6:** Variabilidade de um processo antes e depois de uma modificação de ajuste. (Fonte: Farenzena, 2008)

Na prática é possível verificar que através de uma melhoria no ajuste do controlador é possível obter uma redução na variabilidade (Brand, 2009), conferindo assim uma maior confiabilidade ao sistema de controle. Tal melhoria permite operar mais próximo aos limites e especificações impostos para o processo. A Figura 2.6 mostra o efeito da redução da variabilidade em uma variável de processo, ilustrando a possibilidade de uma maior aproximação desta variável das especificações impostas à ela.

### 2.6.2 Índices Baseados em Controladores de Variância Mínima

Estes índices são determinados a partir da variância atual do processo ( $\sigma_y^2$ ) e da variância mínima do processo, ou seja, a variância do processo obtida a partir de um controlador de variância mínima ( $\sigma_{MV}^2$ ). O controlador de variância mínima foi proposto por Åstrom (1970) para avaliação de desempenho de controladores. A base da determinação da variância mínima é muito simples: assume-se que o atraso do processo é de  $\Phi$ , a ação de controle é então efetiva somente após  $\Phi$ . Assim, uma porção da variância total do sistema é inacessível ao controlador *feedback*. Controladores *feedback*, que atuam em processos cujo período de atraso é significativo em relação à dinâmica do processo apresentam alto valor de variância em comparação com a variância mínima. Esta é uma das razões que tornam a variância mínima uma boa referência para o processo de auditoria e monitoramento de malhas de controle.

A estimação da variância mínima pode ser feita através de algoritmos baseados em filtragem e correlação tais como o FCOR, do inglês *filtering and correlation*, proposto por Huang e Shah (1999). Este algoritmo utiliza um modelo auto-regressivo de média móvel (ARMA) ou um modelo auto-regressivo (AR) para modelar o distúrbio não medido caracterizado por sua vez como um ruído branco, necessitando de dados de operação normal, de uma estimativa do tempo morto e da ordem do modelo AR ou ARMA. Não existe um valor padrão para a ordem do modelo AR ou ARMA, em Desborough e Harris

(1992) é sugerido um aumento gradativo na ordem do modelo a partir de 5 até um valor em que o índice não apresente mudanças consideráveis.

Existem outros métodos para a estimativa da variância mínima que podem ser utilizados, tais como o proposto por Desborough e Harris (1992) que propõem o uso de regressão linear simples e um algoritmo elaborado por Van Overschee e De Moor (2012). É possível encontrar referências substanciais a respeito de algumas metodologias para obtenção da variância mínima em Jelali (2006).

Os índices que utilizam o controlador de variância mínima como referencial para o desempenho são os mais difundidos nos *softwares* comerciais de auditoria de desempenho. Isso se deve principalmente por sua sólida fundamentação teórica e pelo fato de requerer pouco conhecimento de informações do processo. Entretanto, esse método de análise de desempenho apresenta limitações que podem ser sumarizadas, de acordo com Farenzena e Trierweiler (2006a; b) em:

- Deterioração quando ocorrem variações de *setpoint*, restringindo a avaliação de desempenho ao controle regulatório;
- Não possui uma escala global e conclusiva, o que inviabiliza comparações entre diferentes malhas;
- Baixa resolução da escala, em alguns casos a variação entre uma malha rápida e uma lenta é pequena;
- A variância mínima não é uma métrica global, sendo sua interpretação dificultada, uma vez que não é uma medida usual da malha. Além disso, o controlador de variância mínima é teoricamente alcançável, porém é um controlador com baixa robustez, que na prática é raramente utilizado devido às suas excessivas ações de controle.
- Índice de Harris ( $\eta(\Phi)$ ): este índice, desenvolvido por Harris (1989), relaciona a variância atual do sistema de controle ( $\sigma_y^2$ ) com a variância mínima ( $\sigma_{MV}^2$ ) obtida a partir do tempo de atraso ( $\Phi$ ) e dados normais de operação do sistema o que permite sua determinação *online*. O índice de Harris  $\eta(\Phi)$  é definido como:

$$\eta(\Phi) = 1 - \frac{\sigma_{MV}^2}{\sigma_y^2} \quad (2.33)$$

A variância atual da malha é facilmente estimada através de dados da variável controlada.

O índice de Harris está delimitado entre 0 e 1, sendo o melhor controlador possível aquele cujo  $\eta(\Phi)$  se torna mais próximo de 0, ou seja, aquele com desempenho próximo ao referente para a variância mínima. O aumento do valor deste índice implica em uma deterioração do desempenho do controlador.

Maiores detalhes sobre a obtenção de  $\sigma_{MV}^2$  e  $\sigma_y^2$  podem ser encontrados em Farenzena (2008).

### 2.6.3 Modelo de Inferência para Desempenho e Robustez

Em busca de uma metodologia mais completa em relação às metodologias clássicas de auditoria de desempenho e robustez foi proposto o modelo de inferência (*IM*) por Farenzena e Trierweiler (2006b). Este modelo é capaz de gerar índices determinísticos em malha fechada, de forma não intrusiva, que utilizam como referência o desempenho em malha aberta utilizando como entradas do modelo parâmetros facilmente quantificados em tempo real (índices não intrusivos e parâmetros do processo) a partir de dados do processo em condições normais de operação.

O *IM* foi construído a partir de um conjunto de plantas e suas características, tais como: dinâmica, ordem do modelo, polos, zeros e etc. Além disto foi também utilizado um conjunto de controladores PI com diferentes desempenhos para geração de diversos cenários correspondentes a sistemas resultantes da combinação entre os modelos de planta e de controlador. Através desses cenários foram obtidos dados, a partir de testes intrusivos, coletados em duas situações distintas. A primeira delas considerou variações de *setpoint*, sendo coletados os índices  $CV_{AR}$  e  $MV_{AR}$  determinados a partir da curva da variável controlada e da variável manipulada, antes e após a mudança de *setpoint*, apresentados nas Equações 2.34 e 2.35:

$$CV_{AR} = \int_0^{St} (CV - CV_{\infty}) dt \quad (2.34)$$

$$MV_{AR} = \int_0^{St} (MV - MV_{\infty}) dt \quad (2.35)$$

onde  $CV_{AR}$  e  $MV_{AR}$  referem-se aos valores das áreas das curvas das variáveis controladas e manipuladas após o processo estar operando no novo ponto de operação.

A segunda situação é equivalente ao modo de operação onde não ocorrem mudanças de *setpoint*. Neste caso os índices não intrusivos, como índice de Harris e os índices baseados na integral do erro podem ser quantificados. Além destes índices, foram também quantificados os índices propostos por Farenzena e Trierweiler (2006b) que permitem uma avaliação mais clara do desempenho da malha, viabilizando ainda a quantificação da influência de componentes como tempo morto e ruído branco sobre a variância total do sistema. Tais índices partem do princípio de que é possível compor a variância do sinal de saída ( $\sigma_y^2$ ) em três componentes:

$$\sigma_y^2 = \sigma_{w_t}^2 + \sigma_{f_t}^2 + \sigma_{g_t}^2 \quad (2.36)$$

onde,

$\sigma_{w_t}^2$  refere-se ao ruído branco, inerente ao processo e que não pode ser eliminado pelo controlador, apenas por modificações no processo ou em instrumentos de medida.

$\sigma_{f_t}^2$  refere-se ao sinal que pode ser modelado, entretanto o controlador *feedback* não pode removê-lo devido ao tempo morto da malha.

$\sigma_{g_t}^2$  refere-se ao sinal de baixa frequência que o controlador *feedback* pode remover.

Desta composição é possível obter os seguintes índices:

- *nosi* (índice de ruído): mostra a importância da variabilidade da componente aleatória do sinal, que não pode ser removida pelo controlador. É obtido da relação entre a variância da componente aleatória e a variância total em malha fechada, conforme a Equação 2.37.

$$nosi = \frac{\sigma_{w_t}^2}{\sigma_y^2} \quad (2.37)$$

- *deli* (índice de tempo morto): quantifica a parcela referente à influência do tempo morto na variabilidade do processo. É obtido da relação entre a variância causada pelo tempo morto e a variância total em malha fechada, dado pela Equação 2.38.

$$deli = \frac{\sigma_{f_t}^2}{\sigma_y^2} \quad (2.38)$$

- *tuni* (índice de ajuste): quantifica a parcela referente ao poder de atenuação da variabilidade pelo controlador *feedback*, ou seja, a influência do ajuste do controlador. É obtido da relação entre a variância acessível ao controle *feedback* e a variância total em malha fechada, conforme mostra a Equação 2.39.

$$tuni = \frac{\sigma_{g_t}^2}{\sigma_y^2} \quad (2.39)$$

#### 2.6.4 Modelo de Inferência de Variabilidade

Este modelo foi proposto por Brand (2009) e quantifica o potencial de alteração de variabilidade ( $V_A$ ) de uma malha de controle decorrente de alterações do desempenho da malha de controle. O modelo utiliza como entradas índices que apresentam informações do desempenho atual da malha de controle, tais como razão entre o tempo de assentamento em malha aberta e fechada, razão entre o tempo de subida em malha aberta e em malha fechada, máxima sensibilidade, índice *tuni*, índice *deli*, índice *nosi* e características da planta em questão ( $P_c$ ) tais como tempo morto e constante de tempo.

O modelo de Inferência de Variabilidade (MIV) é definido como uma função não-linear ( $N$ ) que pode ser representado como:

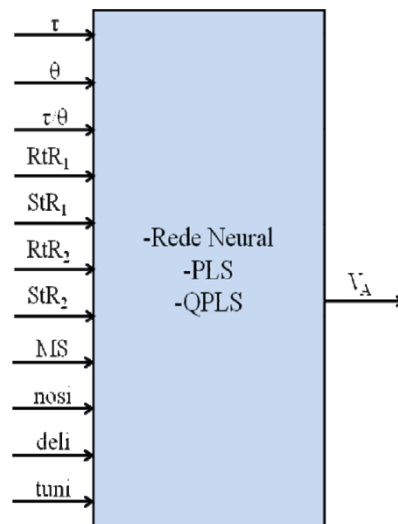
$$V_A = N(IM, P_c) \quad (2.40)$$

onde  $V_A$  é dado como:

$$V_A = \frac{\sigma_2^2}{\sigma_1^2} - 1 \quad (2.41)$$

sendo  $\sigma_1^2$  e  $\sigma_2^2$  a variância da malha de controle antes e depois da alteração de desempenho do sistema, respectivamente, sendo calculadas como a variância do sinal de saída do processo nas condições analisadas.

Desta forma o MIV pode ser representado na Figura 2.7:



**Figura 2.7:** Representação esquemática do modelo de inferência de variabilidade. (Fonte: Brand, 2009)

Na Equação 2.41 assim como na Figura 2.7 os subscritos 1 e 2 representam condição atual e condição após alteração no desempenho da malha de controle, respectivamente.

A falta de informações mais precisas sobre a dinâmica do processo é uma das limitações da aplicabilidade de análises como a MIV, uma vez que esta metodologia necessita do conhecimento dos parâmetros dinâmicos do processo e não leva em consideração o efeito dos distúrbios não medidos presente no processo.



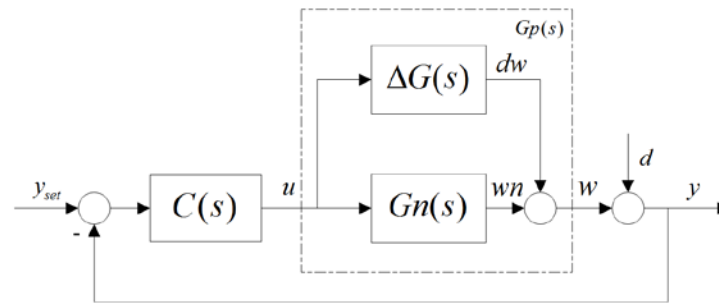
## Capítulo 3 – Metodologia Proposta

Neste Capítulo são abordados os detalhes da metodologia desenvolvida para determinação do estimador de distúrbios não medidos. Além disso, são apresentadas outras duas metodologias complementares que podem ser utilizadas em conjunto ao estimador de distúrbios. Uma das metodologias propostas utiliza o distúrbio estimado para identificação de modelos que representem o comportamento do processo nas condições analisadas sem a necessidade de testes intrusivos e a outra apresenta um mecanismo de obtenção do índice  $VRE$ , capaz de estimar o potencial de redução de variabilidade do sistema de controle a partir de melhorias no desempenho do controlador.

### 3.1 Estimador de Distúrbios não Medidos

O estimador de distúrbios não medidos é uma metodologia desenvolvida para estimação do  $DNM$  em um dado processo a partir de dados de operação normal. A estimação é realizada através de uma janela fixa de dados de processo utilizada para o exercício de toda a metodologia. A metodologia utilizada para desenvolvimento do estimador de  $DNM$ , proposto neste trabalho, foi desenvolvida de forma a ser não intrusiva, dispensando assim quaisquer perturbações sendo necessário apenas o conhecimento dos parâmetros do controlador PI/PID, do sinal de ação de controle ( $u$ ) e de saída do processo ( $y$ ).

O estimador foi desenvolvido com base em um sistema de controle *feedback* clássico representado na Figura 3.1.



**Figura 3.1:** Sistema de controle *feedback*.

Na Figura 3.1  $Gp(s)$  representa o modelo do processo e pode ser dado, em conformidade com a Figura 3.1, como a soma de  $Gn(s)$  (modelo aproximado ou nominal de  $Gp(s)$ ) e  $\Delta G(s)$  que representa a discrepância entre os modelos, sendo expressa como:

$$\Delta G(s) = Gp(s) - Gn(s) \quad (3.1)$$

onde  $C(s)$  é o controlador e  $d$  é o distúrbio não medido presente no processo. A ação de controle é representada por  $u$  e a saída do processo por  $y$ . Será admitido que o *setpoint*,  $y_{set}$ , é mantido constante para não interferir na variância dos sinais.

Conforme a Figura 3.1, o sinal  $y$  pode ser obtido através das seguintes relações:


$$\begin{aligned} y &= d + Gn(s)u + \Delta G(s)u \\ &= d + wn + dw \end{aligned} \quad (3.2)$$

Rearranjando tem-se:

$$y - wn = \underbrace{d + dw}_{dud} \quad (3.3)$$

onde  $wn$  representa a saída do modelo nominal, dada a entrada  $u$ , e  $w$  representa a saída da planta, dada a entrada  $u$ . Para tornar a notação mais simples, o lado direito da Equação 3.3 será representado por  $dud$ . Assim a partir dos sinais  $y$  e  $u$  e do modelo  $Gn(s)$  pode-se obter o sinal  $dud$ , que é um sinal temporal composto por uma parcela exógena ao processo (distúrbio não medido) e outra parcela decorrente do erro de modelagem do processo, ou seja, discrepância entre modelo e planta (sinal  $dw$ ).

Desta forma  $dud$  pode ser obtido de forma direta como mostrado na Figura 3.2:



**Figura 3.2:** Esquema representativo da geração do sinal  $dud$ .

Uma vez que o sinal  $dud$  é dado pela soma de  $d$  e de  $dw$ , pode-se supor que existe uma forte correlação entre este sinal e o sinal  $d$ . Esta correlação poderá ser tão maior quanto menor for a discrepância de modelo,  $\Delta G(s)$ . Em outras palavras quanto menor a discrepância entre o modelo do processo e o modelo aproximado, maior poderá ser a correlação entre os sinais  $dud$  e  $d$ . Outra condição importante admitida pela metodologia é a correlação do sinal  $u$  com o sinal  $d$ . Nos casos em que a malha de controle opera com *setpoint* fixo, quaisquer variações observadas na ação de controle são decorrentes da compensação dos distúrbios levando à uma forte correlação entre a ação de controle e o distúrbio não medido. Desta forma é esperada uma alta correlação dos sinais  $u$  e  $dud$  com o sinal  $d$ . A fim de verificar estas hipóteses foram realizados testes com diferentes modelos de filtro. Para representar estes modelos foram utilizadas funções de transferência de primeira e segunda ordem com e sem tempo morto, cujos parâmetros foram determinados aleatoriamente com o objetivo de obter um conjunto de modelos que representasse uma diversidade de processos, isto foi feito para verificar a sensibilidade da correlação do sinal  $dud$  com o sinal  $d$  em função de diferentes modelos utilizados como filtro. Os resultados obtidos para esta análise encontram-se na seção 4.1 e em decorrência das análises desses resultados o método aqui apresentado propõe então obter uma estimativa de  $d$  através de uma regressão linear utilizando como variáveis os sinais  $u$  e  $dud$ .

A estimação do distúrbio através da regressão linear, pode por sua vez ser representada como:

$$Y = a + \overbrace{b.X}^{\hat{d}} + E \quad (3.4)$$

onde  $Y$  é a variável dependente,  $X$  é a variável independente,  $b$  e  $a$  são os estimadores da regressão e  $E$  é o vetor de resíduos da reta ajustada. Lembrando que se o processo apresentar tempo morto  $Y$  será  $dud$  e  $X$  será  $-u$ , casos ausentes de tempo morto esta relação é invertida.

Uma vez que o interesse da regressão é capturar a parcela referente ao sinal  $d$  possível de ser explicada utilizando os sinais  $u$  e  $dud$ , é admitido então que o sinal estimado de  $\hat{d}$  pode ser extraído da parcela " $b.X$ " obtida através da regressão linear.

Assim a metodologia propõe a utilização de um filtro definido como um modelo aproximado de  $Gp(s)$ , para obter um sinal  $dud$  com uma alta correlação com  $d$ . O filtro será representado como o modelo aproximado  $Gn(s)$  que em conjunto com o sinal  $u$  geram  $dud$ . Esse sinal é utilizado junto com  $u$  e  $y$  para se obter por fim o distúrbio estimado  $\hat{d}$ , por meio de regressão linear. Desta forma a escolha adequada do modelo aproximado do processo é fundamental para a qualidade do  $\hat{d}$  obtido.

A determinação do filtro é realizada tendo como base as relações impostas pelo método de ajuste IMC, que estabelece uma relação direta entre os parâmetros de ajuste do controlador (parcela proporcional,  $Kp$ , parcela integral,  $Ti$ , e parcela derivativa,  $Td$ ) e os parâmetros do modelo de processo, podendo ser representado pela função abaixo:

$$[Kp, Ti, Td] = f(P, \tau_{cl}) \quad (3.5)$$

onde  $P$ , representa o vetor de parâmetros que compõem o modelo da planta (como ganho,  $K$ , constante de tempo,  $\tau$ , polos,  $-1/\tau_1$  e  $-1/\tau_2$ , zeros,  $-1/\tau_3$ , e tempo morto,  $\theta$

– vide Tabela 3.1) e  $\tau_{cl}$  representa a constante de tempo da função de desempenho em malha fechada, que representa a velocidade desejada para a resposta em malha fechada. A constante  $\tau_{cl}$  permite estabelecer uma relação entre a velocidade da resposta em malha fechada e aberta, quanto menor o seu valor em relação a constante de tempo em malha aberta,  $\tau$ , mais rápida será a resposta em malha fechada, no entanto mais sensível às incertezas será a resposta. O valor de  $\tau_{cl}$  é então determinado de acordo com o desempenho desejado para a malha de controle.

A determinação de  $G_n(s)$  pode ser feita realizando o caminho inverso da Equação 3.5, ou seja, através dos parâmetros de ajuste do controlador determinar os parâmetros do modelo do processo, neste caso, do filtro. Assim, por exemplo, para um modelo representado por uma função de transferência de primeira ordem,  $G_A$ :

$$G_A(s) = \frac{K}{\tau s + 1} \quad (3.6)$$

cujos parâmetros a serem determinados a partir dos parâmetros de sintonia do controlador PID podem ser representados pela relação a seguir:

$$P = [K, \tau] = g(Kp, Ti, Td, \tau_{cl}) \quad (3.7)$$

De acordo com o método IMC, para a referida estrutura do modelo de planta é possível encontrar as seguintes restrições para os parâmetros de um controlador PI:

$$\begin{aligned} KK_p &= \frac{\tau}{\tau_{cl}} \\ Ti &= \tau \end{aligned} \quad (3.8)$$

rearranjando-se em função dos parâmetros do modelo:

$$\begin{aligned} \tau &= Ti \\ K &= \frac{Ti}{Kp\tau_{cl}} \end{aligned} \quad (3.9)$$

logo,

$$G_A(s) = g(Kp, Ti, \tau_{cl}) = \frac{Ti}{Kp\tau_{cl}(Tis+1)} \quad (3.10)$$

Como visto, é possível escrever o modelo de processo como uma função dos parâmetros do controlador e de  $\tau_{cl}$ . No entanto, uma vez que não se conhece as atuais condições de desempenho do controlador a metodologia proposta admite que o valor de  $\tau_{cl}$  também é desconhecido, sendo este também um parâmetro a ser encontrado.

No exemplo apresentado, os parâmetros do modelo  $G_A$  a serem determinados resumem-se a apenas uma variável desconhecida ( $\tau_{cl}$ ), porém dependendo da estrutura escolhida para representar o modelo do processo, o número de parâmetros a serem determinados aumenta. Modelos de ordem mais elevada apresentam um maior número

de parâmetros desconhecidos, ou seja, um maior número de graus de liberdade para o problema de identificação a ser resolvido.

Dada à possibilidade de obter os parâmetros do filtro  $Gn(s)$  através dos parâmetros do controlador e das restrições do método IMC, é necessário então escolher o formato e os parâmetros do modelo do filtro que melhor representam o processo, uma vez que  $Gn(s)$  é dado como um modelo tão próximo de  $Gp(s)$  quanto possível. Para a escolha da estrutura e dos parâmetros é proposto um teste com quatro candidatos, pré-estabelecidos, a estrutura para o modelo de função de transferência que representará  $Gn(s)$ . Estes modelos são apresentados nas Tabela 3.1.

**Tabela 3.1:** Formatos de função de transferência para representar o processo, utilizados para determinação de  $Gn(s)$ .


	<i>Primeira ordem</i>	<i>Segunda ordem</i>	<i>Primeira ordem com tempo morto</i>	<i>Segunda ordem com tempo morto</i>
Estrutura do Modelo do Filtro	$\frac{K}{\tau_s + 1}$	$\frac{K}{(\tau_1 s + 1)(\tau_2 s + 1)}$	$\frac{K}{\tau_s + 1} e^{-\theta s}$	$\frac{K(\tau_3 s + 1)}{(\tau_1 s + 1)(\tau_2 s + 1)} e^{-\theta s}$

Estas quatro estruturas de modelo foram escolhidas, dada sua capacidade de representação de diversas dinâmicas de processos. Mesmo processos de elevada ordem podem ser representados através de algum destes modelos de forma satisfatória. A determinação dos parâmetros de cada uma dessas estruturas é feita de forma análoga ao exemplo mostrado para obtenção dos parâmetros de  $G_A(s)$ , sendo então realizado o mesmo procedimento, para determinação dos parâmetros de cada um dos candidatos a modelo de filtro, utilizando como restrições as relações da tabela de ajuste IMC e os parâmetros de sintonia do controlador PI/PID. O número de graus de liberdade do modelo foi determinado através da relação entre os parâmetros de cada estrutura de modelo e as condições de restrição estabelecidas pelo método. Essas relações que foram obtidas assim como as relações do método IMC utilizadas encontram-se no Apêndice B.

Os testes para escolha da estrutura utilizada para o modelo do filtro são realizados com cada um dos quatro candidatos à estrutura, visando a obtenção do par  $Gn(s)$  e  $\hat{d}$  que minimiza a soma da raiz do erro quadrado médio –  $RMSE$  (do inglês *root mean squared error*) de  $y$  e  $u$ ,  $RMSE_y$  e  $RMSE_u$ , dados como:

$$RMSE_y = \sqrt{\frac{\sum (y - y_{sim})^2}{n}} \text{ e } RMSE_u = \sqrt{\frac{\sum (u - u_{sim})^2}{n}} \quad (3.11)$$

onde  $n$  é o número de amostras,  $y_{sim}$  e  $u_{sim}$  são obtidos conforme o esquema representado na Figura 3.3.



**Figura 3.3:** Esquema representativo do processo simulado.

Assim o modelo  $Gn(s)$  é equivalente ao modelo que apresenta o menor valor para a seguinte função objetivo:

$$J_I(Kp, Ti, Td, y, u) = \min_x (RMSE_y + RMSE_u) \quad (3.12)$$

onde  $x$  é o vetor das variáveis de decisão da otimização, neste caso os parâmetros do filtro e a constante de tempo da função de desempenho em malha fechada,  $\tau_{cl}$ . A dimensão de  $x$  é equivalente ao número de graus de liberdade do modelo tomado como representante para o filtro. A otimização é feita com  $\hat{d}$  variável, por sua vez atualizado a cada iteração da otimização utilizando o  $Gn(s)$  encontrado a cada passo.

O filtro escolhido será aquele obtido com os parâmetros encontrados como solução da otimização que apresenta o menor valor para a função objetivo, dentre os quatro modelos testados. Esse filtro será utilizado para geração do sinal  $dud$  que juntamente com o sinal da ação de controle possibilita estimar de forma satisfatória o distúrbio não medido. O método de otimização utilizado nas análises foi o Nelder-Mead, também conhecido como poliedros flexíveis ou *simplex* (Nelder e Mead, 1965) e implementado por Lagarias *et al.* (1998). O método de Nelder-Mead foi escolhido devido sua capacidade de aplicação a problemas de otimização não lineares, para os quais não se tem conhecimento de suas derivadas. As relações de restrição do problema de otimização, dadas pelas relações de sintonia do método IMC, foram incluídas diretamente na função objetivo uma vez que a função de transferência do modelo é reescrita utilizando-as.


O estimador de distúrbios, bem como o sinal estimado do distúrbio obtido por meio dele, podem ser utilizados como ferramenta auxiliar em várias áreas de controle relacionadas à auditoria e manutenção de malhas de controle. As próximas seções deste capítulo apresentam outras possíveis finalidades para a ferramenta e metodologia proposta para o estimador de distúrbios.

A Tabela 3.2 descreve sucintamente os 5 passos empregados para se determinar o modelo da planta empregado como filtro no procedimento proposto.


**Tabela 3.2:** Algoritmo de determinação de  $Gn(s)$  e estimação de  $\hat{d}$ .

Com os parâmetros do controlador ( $Kp, Ti, Td$ ), os sinais do processo ( $y$  e  $u$ ) e valores iniciais para as variáveis de decisão de cada modelo é iniciado o processo de otimização, onde cada iteração é dada como:

1. Com os valores para as variáveis de decisão é obtido um  $Gn_i(s)$  e de posse de  $y$  e  $u$  é gerado o sinal  $dud_i$ , através de simulação utilizando o esquema apresentado na Figura 3.4;

**Figura 3.4:** Esquema representativo para obtenção do sinal  $dud_i$ 

2. Os sinais  $dud_i$ , gerado na etapa 1, e ação de controle  $u$  são utilizados como variáveis na regressão linear apresentada na Equação 3.4 para obtenção do sinal  $\hat{d}_i$ ;
3. Com  $C(s)$ ,  $Gn_i(s)$  e  $\hat{d}_i$  é gerada uma saída simulada  $y_{sim_i}$  e uma ação de controle simulada  $u_{sim_i}$ , conforme o esquema representado na Figura 3.5;

**Figura 3.5:** Esquema representativo do processo simulado iterativo.

4. Com  $y, y_{sim_i}, u$  e  $u_{sim_i}$  é calculada a soma de  $RMSE_{y_i}$  e  $RMSE_{u_i}$ .
5. O procedimento é realizado até a obtenção da convergência ou a tolerância ser atingida.

## 3.2 Identificação Do Modelo Nominal Da Planta

A presença de distúrbios não medidos dificulta o processo de identificação uma vez que tem efeito direto na saída do processo podendo levar a modelos identificados de baixa acuracidade em relação ao modelo processo. Uma vez que é possível ter uma estimativa do sinal do distúrbio não medido que está ocorrendo no processo é possível então utilizar deste conhecimento para minimizar seu efeito no processo de identificação.

A metodologia apresentada para estimação do distúrbio não medido envolve um processo sequencial onde se utiliza uma estrutura de modelo genérico, cujos parâmetros são ajustados a fim de minimizar o erro entre os dados simulados e os dados reais,

utilizando o sinal estimado para o distúrbio não medido. Desta forma é possível admitir que o modelo obtido como filtro na etapa de desenvolvimento do estimados de  $DNM$ s apresenta uma boa capacidade de representar o modelo do processo, dentro do conjunto de dados utilizados, podendo então ser caracterizado como um modelo identificado a partir de uma estimativa do distúrbio não medido. A fim de verificar a influência do distúrbio não medido durante o processo de identificação, bem como se a sua estimativa é suficiente para obter-se um modelo identificado com uma boa capacidade de previsão do modelo do processo serão propostas duas metodologias para identificação. Uma utiliza somente os dados normais de processo e o conhecimento do distúrbio estimado enquanto a outra utiliza dados de processo obtidos mediante pequenas perturbações no processo.

Para a etapa de identificação dos modelos, em ambas as situações, é proposta a utilização de estruturas de modelos do tipo ARX, Box-Jenkins e N4SID. Dentre os métodos de otimização disponíveis para determinação dos parâmetros do modelo ARX foi utilizado o método dos mínimos quadrados. Os parâmetros dos modelos Box-Jenkins foram determinados utilizando um algoritmo Gauss-Newton iterativo (Ljung, 1998) para minimizar um critério de erro quadrático, enquanto os modelos do tipo N4SID foram determinados conforme o algoritmo proposto por Overschee e Moor (1994), maiores detalhes a respeito destes métodos de identificação podem ser encontrados no Apêndice A.

A escolha da estrutura do modelo ARX foi feita através de varredura nas ordens dos polinômios que constituem o modelo, onde  $na$  (ordem do polinômio  $A(q)$ ) e  $nb$  (ordem do polinômio  $B(q)$  mais 1) foram varridas dentro de um intervalo de 1 a 10 e  $nk$  (número de atrasos da entrada para saída expressos como zeros do polinômio  $B(q)$ ) dentro de um intervalo de 0 a 100. Como critério de escolha, para o melhor candidato a modelo foi utilizada a função perda  $V$ , dada como o erro quadrático para a estrutura em questão, calculada como a Equação 3.13.

$$V = \det \left\{ \frac{1}{N} \sum_1^N \varepsilon(t|\theta) [\varepsilon(t|\theta)^T] \right\} \quad (3.13)$$

onde  $N$  é o conjunto total de dados,  $\varepsilon(t|\theta) = z(t) - \hat{z}(t|\theta)$  representa o erro de previsão (onde  $z$  é o conjunto de dados de saída utilizado na modelagem e  $\hat{z}(t|\theta)$  a saída estimada) e  $\theta$  é o vetor de parâmetros do modelo polinomial.

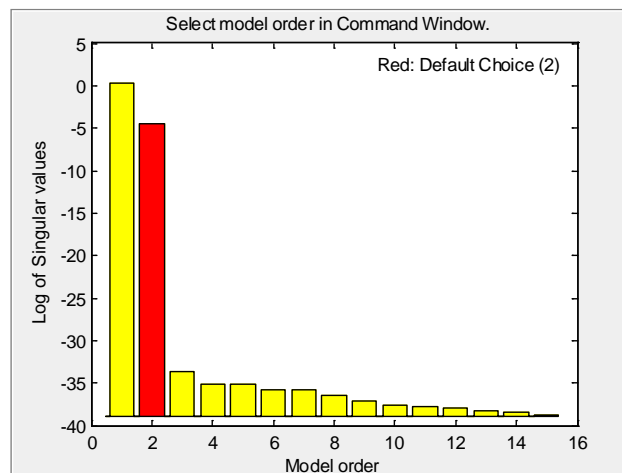
Desta forma a estrutura, e seus respectivos parâmetros, que apresentam menor valor para a função perda pode ser admitida como aquela que apresenta melhor ajuste perante os dados de validação.

A escolha da estrutura do modelo Box-Jenkins foi realizada em conformidade com a escolha da estrutura do modelo ARX, ou seja, como ordem do polinômio  $B(q)$  da estrutura Box-Jenkins foi utilizada a mesma ordem encontrada para este polinômio na estrutura ARX, de forma análoga definiu-se o parâmetro de atraso  $nk$  para a estrutura Box-Jenkins igual ao valor encontrado para estrutura ARX. A ordem do polinômio  $F(q)$ ,  $nf$ , foi admitida como igual a ordem do polinômio  $A(q)$ ,  $na$ , encontrada para a estrutura ARX. As ordens  $nc$  e  $nd$  dos polinômios  $C(q)$  e  $D(q)$ , respectivamente, foram



determinadas através de varredura dentro de um intervalo de 1 a 5, sendo as ordens escolhidas como a combinação que apresentou menor valor para função perda  $V$ .

A escolha da ordem do modelo  $N4SID$  foi feita através de varredura dentro do intervalo 1 a 15 sendo determinada com base nos valores singulares das matrizes de Hankel, dos dados de entrada e saída do sistema. Desta forma a ordem para o modelo  $N4SID$  pode ser determinada detectando uma lacuna entre os valores singulares. Por exemplo, na Figura 3.6 é apresentado o gráfico para os valores singulares da matriz de Hankel avaliada em cada ordem dentro de um intervalo de varredura de 1 a 15 para um conjunto de dados genérico.



**Figura 3.6:** Representação da escolha da ordem do modelo  $N4SID$ .

Conforme a Figura 3.6 a ordem escolhida para o modelo, neste exemplo, seria 2.

Como critério de validação entre os modelos encontrados, por cada um dos métodos pode-se calcular o índice percentual de ajuste baseado na razão entre a norma euclidiana de erro do processo de predição e a norma euclidiana do erro médio normalizado, determinado conforme a Equação 3.14, que expressa a capacidade de reprodução da saída  $z$  através do modelo identificado dado o mesmo sinal de entrada.

$$Fit = \left( 1 - \frac{\|z(t) - \hat{z}(t|\theta)\|}{\|z(t) - \bar{z}\|} \right) \cdot 100 \quad (3.14)$$

onde  $z(t)$  é o conjunto de dados de saída utilizado na modelagem,  $\hat{z}(t|\theta)$  a saída estimada pelo modelo) e  $\bar{z}$  é a média de  $z(t)$ .

### 3.2.1 Identificação Direta em Malha Fechada utilizando o Distúrbio não Medido Estimado – Não intrusiva

O modelo obtido para o filtro é capaz de estimar a saída do processo, nas condições em que foi determinado (ou seja utilizando como dados a ação de controle, a saída do processo e o distúrbio não medido estimado) uma vez que sua determinação envolveu um procedimento de otimização com o objetivo de minimizar o erro entre a saída real do processo e a saída simulada obtida a partir de uma estimativa para o distúrbio não medido presente no processo. Pode-se então admitir, que o modelo do filtro corresponde a um modelo obtido através de um método de identificação em malha fechada que utiliza a informação do distúrbio não medido.

No entanto a solução obtida para a otimização realizada na determinação do filtro será exata em relação à real, ou seja a solução da otimização é igual aos parâmetros do modelo, somente quando  $\hat{d}$  é idêntico a  $d$  e isto não ocorrerá, pois o  $\hat{d}$  é obtido por meio de regressão linear simples o que acarreta na geração de um erro variável apresentando sempre um desvio, mesmo que pequeno, entre os sinais  $\hat{d}$  e  $d$ . Em virtude deste fato o modelo encontrado como filtro pode não representar, a depender da finalidade para a qual é realizada a identificação, de forma coerente o modelo do processo. Apesar disto o conhecimento do distúrbio estimado por sua vez pode auxiliar neste processo uma vez que dados em condição normal de operação, de uma forma geral, não possuem informações suficientes para uma boa identificação do processo, ou seja, os dados coletados não apresentam excitação suficiente para obtenção de um modelo identificado preciso.

Para auxiliar neste processo de identificação, onde têm-se em mão apenas dados de operação normal, é proposta a identificação do modelo do processo através da metodologia apresentada na seção anterior, utilizando como sinal de entrada a ação de controle ( $u$ ) e de saída o sinal estimado para saída da planta ( $\hat{w}$ ), obtido através da subtração entre a saída do sistema ( $y$ ) e o distúrbio estimado ( $\hat{d}$ ), em outras palavras a saída estimada para o processo pode ser dada como:

$$\hat{w} = y - \hat{d} \quad (3.15)$$

Ao utilizar como saída o sinal  $\hat{w}$  pretende-se reduzir a influência do distúrbio não medido no processo de identificação, resultando em modelos identificados ainda mais precisos para representação do processo em estudo.

### 3.2.2 Identificação Direta em Malha Fechada com Perturbação

Este procedimento de identificação é análogo ao procedimento descrito na seção anterior. Porém, neste tipo de abordagem são utilizados dados de entrada e saída obtidos a partir de algum tipo de perturbação no sistema, ou seja, através de uma ação intrusiva na malha de comportamento previamente conhecido. Essas perturbações são realizadas com a finalidade de se obter dados suficientemente ricos que permitam a extração de informações em relação às características dinâmica e estática do sistema. Neste tipo de identificação as perturbações podem ser realizadas na entrada do sistema, como por exemplo, uma mudança de *setpoint* ou uma perturbação direta na entrada da planta, como um distúrbio na carga ou perturbação no *u-bias*. O tipo de perturbação ideal para a obtenção de um bom modelo identificado é dependente da complexidade do modelo que descreve o processo a ser identificado e também dos distúrbios não medidos que atuam no processo. Em virtude disto é possível encontrar na literatura trabalhos voltados ao planejamento de perturbações para identificação de modelos de processo como, por exemplo, o trabalho de Gevers *et al.* (2008). Vale salientar que em alguns casos a realização de perturbações específicas podem ser inviáveis, uma vez que a depender do sistema podem comprometer as condições operacionais.

### 3.3 Potencial de Redução de Variabilidade Estimado (*VRE*)

Em virtude da recorrência de malhas de controle que apresentam desempenho aquém de seu potencial real, decorrente de fatores tais como a presença de incertezas internas (discrepância entre o modelo utilizado no ajuste do controlador e o modelo atual da planta) e incertezas externas (distúrbios não medidos).

As metodologias descritas nas seções anteriores descrevem técnicas que auxiliam na detecção destes dois fatores cruciais na avaliação do desempenho de uma malha de controle. Desta forma, uma vez estimados os modelos da planta e do distúrbio não medido presente no processo é possível então realizar uma estimativa do potencial de melhoria do desempenho desta malha. Uma alternativa para a quantificação deste potencial é através da análise sobre a variância do sinal de saída do processo, calculado como:

$$\sigma^2 = \frac{1}{n-1} \sum (y - \bar{y})^2 \quad (3.16)$$

onde  $\sigma^2$  é a variância,  $n$  é o número de amostras da saída do processo ( $y$ ) e  $\bar{y}$  é a média do sinal  $y$ . Processos com alta variabilidade em seus produtos finais podem indicar que o atual ajuste do controlador é insatisfatório, podendo então possuir um potencial de melhoria.

Esta seção apresenta uma alternativa para quantificar o potencial de melhoria do desempenho de uma dada malha de controle decorrente de modificações no ajuste do controlador sem a necessidade de testes intrusivos. Propõe-se a determinação da redução de variabilidade estimada, ou *VRE*, este índice tem por objetivo traduzir o quanto da variabilidade da saída do processo pode ser reduzida ou acrescida em decorrência de uma modificação no ajuste do controlador sendo calculado como a razão entre a variância futura estimada para o sinal de saída do processo ( $\hat{\sigma}_2^2$ ) e a variância atual deste sinal ( $\sigma_1^2$ ), subtraída por 1, isto é:

$$VRE = \frac{\hat{\sigma}_2^2}{\sigma_1^2} - 1 \quad (3.17)$$

Valores de *VRE* positivos indicam que a malha de controle pode ter sua variabilidade aumentada, sendo esse potencial de aumento tão maior quanto maior for o valor de *VRE*, enquanto valores negativos indicam que a malha de controle pode ter sua variabilidade reduzida, sendo esse potencial de redução tão maior quanto mais negativo for o valor de *VRE*.

A determinação de  $\hat{\sigma}_2^2$  é feita através de simulação, utilizando o esquema representado na Figura 3.3, onde  $Gn_i(s)$  é agora fixado como o modelo identificado utilizando a metodologia apresentada na seção 3.2,  $\hat{d}$  é o distúrbio estimado através da metodologia apresentada na seção 3.1, onde as saídas futuras são determinadas analisadas sob o comportamento esperado mediante alterações nos parâmetros do controlador. Desta forma é possível, assim, prever o comportamento que seria esperado para o sistema caso um ajuste específico para o controlador fosse colocado em prática. O potencial de alteração de variabilidade pode ser, então, predito comparando-se a variância atual da malha com a predita para a condição futura, tomando como referência a variância do sinal de saída do processo.

## Capítulo 4 – Estudo de Casos

Este Capítulo apresenta os testes realizados para validação das metodologias propostas no Capítulo 3. Foram utilizados quatro diferentes modelos de processo sob o efeito de dois tipos de distúrbios não medidos. As condições utilizadas nos testes, assim como os principais resultados obtidos, serão apresentadas e discutidos nas próximas seções.

### 4.1 Descrição dos Estudo de Casos

Para validar a metodologia proposta foram analisados cenários com modelos de processo representados por funções de transferência de primeira e segunda ordem com e sem tempo morto. A escolha destas estruturas foi feita levando em consideração que uma grande quantidade de processos pode ser representada por meio destas funções de transferência. Os controladores utilizados foram PIs e PIDs cujos parâmetros de sintonia foram determinados a fim de se obter três condições de operação diferentes para as malhas de controle. Para a primeira condição de operação (OP1) tem-se que a malha fechada possui velocidade de resposta mais lenta em relação a malha aberta, para a segunda condição de operação (OP2) tem-se que a malha fechada possui velocidade de resposta mais rápida em relação a malha aberta e para a terceira condição de operação (OP3) tem-se que a malha fechada possui velocidade de resposta equivalente da malha aberta. Os parâmetros de ajuste para os controladores, bem como os modelos utilizados como processos estão apresentados na Tabela 4.1.

**Tabela 4.1:** Modelos de processos utilizados nas análises e suas respectivas sintonias.

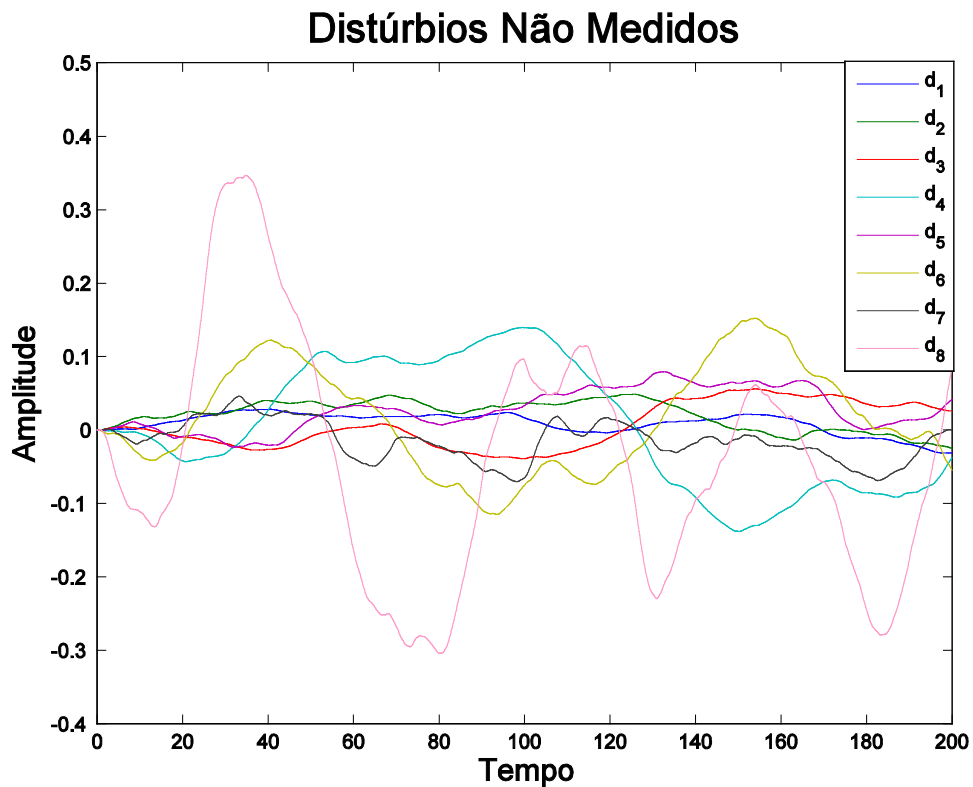
	Processo $Gp(s)$	OP1			OP2			OP3		
		$Kp$	$Ti$	$Td$	$Kp$	$Ti$	$Td$	$Kp$	$Ti$	$Td$
I	$\frac{1}{5s+1}$	0,23	2,3	0	1,27	1,64	0	0,74	3,72	0
II	$\frac{1}{15s^2+8s+1}$	0,26	3,56	0	0,725	4,07	0	0,77	5,92	0
III	$\frac{1}{9s^2+3s+1}$	0,39	2,78	0,69	1,20	3,14	0,639	1	5	4
IV	$\frac{-3s+1}{25s^2+40s+1}$	0,25	19,23	0	1,5	41,66	0	0,8	22,22	0
V	$\frac{8}{15s+1}e^{-5s}$	0,047	10,44	0	0,12	13,63	0	0,1	18,18	0
VI	$\frac{1}{5s+1}e^{-1s}$	0,18	2,16	0,55	1,7	5,07	0	0,72	4,23	0
VII	$\frac{2(3s+1)}{24s^2+10s+1}e^{-5s}$	0,15	7,5	3,33	0,46	8,68	0,67	0,3	7,69	0
VIII	$\frac{2s+1}{12s^2+3s+1}e^{-1s}$	0,34	2,28	0,59	1,7	5,7	0,11	0,68	2,53	0,59

Para representar o distúrbio não medido foram utilizados sinais randômicos, com distribuição normal, 'coloridos' por meio de funções de transferência,  $F(s)$ , a fim de obter uma representação coerente dos distúrbios presentes em processos reais. Os sinais randômicos utilizados para a geração dos *DNMs* foram definidos admitindo-se variância 1 e média 0 e gerados a partir de um bloco da ferramenta *simulink* do *software* Matlab 7.8.0 (bloco *Random Number*) gerador de números aleatórios sendo o valor da 'semente' limitado em um intervalo de  $[2 - 5] \times 10^3$  e escolhido de forma aleatória. Os filtros,  $F(s)$ , foram definidos como:

$$F(s) = \frac{K}{\tau^2 s^2 + 2\zeta\tau s + 1} \quad (4.1)$$

com  $\tau$  definido entre 10 e 25,  $K$  definido entre 1 e 2 e  $\zeta$  definido entre 0 e 2.

Dentre os sinais finais obtidos foram escolhidos 8 para representar o *DNM*  $d$  nos cenários estabelecidos. Esses sinais estão apresentados na Figura 4.1, onde  $d_i$  representa o *DNM* obtido com  $i = 1, 2, \dots, 8$ .



**Figura 4.1:** Sinais utilizados para representar o *DNM*  $d$ .

Os dados utilizados para representar as condições reais de operação foram gerados por simulação utilizando a ferramenta *simulink* do *software* Matlab 7.8.0, tendo-se como base um sistema de controle *feedback* clássico. O tempo de simulação foi de 200 com tempo de amostragem de 0,1 para todas as simulações. Foram obtidas 4002 amostras, referentes ao par  $y$  e  $u$ , para cada um dos 192 cenários analisados. Para a geração dos dados foi admitido o *DNM* como um distúrbio na carga, ou seja, um sinal adicional na entrada da planta. Essa escolha foi feita com o objetivo de validar a capacidade de estimação do *DNM*, através da metodologia proposta, independentemente de sua posição de entrada no sistema pois, sendo o sistema linear e invariante no tempo este fato não deve comprometer a eficiência da metodologia que, por sua vez, estima o sinal equivalente a um sinal aditivo na saída do processo.

Os resultados obtidos nas análises, sob a presença dos *DNMs* serão apresentados nas próximas seções.

## 4.2 Resultados e Discussões

A fim de analisar a eficácia das metodologias apresentadas foram realizados testes buscando validar alguns aspectos que envolvem as metodologias propostas, tanto para obtenção do estimador de distúrbios como na sua utilização para identificação de modelos de processo e para estimação do potencial de redução de variabilidade.

#### 4.2.1 Estimador de Distúrbios não Medidos

O estimador de distúrbios proposto é composto por uma função de transferência que atua como um filtro para geração de um sinal que em conjunto com a ação de controle são capazes, por meio de uma regressão linear, estimar o distúrbio não medido com uma boa acuracidade. Esta função de transferência, ou filtro, deve ser capaz de representar a dinâmica e estática do processo de forma satisfatória, com o objetivo de garantir uma pequena discrepância de modelo. No entanto nem sempre se tem informações suficientes a respeito do modelo que representa o sistema em seu estado atual, o que não permite a utilização do modelo da planta como modelo para o filtro. Neste caso, uma alternativa para determinação do filtro consiste primeiramente na escolha da estrutura do modelo. Em alternativa para esta escolha é proposta a realização de testes, em quatro formatos (pré-estabelecidos) de função de transferência a fim de determinar qual dessas estruturas, bem como seus parâmetros, é a mais adequada para representação do processo. Esta escolha é realizada através do resultado para a metodologia apresentada na Seção 3.1, onde o modelo de menor valor para a função objetivo, representada pela Equação 3.12, é dado como o mais adequado dentre eles, sendo então utilizada como modelo para o filtro.

Como apresentada na seção 3.1 a estimação do distúrbio não medido é feita através de regressão linear utilizando como variáveis os sinais  $u$  e  $dud$ . A alta correlação, esperada, entre os sinais  $u$  e  $dud$  e o sinal  $d$  foi comprovada através de análises utilizando como métrica o coeficiente de correlação linear de Pearson ( $r$ ) entre os sinais. As análises foram realizadas não somente com o intuito de confirmar as hipóteses de correlação levantadas na metodologia apresentada na seção 3.1, mas também com a finalidade de observar a sensibilidade da correlação entre os sinais  $dud$  e  $d$  em função dos parâmetros de um modelo genérico de filtro, uma vez que o sinal  $dud$  é nitidamente dependente do filtro. As análises foram feitas utilizando uma série de filtros cuja estrutura foi fixada em conformidade com a estrutura do modelo de processo ( $Gp(s)$ ) utilizado para geração dos sinais  $y$  e  $u$ , sendo alterado de forma aleatória o valor dos parâmetros que constituem o modelo do filtro. Através dos resultados foi possível observar, que independente dos parâmetros do modelo do filtro o sinal  $dud$  obtido através dele e de  $u$  apresentou alto grau de correlação em relação a  $d$  apresentando  $r$  entre 0,77 e 0,99. Os valores encontrados para  $r$ , entre  $u$  e  $d$ , ficaram entre -0,9 e -0,99. Esses resultados confirmam por sua vez a hipótese apresentada no parágrafo anterior. Os altos valores de  $r$  obtidos para a análise de  $dud$  em todas as situações analisadas mostraram que a dependência com os parâmetros do modelo do filtro é pouco relevante em relação ao grau de correlação do sinal gerado pelo filtro e o distúrbio não medido, sendo então a estrutura do modelo utilizado para o filtro mais importante em relação ao grau de correlação dos sinais do que os parâmetros que constituem este modelo.

Outra característica importante observada é que a qualidade do sinal estimado está intimamente relacionada com a escolha da variável dependente e independente utilizada na regressão. Durante as análises foi observado que para modelos de processo com a presença de tempo morto a escolha ideal era  $dud$  e  $-u$  como variável dependente e independente, respectivamente, enquanto em modelos de processo ausentes de tempo morto a escolha ideal era  $-u$  e  $dud$  como variável dependente e independente, respectivamente. Este fato pode ser explicado em virtude da inversão de causalidade observada entre os sinais, decorrente do fator de atraso. De acordo com Knockaert e Dhaene (2008) atrasos de tempo podem alterar a causalidade dos sinais, migrando um

sinal não causal para regiões causais e vice-versa. O negativo do sinal  $u$  foi utilizado em virtude dos valores negativos observados para os coeficientes de correlação entre esse sinal e o sinal  $d$ .

O processo de otimização utilizado para obtenção dos parâmetros do modelo do filtro busca minimizar o valor do  $RMSE$  entre os dados simulados obtidos de acordo com o esquema apresentado na Figura 3.3 e os dados de processo. Os parâmetros da regressão linear, utilizada para estimação do distúrbio não medido através de  $d$  e  $u$ , foram encontrados através do método dos mínimos quadrados.

Os testes foram feitos utilizando os modelos presentes na Tabela 4.1, como candidatos a estrutura do modelo do processo,  $Gp(s)$ . As análises foram feitas buscando validar o método, através de sua capacidade de estimação do distúrbio não medido, sob o ponto de vista de sua sensibilidade a diferentes valores iniciais para as variáveis de decisão,  $X_0$ . Para isto, foram utilizados 11 vetores com comprimento igual ao número de graus de liberdade ( $k$ ) do formato do modelo a ser ajustado, com elementos iguais entre si, ou seja:

$$X_{0,i} = [x_{0,i} \ x_{0,i} \ \dots \ x_{0,i}]_{1 \times j} \quad j = 1, 2, \dots, k \quad (4.2)$$

$$x_{0,i} = i \quad i = 1, 2, \dots, 11 \quad (4.3)$$

Por exemplo, para um problema cujo grau de liberdade é  $k = 3$  o oitavo valor inicial para as variáveis de decisão será dados como:

$$X_{0,8} = [8 \ 8 \ 8]_{1 \times 3} \therefore x_{0,8} = 8 \quad (4.4)$$

Sob o ponto de vista de sensibilidade, dos 11 pontos testados como valores iniciais para as variáveis de decisão do problema de otimização (em cada um dos cenários analisados) foram obtidos em alguns casos mais de uma solução para o problema de otimização, o que demonstra uma sensibilidade aos valores iniciais utilizados para resolução do problema de otimização. Essa sensibilidade em relação aos valores iniciais apresentada nos resultados já era esperada em virtude da quantidade de mínimos locais que o problema de otimização possui. Desta forma esse problema poderia ser resolvido através da utilização de um algoritmo de otimização global, no entanto esses algoritmos demandam, geralmente, de um maior custo computacional, podendo não refletir de fato numa melhoria dos resultados obtidos pelo método. Uma outra alternativa é a realização da metodologia dentro de um intervalo pré-definido para os valores iniciais do problema de otimização sendo a solução determinada como aquela que apresentasse menor valor para função objetivo. Nesse trabalho foi escolhida a segunda alternativa, onde, desta forma, o filtro é determinado a como a solução que apresentou menor valor para função objetivo dentre os resultados obtidos para os diferentes valores iniciais testados para resolução do problema de otimização.

Uma vez que a metodologia estima o  $DNM$  como um sinal adicional na saída da planta ( $d_{saída}$ ), logo, sendo os sistemas de controle, nos estudo de casos analisados, lineares e invariantes no tempo as análises dos sinais de  $DNMs$  estimados ( $\hat{d}$ ) devem ser realizadas tendo como referência o sinal  $d_{saída}$ , ou seja:



$$d_{saída} = G_p(s)d_{entrada} \quad (4.5)$$

onde  $d_{entrada}$  representa o *DNM* como um distúrbio na carga (sinal adicional na entrada da planta) e  $G_p(s)$  é o processo. O processo representado na Equação 4.5 converte o sinal como um distúrbio na carga ao sinal equivalente como um distúrbio na saída. Assim, considerando cada um dos sinais  $d_i$  apresentados na Figura 4.1 como um  $d_{entrada}$  existirá um  $d_{saída}$  diferente para cada modelo  $G_p(s)$ . Desta forma, os *DNMs* estimados serão comparados com os  $d_{saída}$ , respectivos ao  $G_p(s)$  em análise.

Os modelos de filtro encontrados como solução do problema de otimização para o ponto de operação OP3 com os *DNMs*  $d_1, d_2, d_3$  e  $d_4$  estão apresentados na Tabela 4.2. Os modelos de filtro obtidos para os demais *DNMs* e pontos de operação encontram-se no Apêndice C.

**Tabela 4.2:** Modelos de Filtros encontrados para serem aplicados na obtenção de  $\hat{d}$  para os *DNM*  $d_1, d_2, d_3$  e  $d_4$  no ponto de operação OP3.

	Processo $G_p(s)$	Modelo de Filtro			
		$d_1$	$d_2$	$d_3$	$d_4$
I	$\frac{1}{5s+1}$	$\frac{0,97}{3,72s+1}$	$\frac{0,99}{3,72s+1}$	$\frac{0,98}{3,72s+1}$	$\frac{0,98}{3,72s+1}$
II	$\frac{1}{15s^2+8s+1}$	$\frac{0,96}{6s+1}$	$\frac{0,99}{5,92s+1}$	$\frac{0,97}{5,92s+1}$	$\frac{0,97}{5,92s+1}$
III	$\frac{1}{9s^2+3s+1}$	$\frac{0,96}{20s^2+5s+1}$	$\frac{0,97}{20s^2+5s+1}$	$\frac{0,94}{20s^2+5s+1}$	$\frac{0,94}{20s^2+5s+1}$
IV	$\frac{-3s+1}{25s^2+40s+1}$	$\frac{0,96}{22,22s+1}$	$\frac{0,96}{22,22s+1}$	$\frac{0,74}{22,22s+1}$	$\frac{0,74}{22,22s+1}$
V	$\frac{8}{15s+1}e^{-5s}$	$\frac{9,87}{18,2s+1}e^{-0,25s}$	$\frac{9,88}{18,2s+1}e^{-0,23s}$	$\frac{9,76}{18,2s+1}e^{-0,46s}$	$\frac{9,77}{18,2s+1}e^{-0,42s}$
VI	$\frac{1}{5s+1}e^{-1s}$	$\frac{0,97}{4,23s+1}$	$\frac{0,99}{4,23s+1}$	$\frac{0,97}{4,23s+1}$	$\frac{0,97}{4,23s+1}$
VII	$\frac{2(3s+1)}{24s^2+10s+1}e^{-5s}$	$\frac{3,23}{7,7s+1}e^{-0,25s}$	$\frac{3,28}{7,7s+1}e^{-0,12s}$	$\frac{3,12}{7,7s+1}e^{-0,35s}$	$\frac{3,12}{7,7s+1}e^{-0,28s}$
VIII	$\frac{2s+1}{12s^2+3s+1}e^{-1s}$	$\frac{0,97}{1,5s^2+2,53s+1}$	$\frac{0,98}{1,5s^2+2,53s+1}$	$\frac{0,98}{1,5s^2+2,53s+1}$	$\frac{0,98}{1,5s^2+2,53s+1}$

Os resultados obtidos para os demais distúrbios, i.e.  $d_5$  a  $d_8$ , bem como os resultados para os pontos de operação OP1 e OP2 estão apresentados no Apêndice C. Com base nestes resultados e como pode ser visto através da Tabela 4.2 os modelos encontrados como filtro apresentaram estrutura e parâmetros semelhantes a estrutura e aos parâmetros dos modelos de processo o que mostra a capacidade da metodologia em conseguir um modelo de filtro semelhante ao modelo do processo. No entanto, pôde-se constatar que em nenhum dos casos estudados, independentemente do ponto de operação, os modelos de filtro encontrados para os processos que apresentavam tempo morto, i.e. processos V a VIII, apresentou este parâmetro de forma adequada, sendo esta discrepância ainda mais pronunciada nos processos VI e VIII, nos quais nem a presença do parâmetro de atraso foi identificada. Uma possibilidade para estes resultados é que nos processos VI e VIII o parâmetro de tempo morto tem valor insignificante em relação à dinâmica do processo não representando atraso significativo na correlação dos dados  $u$  e

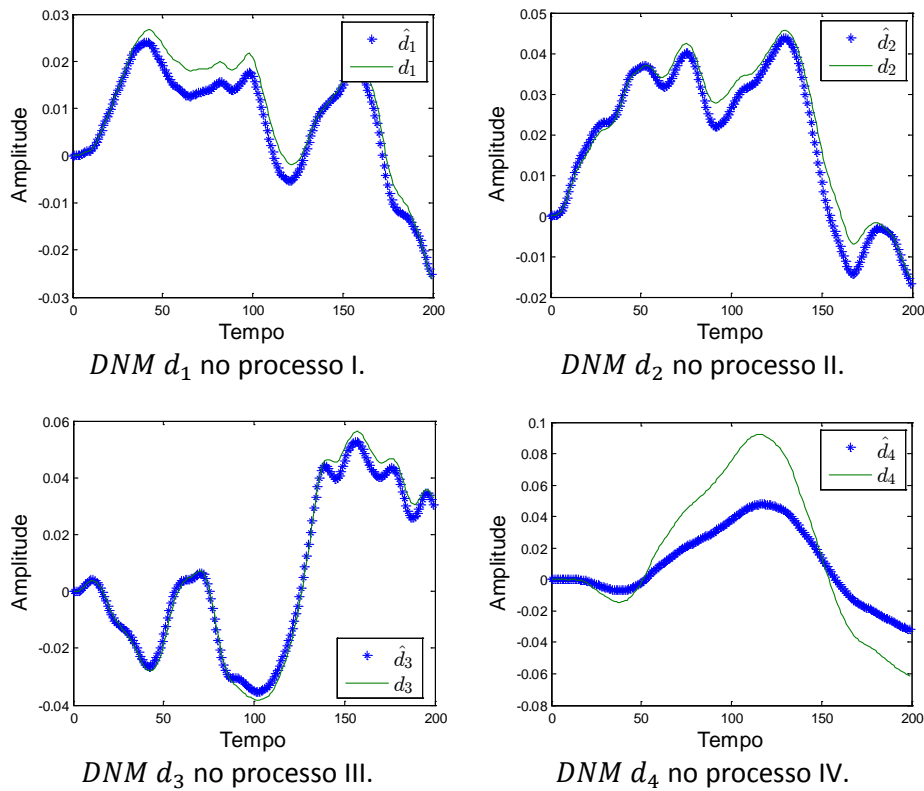
$dud$ , enquanto que nos processos V e VII o valor deste parâmetro é mais pronunciado em relação à dinâmica dos processos conseguindo refletir um atraso na correlação dos dados  $u$  e  $dud$ .

Os valores mínimos para a função objetivo, ou seja, a soma de  $RMSE_y$  e  $RMSE_u$ , encontrados pela otimização para o ponto de operação OP3 com os DNMs  $d_1, d_2, d_3$  e  $d_4$  estão dispostos e comparados com seus respectivos valores iniciais na Tabela 4.3. Os valores obtidos para os demais DNMs bem como os valores obtidos para a função objetivo no ponto ótimo para os pontos de operação OP1 e OP2 encontram-se no Apêndice C.

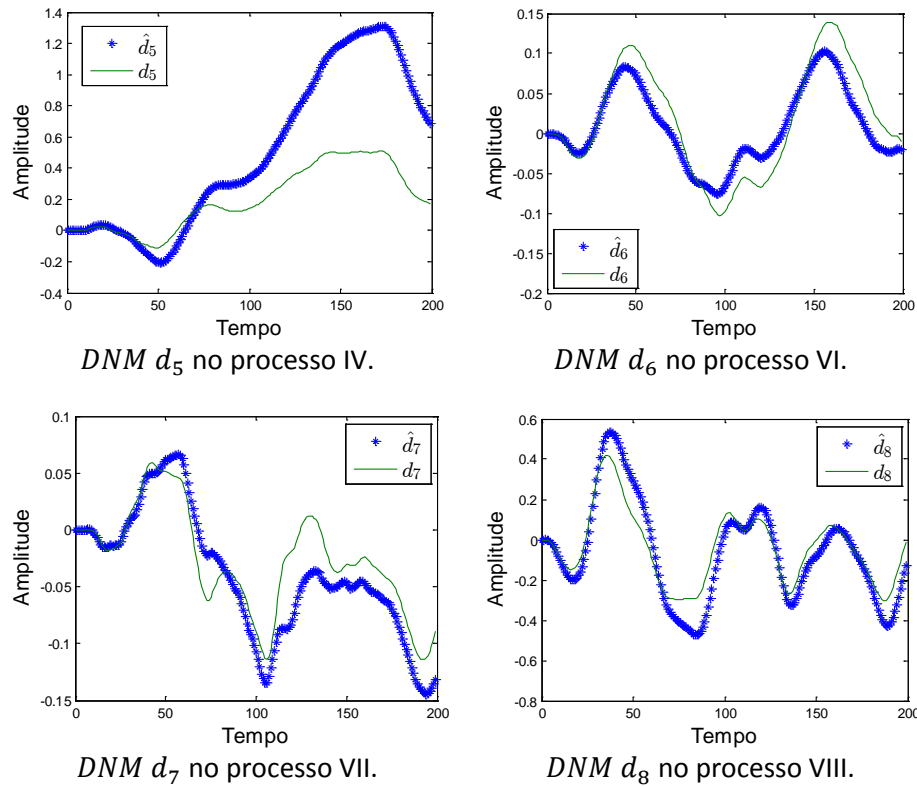
**Tabela 4.3:** Valor da função objetivo obtida como resultado da otimização para os ponto de operação OP3 com os DNMs  $d_1, d_2, d_3$  e  $d_4$ .

	Processo $Gp(s)$	Valor da Função objetivo avaliada no ponto inicial ( $X_0$ )( $\times 10^2$ )				Valor da Função objetivo para a solução( $\times 10^5$ )			
		$d_1$	$d_2$	$d_3$	$d_4$	$d_1$	$d_2$	$d_3$	$d_4$
I	$\frac{1}{5s+1}$	1,4	2,4	0,3	0,9	4,16	5,5	7,4	20
II	$\frac{1}{15s^2+8s+1}$	0,05	0,5	0,8	0,3	3,3	4,6	6	16,9
III	$\frac{1}{9s^2+3s+1}$	1,2	0,9	0,7	3,5	230	357	334	763
IV	$\frac{-3s+1}{25s^2+40s+1}$	1,8	2,78	1,7	9,4	0,71	1,2	0,5	2
V	$\frac{8}{15s+1}e^{-5s}$	2,3	6,3	7,9	14,5	2,15	3,4	13,6	40,7
VI	$\frac{1}{5s+1}e^{-1s}$	0,4	1,6	1,9	5,6	3,9	5,3	7,13	19,5
VII	$\frac{2(3s+1)}{24s^2+10s+1}e^{-5s}$	0,4	0,8	0,5	1,7	2,1	1,7	6,4	15,6
VIII	$\frac{2s+1}{12s^2+3s+1}e^{-1s}$	1,4	4,4	2,8	2	31	51	47,5	106


Como apresentado na Tabela 4.3 o problema de otimização consegue reduzir significativamente os erros entre os valores de  $y$  e  $u$  simulados em relação a seus valores de referência. As Figuras 4.2 à 4.7 apresentam os  $\hat{d}$  para os casos nas condições de operação OP1, OP2 e OP3, respectivamente.



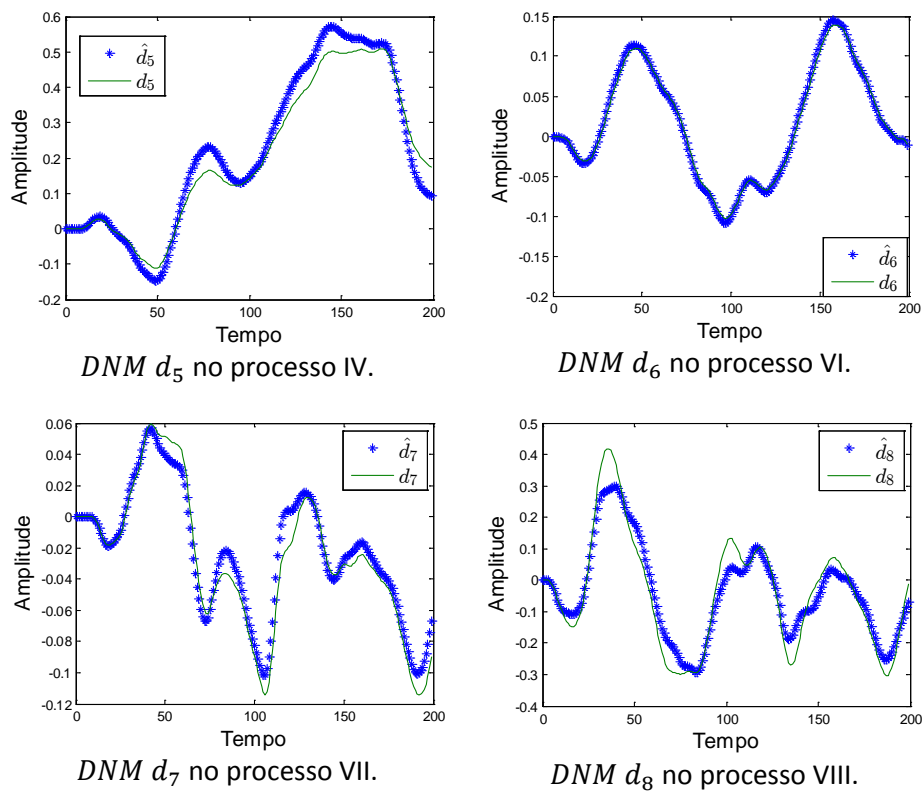
**Figura 4.2:** Distúrbio estimado, por cada um dos filtros encontrados, comparado ao distúrbio real para a condição de operação OP1.



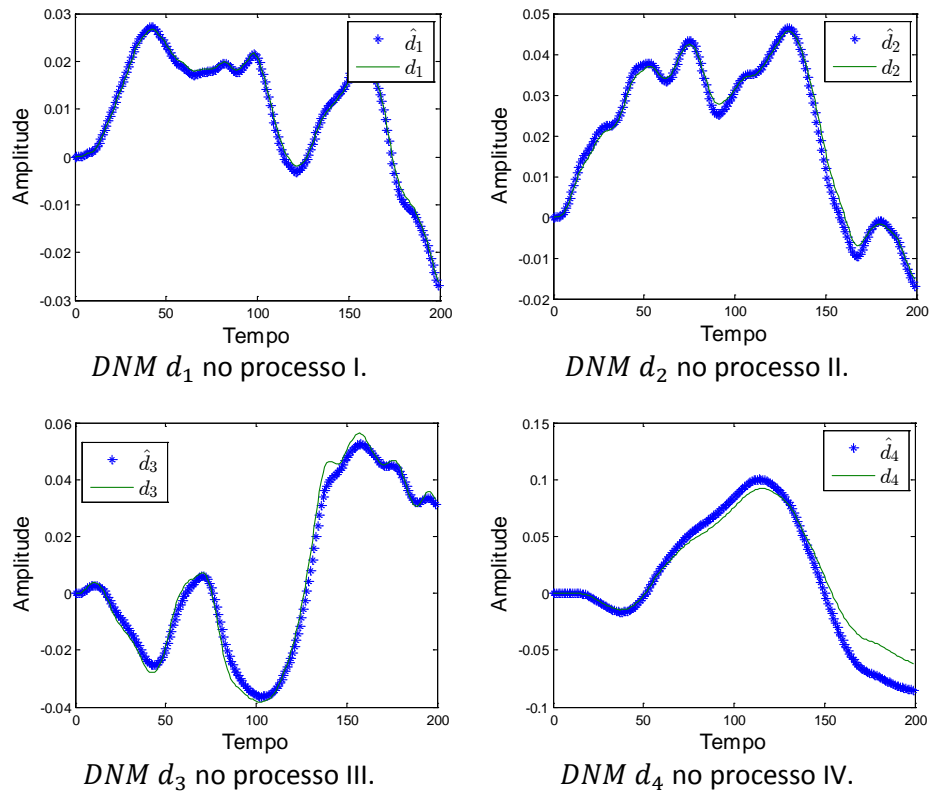
**Figura 4.3:** Distúrbio estimado, por cada um dos filtros encontrados, comparado ao distúrbio real para a condição de operação OP1.



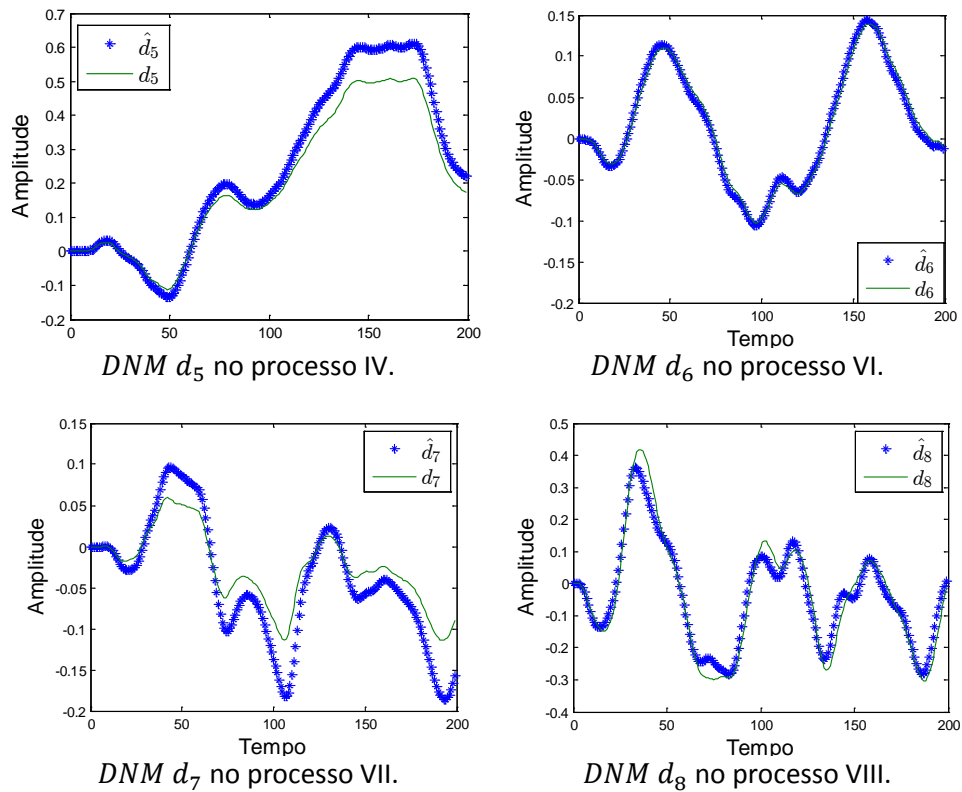
**Figura 4.4:** Distúrbio estimado, por cada um dos filtros encontrados, comparado ao distúrbio real para a condição de operação OP2.



**Figura 4.5:** Distúrbio estimado, por cada um dos filtros encontrados, comparado ao distúrbio real para a condição de operação OP2.



**Figura 4.6:** Distúrbio estimado, por cada um dos filtros encontrados, comparado ao distúrbio real para a condição de operação OP3.



**Figura 4.7:** Distúrbio estimado, por cada um dos filtros encontrados, comparado ao distúrbio real para a condição de operação OP3.

Através das Figuras 4.2 à 4.7 é possível ver que os sinais obtidos por meio dos estimadores de distúrbios, encontrados através da aplicação da metodologia proposta, apresentam comportamento *vero* similar ao comportamento do *DNM* real. A fim de quantificar a acuracidade do sinal  $\hat{d}$  em relação ao correspondente sinal  $d_{saída}$  foi calculado o *RMSE* entre estes dois sinais e os resultados encontrados para os casos com condição de operação OP1, OP2 e OP3 tendo como  $d_{entrada}$  os sinais  $d_i$  com  $i = 1, 2, 3, \dots, 8$  estão dispostos nas Tabelas 4.4 à 4.6.

**Tabela 4.4:** Acuracidade entre os sinais  $\hat{d}$  e  $d$ , medida através do valor do *RMSE* para o ponto de operação OP1.

	<i>Processo Gp(s)</i>	<i>Valor do RMSE entre <math>\hat{d}</math> e <math>d_{saída}</math> (<math>\times 10^3</math>)</i>							
		OP1							
		$d_1$	$d_2$	$d_3$	$d_4$	$d_5$	$d_6$	$d_7$	$d_8$
I	$\frac{1}{5s+1}$	3,3	2,5	5,3	13,4	4,8	30,9	12,3	58,5
II	$\frac{1}{15s^2+8s+1}$	9,2	3,8	10,2	24,8	6,11	27,6	11,9	53,5
III	$\frac{1}{9s^2+3s+1}$	2	1,7	3,1	7,3	3,19	13,3	13,5	68,8
IV	$\frac{-3s+1}{25s^2+40s+1}$	5,2	10,7	9,1	24,0	49,6	29,6	21,7	65,6
V	$\frac{8}{15s+1}e^{-5s}$	168	338	245,5	785	432	549	206	867
VI	$\frac{1}{5s+1}e^{-1s}$	5,5	3,6	9	22,0	5,9	29	12,2	58
VII	$\frac{2(3s+1)}{24s^2+10s+1}e^{-5s}$	20	41	29	96	53	73	26,1	136
VIII	$\frac{2s+1}{12s^2+3s+1}e^{-1s}$	2,5	2,6	3,8	8,6	4,6	15,9	18,8	95

**Tabela 4.5:** Acuracidade entre os sinais  $\hat{d}$  e  $d$ , medida através do valor do *RMSE* para o ponto de operação OP2.

	Processo $Gp(s)$	Valor do <i>RMSE</i> entre $\hat{d}$ e $d_{saída}$ ( $\times 10^3$ )							
		OP2							
		$d_1$	$d_2$	$d_3$	$d_4$	$d_5$	$d_6$	$d_7$	$d_8$
I	$\frac{1}{5s+1}$	2,8	3,4	4,7	12,4	5,5	15,7	8,6	49
II	$\frac{1}{15s^2+8s+1}$	2,8	3,3	5	13,5	5,4	16,6	6,6	46
III	$\frac{1}{9s^2+3s+1}$	1,1	1,8	1,7	3,8	3,3	5,7	6,3	21
IV	$\frac{-3s+1}{25s^2+40s+1}$	1	1,7	3,4	13,5	3,9	7,2	3,5	13
V	$\frac{8}{15s+1}e^{-5s}$	20	32	45,3	134,9	42,8	139	44	307
VI	$\frac{1}{5s+1}e^{-1s}$	0,9	0,9	1,4	3,7	1,5	4,6	2,7	15
VII	$\frac{2(3s+1)}{24s^2+10s+1}e^{-5s}$	6,4	11	12,3	33,4	16	32,4	10,1	62
VIII	$\frac{2s+1}{12s^2+3s+1}e^{-1s}$	2,9	4	5	13,3	6,5	16,9	9,8	50

**Tabela 4.6:** Acuracidade entre os sinais  $\hat{d}$  e  $d$ , medida através do valor do *RMSE* para o ponto de operação OP3.

	Processo $Gp(s)$	Valor do <i>RMSE</i> entre $\hat{d}$ e $d_{saída}$ ( $\times 10^3$ )							
		OP3							
		$d_1$	$d_2$	$d_3$	$d_4$	$d_5$	$d_6$	$d_7$	$d_8$
I	$\frac{1}{5s+1}$	0,8	1,1	1,5	4	1,5	4,9	1,9	13,2
II	$\frac{1}{15s^2+8s+1}$	1,5	1,7	2,6	7	2,7	9	3,5	26,5
III	$\frac{1}{9s^2+3s+1}$	1,9	2,4	3,1	8,2	3,9	10,5	7	38,3
IV	$\frac{-3s+1}{25s^2+40s+1}$	2,2	4,2	3,6	13,6	4,8	8,1	2,2	11,3
V	$\frac{8}{15s+1}e^{-5s}$	23	45	32	95,2	57,5	71	34,2	160,6
VI	$\frac{1}{5s+1}e^{-1s}$	1,2	1,4	2,1	5,8	2,2	7,2	3	20,9
VII	$\frac{2(3s+1)}{24s^2+10s+1}e^{-5s}$	18,5	35	33,7	97,9	47,9	82,2	32	174,4
VIII	$\frac{2s+1}{12s^2+3s+1}e^{-1s}$	1,9	2,7	2,8	6,4	5	10	10,6	39,13

Devido aos baixos valores encontrados para o *RMSE* entre os sinais  $\hat{d}$  e  $d_{saída}$  presentes nas Tabelas 4.4 à 4.6 e a capacidade dos *DNMs* estimados em representar os

*DNMs* reais vista nas Figuras 4.2 à 4.7 pode-se confirmar a alta capacidade do  $\hat{d}$  em representar o distúrbio não medido presente no processo, mostrando a eficiência da metodologia proposta para estimação de distúrbios não medidos. Através das Tabelas 4.4 à 4.6 é possível verificar, também, que a condição de operação OP1 foi a que apresentou de forma geral as maiores discrepâncias entre  $d$  e  $\hat{d}$ , em especial nos processos V e VII, independente da condição de operação analisada. O fato em comum nos dois processos é a presença de tempo morto com valor significativo em relação à dinâmica do processo e como visto através dos resultados apresentados para os modelos de filtro encontrados pela metodologia proposta, nos casos cujos processos eram V e VII o modelo encontrado como filtro apresentou maior discrepância em relação ao modelo do processo. Estes resultados permitem concluir uma perda da eficiência na estimação dos *DNMs* em sistemas que apresentam tempo morto significativo, vista a ineficiência da metodologia em estimar de forma coerente o valor do parâmetro de atraso do processo.

#### 4.2.2 Identificação do Modelo do Processo

Uma vez possível a estimação do sinal de distúrbio não medido presente no processo, é possível então aplicar a metodologia proposta para identificação do modelo de processo. Para geração dos resultados apresentados a seguir foram utilizados procedimentos de identificação direta em malha fechada sob diferentes pontos de vista. A primeira abordagem considera as situações onde se conhecem apenas os sinais de ação de controle e saída do processo, realizada a fim de verificar a utilidade de uma estimativa do distúrbio dentro do processo de identificação. A segunda abordagem compara os resultados da identificação não intrusiva, obtida utilizando o conhecimento do sinal estimado para o distúrbio não medido, proposta neste trabalho, com os resultados da identificação a partir de dados obtidos de forma intrusiva para o mesmo problema base.

#### Influência do conhecimento de uma estimativa para o distúrbio não medido

Para analisar a contribuição do conhecimento do distúrbio não medido no processo de identificação foram analisadas as situações onde não se tem conhecimento de  $\hat{d}$  desta forma os sinais utilizados para identificação são a ação de controle ( $u$ ) como entrada do modelo e a saída do processo como saída do modelo ( $y$ ). Na segunda situação é considerado que se conhece  $\hat{d}$ , dado como o sinal estimado a partir do estimador de distúrbios, e em virtude disto utiliza-se o sinal  $\hat{w}$  (dado como a diferença entre os sinais  $y$  e  $\hat{d}$ , conforme a Equação 3.15) como saída para o modelo e como entrada utilizou-se novamente o sinal da ação de controle.

Em ambas as situações os dados de entrada e saída foram tratados através da remoção da média de cada sinal. Este novo conjunto de dados foi dividido em duas partes iguais, onde a primeira parte foi utilizada para estimação do modelo enquanto a segunda metade foi utilizada para validação do modelo. Para a etapa de identificação dos modelos utilizados nos estudo de casos, foram testadas estruturas de modelos do tipo ARX, Box-Jenkins (*BJ*) e N4SID. O método de otimização utilizado para determinação dos parâmetros do modelo ARX foi o método dos mínimos quadrados. No caso do modelo Box-Jenkins seus parâmetros foram determinados através de um algoritmo Gauss-



Newton iterativo (Ljung, 1998), enquanto para o modelo N4SID foi determinado conforme o algoritmo proposto por Overschee e Moor (1994).

Os valores do índice *Fit* e as ordens dos polinômios das estruturas obtidas para o melhor candidato, em cada uma das estruturas testadas, (i.e. os modelos que apresentaram menor valor para a função perda  $V$ ), nas duas situações analisadas, utilizando os dados obtidos na condição de operação OP3 onde  $d_1$  era o distúrbio atuante estão apresentados nas Tabelas 4.7 e 4.8. Os resultados para os demais *DNMs* bem como para os demais pontos de operação encontram-se no Apêndice C.

**Tabela 4.7:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal  $y$ , para os processos sob o efeito do distúrbio  $d_1$ .

Processo	$ARX_{(y u)}$	Ordem dos polinômios [na, nb, nk]	$BJ_{(y u)}$	Ordem dos polinômios [nb, nc, nd, nf, nk]	$N4SID_{(y u)}$	Ordem do modelo N4SID
I	100	[2,3,0]	100	[3,2,2,2,0]	-155,62	2
II	100	[2,3,0]	100	[3,2,2,2,0]	-127,8	2
III	100	[3,3,0]	100	[3,2,2,2,0]	98,19	3
IV	100	[2,3,0]	100	[3,2,2,2,0]	-124,17	2
V	100	[2,3,0]	100	[3,2,2,2,0]	-158,57	2
VI	100	[2,3,0]	100	[3,2,2,2,0]	0,22	2
VII	100	[2,3,0]	99,99	[3,2,2,2,0]	-180,8	2
VIII	100	[3,3,0]	100	[3,2,2,3,0]	97,37	3

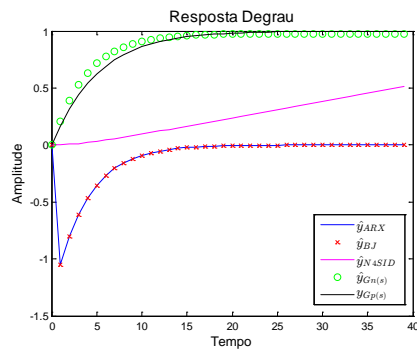
**Tabela 4.8:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal  $\hat{w}$ , para os processos sob o efeito do distúrbio  $d_1$ .

Processo	$ARX_{(\hat{w} u)}$	Ordem dos polinômios [na, nb, nk]	$BJ_{(\hat{w} u)}$	Ordem dos polinômios [nb, nc, nd, nf, nk]	$N4SID_{(\hat{w} u)}$	Ordem do modelo N4SID	Filtro $_{(\hat{w} u)}$
I	99,95	[2,2,1]	98,65	[2,2,2,2,1]	99,96	2	99,83
II	99,87	[2,2,1]	98,37	[2,2,2,2,1]	99,92	2	99,80
III	96,29	[3,2,0]	99,99	[2,2,2,3,0]	99,99	3	99,15
IV	99,80	[2,2,0]	99,45	[2,2,2,2,0]	99,90	2	99,90
V	99,83	[2,3,0]	99,99	[3,2,2,2,0]	99,96	2	99,84
VI	99,92	[2,2,1]	99,94	[2,2,2,2,1]	99,94	2	99,81
VII	100	[2,3,0]	100	[3,2,2,2,0]	99,72	2	99,72
VIII	99,25	[3,2,0]	99,99	[2,2,2,3,0]	99,99	4	99,61


Através dos valores obtidos para o índice *Fit* dispostos na Tabela 4.7 é possível verificar que os modelos ARX e Box-Jenkins tiveram maior capacidade em reproduzir os dados de saída utilizados na situação onde a saída do modelo foi dada como a saída do processo, no entanto na situação onde a saída do modelo foi dada como a saída estimada da planta as quatro metodologias conseguiram valores de índice *Fit* equivalentes entre si e próximos do valor ideal 100. O modelo identificado para o filtro foi comparado apenas

com os resultados onde  $\hat{w}$  foi utilizada como saída, porém vale salientar que o processo realizado para sua identificação foi feito tomando as condições onde a saída utilizada para o processo é  $y$ , porém utiliza na identificação do modelo de filtro o sinal  $\hat{d}$ .

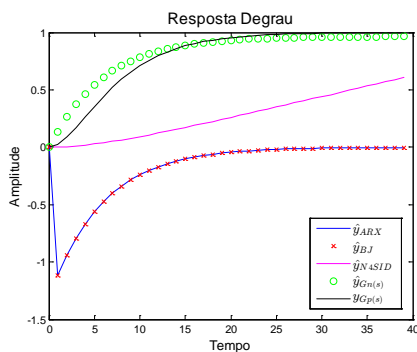
A fim de verificar a reprodutibilidade dos modelos identificados em representar o modelo do processo, foi realizada uma perturbação do tipo degrau em cada um dos modelos identificados sendo suas saídas comparados com a resposta esperada para o modelo do processo. Os resultados obtidos em ambas as condições de identificação obtidas para o ponto de operação OP3 com o *DNM*  $d_1$  encontram-se apresentados nas Figuras 4.8 à 4.11.



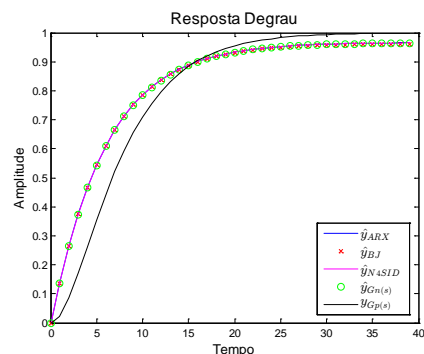
Processo I com  $y$  como saída.



Processo I com  $\hat{w}$  como saída.



Processo II com  $y$  como saída.



Processo II com  $\hat{w}$  como saída.

**Figura 4.8:** Comparação entre a resposta à uma perturbação degrau unitário nos modelos identificados.

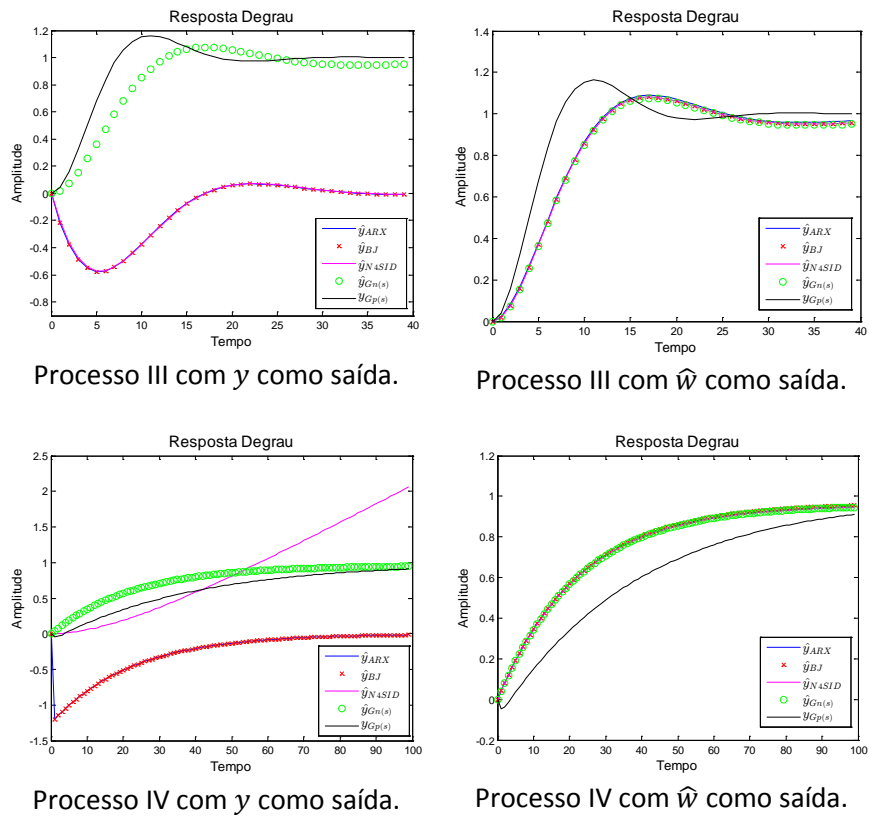


Figura 4.9: Comparação entre a resposta à uma perturbação degrau unitário nos modelos identificados.

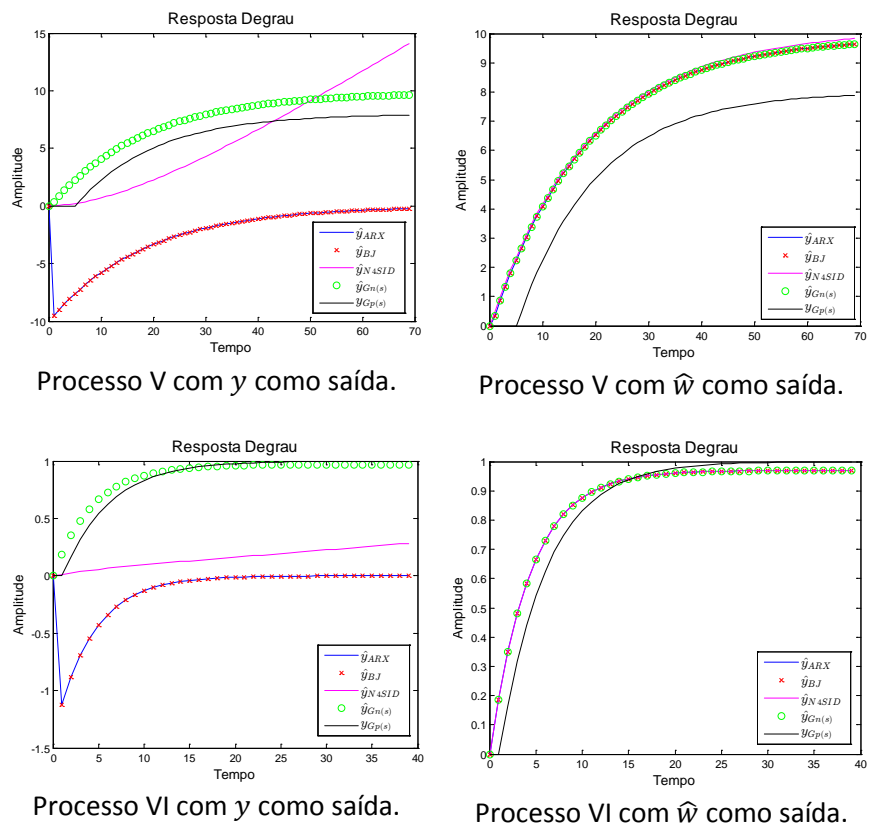
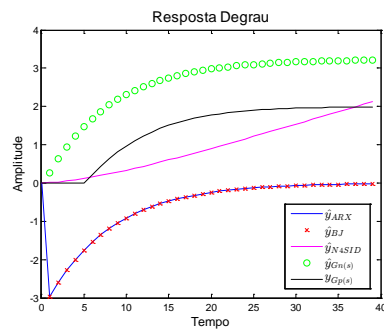





Figura 4.10: Comparação entre a resposta à uma perturbação degrau unitário nos modelos identificados.

Processo VII com  $y$  como saída.Processo VII com  $\hat{w}$  como saída.Processo VIII com  $y$  como saída.Processo VIII com  $\hat{w}$  como saída.


**Figura 4.11:** Comparação entre a resposta à uma perturbação degrau unitário nos modelos identificados.

Nas Figuras 4.8 à 4.11 as legendas  $\hat{y}_{ARX}$ ,  $\hat{y}_{BJ}$ ,  $\hat{y}_{N4SID}$  e  $\hat{y}_{Gn(s)}$  representam as saídas estimadas pelo modelo identificado através das estruturas ARX, N4SID e Filtro, respectivamente, e  $y_{Gp(s)}$  é a saída do modelo do processo. Através das Figuras 4.8 à 4.11 é possível verificar nitidamente a melhora na reprodutibilidade do modelo identificado mediante a utilização do sinal estimado para o distúrbio não medido do processo. É possível observar também que apesar das estruturas ARX e Box-Jenkins terem apresentado bons valores para o índice *Fit*, na situação onde a saída do modelo era dada como  $y$ , os modelos identificados apresentaram baixa capacidade de reprodutibilidade em relação ao modelos do processo. Nos casos onde o modelo do processo,  $Gp(s)$ , apresenta tempo morto (i.e., modelos V a VIII) nenhuma das abordagens utilizadas para identificação foi capaz de estimar este parâmetro com exatidão. Os resultados obtidos para os demais *DNMs* bem como para os demais pontos de operação foram equivalentes aos apresentados para o ponto de operação OP3 com o sinal  $d_1$ . Desta forma é possível concluir que o conhecimento de uma estimativa confiável do sinal de distúrbio não medido é de grande utilidade no processo de identificação quando apenas dados em condição normal de operação são conhecidos, uma vez que viabiliza a identificação de um modelo coerente em relação ao processo a ser identificado. É possível verificar também que os modelos de filtro identificados via metodologia proposta foram equivalentes aos modelos obtidos via estrutura ARX e Box-Jenkins uma vez que apresentaram índices *Fit* próximos entre si e semelhante capacidade de reprodutibilidade vista nas Figuras 4.8 à 4.11.

### Identificação Direta em Malha Fechada com Perturbações

Como visto na seção anterior, principalmente nos casos onde existia a presença de tempo morto no processo, os dados em condição normal de operação não conseguiram estimar seu valor de forma satisfatória. Desta forma a fim de auxiliar no procedimento de identificação para os modelos III e IV existe a possibilidade de realizar perturbações com a finalidade de excitar o sistema de forma a conseguir dados que capturem suas principais características dinâmicas e estáticas, possibilitando estimar com maior precisão o tempo morto do processo, por exemplo.

Para geração dos resultados foi utilizado um padrão único de perturbação com o sistema em malha fechada equivalente a uma sequência de degraus positivos e negativos intercalados, de amplitude 0,5 e -0,5, nos tempo de 10, 30, 50 e 70, 90 e 110 no  $u$ -bias do controlador, ou seja, diretamente na ação do controlador, conforme mostrado pela Figura 4.12.



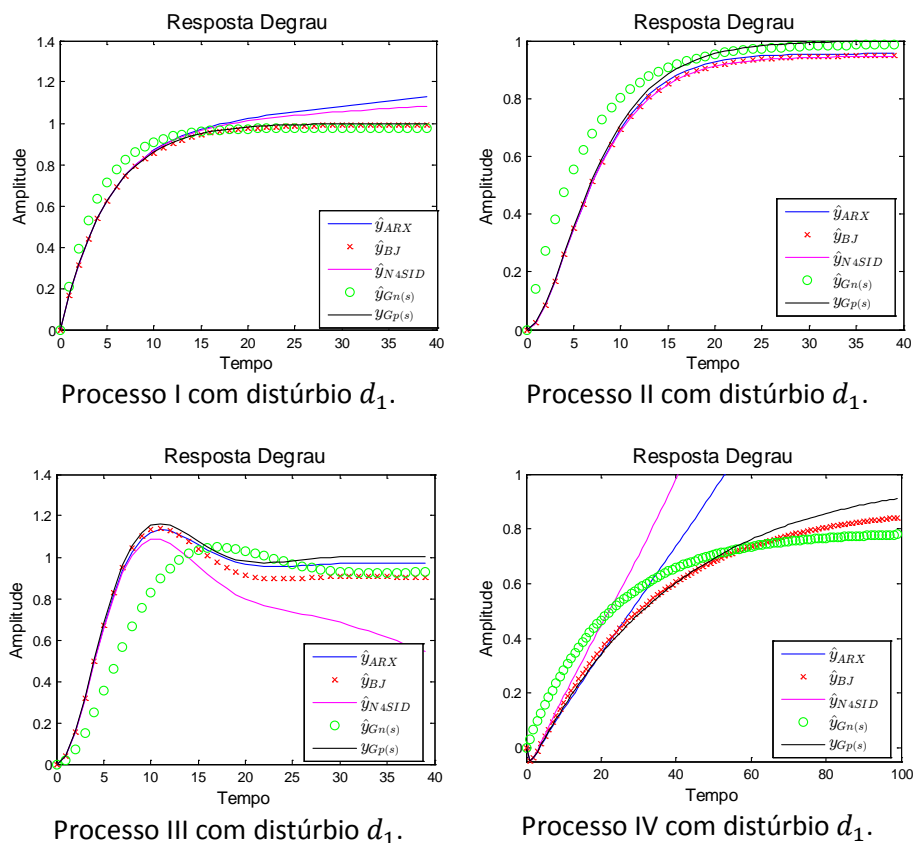
**Figura 4.12:** Perturbações em malha fechada no processo V. Gráfico superior: *setpoint* (linha cheia) e saída do processo (linha tracejada). Gráfico intermediário: ação de controle calculada pelo controlador (linha tracejada) e ação total de controle (linha cheia). Gráfico inferior: perturbação adicional aplicada ao  $u$ -bias do controlador.

Para obtenção dos resultados apresentados a seguir os modelos foram identificados utilizando-se a mesma metodologia e critérios de escolha apresentada na seção anterior. Como sinal de saída do modelo foi utilizado o sinal saída do processo,  $y$ , e como sinal de entrada a ação total de controle, dada como a soma entre o sinal correspondente da ação calculada pelo controlador e a perturbação feita no  $u$ -bias, conforme ilustrado na Figura 4.12. Os valores do índice *Fit* obtidos para as estruturas de modelo testadas, considerando o ponto de operação OP3, sob efeito dos distúrbios  $d_1$ ,  $d_2$ ,  $d_3$  e  $d_4$  estão apresentados na Tabelas 4.9. Os valores para o índice *Fit* no ponto de operação OP3 avaliado nos demais *DNMs*, bem como os resultados para os demais pontos de operação encontram-se no Apêndice C.

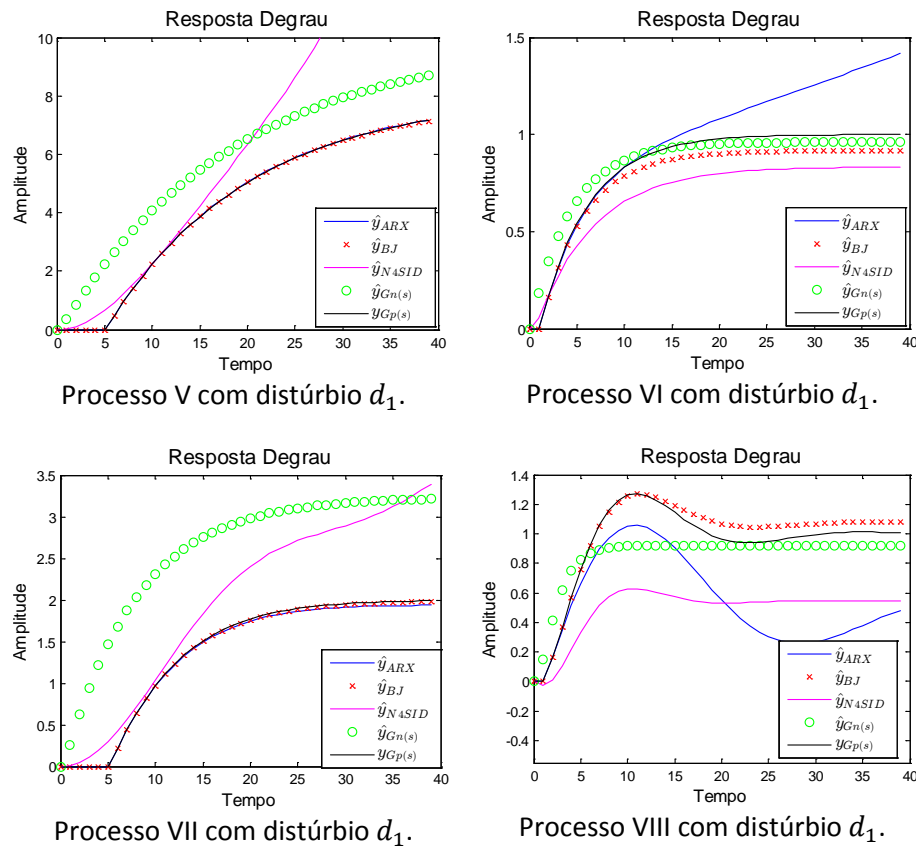
**Tabela 4.9:** Índice *Fit* para cada um dos modelos identificados, no ponto de operação OP3 sob o efeito de  $d_1, d_2, d_3$  e  $d_4$ .

	$d_1$			$d_2$			$d_3$			$d_4$		
	ARX	BJ	N4SID	ARX	BJ	N4SID	ARX	BJ	N4SID	ARX	BJ	N4SID
I	87,87	87,05	87,32	83,41	82,89	75,22	69,81	45,23	69,65	19,25	24,99	2,77
II	87,52	91,57	87,48	78,80	82,51	78,89	76,07	76,31	75,91	59,06	62,92	50,41
III	84,72	89,28	84,29	72,92	75,85	73,14	70,14	72,40	71,98	52,89	16,27	20,71
IV	86,66	89,93	85,24	82,06	86,89	75,24	72,01	57,07	65,34	39,83	19,04	58,44
V	98,85	98,94	68,11	97,86	98,50	70,49	97,46	97,17	71,99	93,07	91,04	63,78
VI	89,25	89,46	83,70	85,33	80,57	74,05	73,75	75,46	71,25	27,21	29,17	37,61
VII	95,58	97,18	72,58	93,03	94,51	72,50	89,32	91,55	76,28	79,57	76,46	68,69
VIII	86,45	88,08	73,30	77,28	82,43	64,77	75,11	75,11	62,70	49,27	23,74	34,62

Através dos valores para o índice *Fit* obtidos nesta análise foi possível verificar que os modelos identificados via estrutura Box-Jenkins apresentaram de uma forma geral a maior capacidade de adequação do modelo em função dos dados de entrada e saída utilizados para modelagem. A fim de verificar a capacidade dos modelos identificados em representar o modelo do processo, foram analisadas as respectivas respostas degrau, cujos resultados estão apresentados nas Figuras 4.13 e 4.14.



**Figura 4.13:** Resposta ao degrau unitário dos modelos identificados e do modelo do processo.



**Figura 4.14:** Resposta ao degrau unitário dos modelos identificados e do modelo do processo.

Nas Figuras 4.13 e 4.14 as legendas  $\hat{y}_{ARX}$ ,  $\hat{y}_{BJ}$ ,  $\hat{y}_{N4SID}$  e  $\hat{y}_{Gn(s)}$  representam as saídas estimadas pelo modelo identificado através das estruturas ARX, N4SID e Filtro, respectivamente, e  $y_{Gp(s)}$  é a saída do modelo do processo. Como pode ser visto nas Figuras 4.13 e 4.14, os modelos Box-Jenkins foram os que apresentaram maior capacidade de reprodutibilidade, confirmando assim a informação obtida através do índice *Fit*. É possível verificar também que todos os modelos de estrutura ARX e consequentemente os modelos de estrutura Box-Jenkins conseguiram estimar satisfatoriamente o valor do tempo morto do processo, do ganho e o tempo de subida e de assentamento do processo. Através destes resultados é possível verificar que sistemas mais complexos tal como aqueles que apresentam tempo morto necessitam de dados suficientemente ricos para a obtenção de modelos identificados com maior coerência em relação ao processo que se deseja identificar. Estes resultados reforçam que dados em condições normal de operação, ou seja, aqueles colhidos sem nenhum tipo de perturbação adicional no processo são por incapazes de promover uma identificação de um modelo coerente com as características do processo.

#### 4.2.3 Determinação do Potencial de Redução de Variabilidade (VRE)

Com o objetivo de verificar a capacidade de estimação do potencial de redução de variabilidade de um dado processo foi então aplicado o método proposto na seção 3.3 para determinação do índice *VRE*. Este traduz a alteração de variabilidade de uma variável de processo decorrente a uma modificação nos parâmetros de ajuste do controlador. Para tal com a finalidade de analisar o feito de alterações simultâneas nos parâmetros do ajuste do controlador, foram analisadas situações onde a velocidade do

controlador foi alterada gradativamente através do aumento no valor da parcela proporcional do controlador ( $Kp$ ) e da redução gradativa da parcela integradora ( $Ti$ ). De forma geral, pequenos aumentos do valor de  $Kp$  ou reduções na parcela integradora conferem uma maior velocidade da resposta em malha fechada. Os intervalos utilizados para alteração do  $Kp$  e  $Ti$  do controlador, utilizado em cada modelo de planta estão dispostos na Tabela 4.10. O impacto da alteração de  $Kp$  na velocidade de resposta da malha, pode ser visto através da razão entre o valor de  $Kp$  na condição atual ( $Kp_1$ ) e seu valor na condição futura desejada ( $Kp_2$ ), ou seja, para um controlador com  $Kp_1$  igual a 1 e  $Kp_2$  igual a 4 significa dizer que a situação futura apresenta uma resposta quatro vezes mais rápida do que a situação atual.

**Tabela 4.10:** Valores utilizados para geração de dados utilizados nas análises de validação do VRE.

	Processo $Gp(s)$	$Kp$	$Kp_2/Kp_1$	$Ti$	Número de sintonias
I	$\frac{1}{5s + 1}$	[0,23:0,046:1,61]	[1:0,046:7]	[2,3:-0,057:0,57]	961
II	$\frac{1}{15s^2 + 8s + 1}$	[0,26:0,05:1,82]	[1:0,05:7]	[3,56:-0,03:2,54]	961
III	$\frac{1}{9s^2 + 3s + 1}$	[0,39:0,013:0,78]	[1:0,013:2]	[2,78:-0,03:1,85]	961
IV	$\frac{-3s + 1}{25s^2 + 40s + 1}$	[0,25:0,03:1,25]	[1:0,03:5]	[19,2:-0,3:9,6]	961
V	$\frac{8}{15s + 1} e^{-5s}$	[0,047:0,006:0,23]	[1:0,006:5]	[10,44:-0,11:6,96]	961
VI	$\frac{1}{5s + 1} e^{-1s}$	[0,18:0,018:0,72]	[1:0,018:4]	[2,16:-0,02:1,44]	961
VII	$\frac{2(3s + 1)}{24s^2 + 10s + 1} e^{-5s}$	[0,15:0,01:0,45]	[1:0,01:1,3]	[7,5:-0,1:4,41]	961
VIII	$\frac{2s + 1}{12s^2 + 3s + 1} e^{-1s}$	[0,34:0,005:0,51]	[1:0,005:1,5]	[2,28:-0,01:1,9]	961

A notação da Tabela 4.10 para representação dos intervalos dos parâmetros  $Kp$ ,  $Kp_2/Kp_1$  e  $Ti$  está em conformidade com a notação do Matlab, onde os valores extremos representam os limites do intervalo e o valor intermediário representa o incremento. Os valores extremos superiores dos intervalos foram escolhidos de forma a levar o sistema a apresentar uma resposta oscilatória, podendo assim apresentar um ponto de inflexão dentro do intervalo analisado. Os incrementos foram escolhidos de forma a obter vetores de mesmo comprimento.

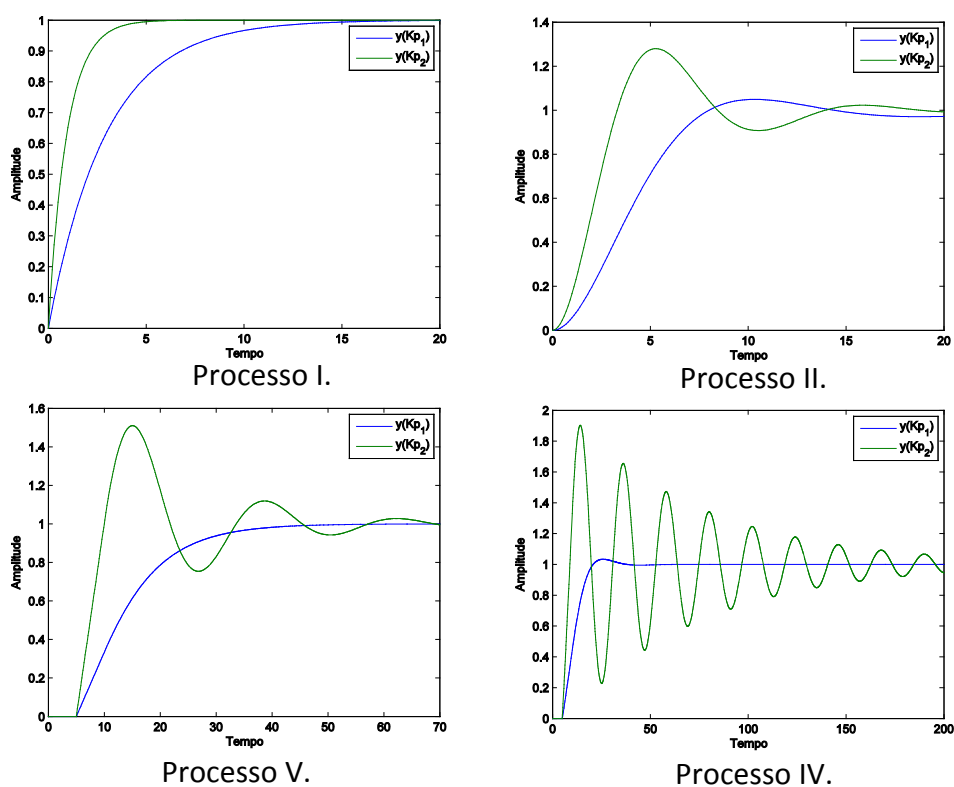
Outra forma de observar a alteração do desempenho da malha de controle, mediante a alteração do valor de  $Kp$ , para as situações analisadas, é através de uma perturbação do tipo degrau no sistema em malha fechada na condição inicial e em uma condição final na qual o controlador encontra-se mais veloz. Tal situação pode ser exemplificada admitindo os quatro modelos de processo, nas condições apresentadas na Tabela 4.11.



**Tabela 4.11:** Alteração de  $Kp$  utilizada para obtenção da Figura 4.15.

	Processo $Gp(s)$	$Kp_2/Kp_1$
I	$\frac{1}{5s + 1}$	4
II	$\frac{1}{15s^2 + 8s + 1}$	4
V	$\frac{8}{15s + 1} e^{-5s}$	4
VII	$\frac{2(3s + 1)}{24s^2 + 10s + 1} e^{-5s}$	3

Os resultados obtidos para o comportamento dos sistemas perante as perturbações são apresentados na Figura 4.15, através da qual se pode observar uma redução no tempo de subida, ou seja, o sistema passou a apresentar uma resposta mais rápida.

**Figura 4.15:** Resposta degrau na mudança de *setpoint* para as malhas consideradas admitindo  $Kp_2$  três vezes mais rápido do que  $Kp_1$ .

No entanto, como pode ser visto em especial para o modelo VII, tal aumento na velocidade do controlador provocou uma resposta bastante oscilatória para o sistema, o que contribui de forma negativa para a estabilidade do processo. Neste caso é esperado que ao invés de uma diminuição da variabilidade do sinal de saída do processo, decorrente de um aumento de quatro vezes na velocidade de resposta, seja obtido um aumento da variabilidade, o que nos mostra outra questão muito importante do ponto de vista de auditoria. Afinal é sabido que pequenas alterações contribuem na redução da variabilidade do sinal de saída, no entanto até que ponto pode-se tornar o sistema veloz sem que tal ação interfira de forma negativa. Uma forma de responder a esta questão pode ser através da determinação do *VRE* que busca traduzir o impacto que uma dada alteração nos parâmetros do controlador tem na alteração de variabilidade do processo,

podendo responder também até que ponto pode-se tornar veloz a resposta sem que o sistema se torne oscilatório em demasia ou até mesmo instável, levando em considerações todas as reais limitações de desempenho como o modelo de planta, estrutura do controlador e o *DNM*.

Para ilustrar a capacidade de predição do índice *VRE*, os valores obtidos para ele foram comparados com os valores obtidos pelo índice de Harris e com a alteração real do processo. O índice de Harris foi calculado conforme Equação 4.6, onde  $\eta(\Phi)$  foi calculado conforme a Equação 2.33 utilizando um modelo AR com ordem 20 e tempo morto igual ao tempo morto do processo para determinação da variância mínima ( $\sigma_{MV}^2$ ). A alteração real de variabilidade em porcentagem foi calculada conforme a Equação 4.7.

$$Harris = -\eta(\Phi) \cdot 100\% = \left(\frac{\sigma_{MV}^2}{\sigma_1^2} - 1\right) \cdot 100\% \quad (4.6)$$

$$Alteração\ real = \left(\frac{\sigma_2^2}{\sigma_1^2} - 1\right) \cdot 100\% \quad (4.7)$$

onde  $\sigma_1^2$ , nas Equações 4.6 e 4.7, representa a variância do sinal de saída nas condições atuais e  $\sigma_2^2$  é a variância do sinal de saída na condição futura ( $y_2$ ), obtida por simulação utilizando os modelos  $Gp(s)$  e os *DNMs*  $d_i$ . Desta forma valores positivos para alteração real de variabilidade indicam aumento da variabilidade, enquanto, valores negativos indicam redução da variabilidade.

Para determinação do índice *VRE* foram utilizados os modelos identificados através das duas metodologias de identificação apresentadas (identificação com dados de operação normal - *VRE1* e com dados obtidos com perturbações - *VRE2*) e o sinal de distúrbio não medido foi representado como  $\hat{d}$  para obtenção de  $\hat{y}_2$ . Os valores máximos de *VRE* obtidos, para os processos sob o ponto de operação OP3 considerando os *DNMs*  $d_1$  e  $d_2$  estão apresentados na Tabela 4.12.

**Tabela 4.12:** Percentual de máxima redução de variabilidade estimados comparados à índice de Harris e Alteração real para os processos no ponto de operação OP3 sob os efeitos dos *DNMs*  $d_1$  e  $d_2$ .

Processo	<i>VRE1</i> (%)		<i>VRE2</i> (%)		<i>Harris</i> (%)		Alteração real(%)	
	$d_1$	$d_2$	$d_1$	$d_2$	$d_1$	$d_2$	$d_1$	$d_2$
I	-99,76	-99,70	-99,74	-99,64	-99,99	-99,99	-99,75	-99,65
II	-93,52	-92,67	-91,61	-89,24	-99,99	-99,99	-92,94	-90,99
III	-93,61	-91,78	-95,14	-94,48	-99,99	-99,99	-94,49	-91,66
IV	-82,49	-90,20	-70,70	-84,28	-99,99	-99,99	-64,22	-84,71
V	-82,94	-90,02	-74,16	-81,40	-99,63	-99,63	-75,39	-82,61
VI	-94,59	-93,55	-94,06	-91,64	-99,99	-99,99	-94,53	-92,61
VII	-78,66	-79,02	-57,47	-49,89	-98,44	-98,44	-58,35	-49,69
VIII	-47,37	-43,96	-44,54	-30,56	-99,99	-99,99	-50,65	-34,17

Para avaliar de uma forma mais direta a qualidade na predição da alteração de variabilidade através das três metodologias foram também calculados os erros relativos percentuais (*ERP*), conforme a Equação 4.8.

$$ERP = \left| \frac{\text{Alteração real} - \text{valor predito}}{\text{Alteração real}} \right| \cdot 100 \quad (4.8)$$

onde *valor predito* representa o valor obtido para *VRE1*, *VRE2* e *Harris*.

Os valores obtidos pra os *ERP* avaliados no ponto de operação OP3 considerando os *DNMs*  $d_1$  e  $d_2$  estão apresentados na Tabelas 4.13. Os valores obtidos para os *ERP* calculados para os demais *DNMs*, bem como para os pontos de operação OP1 e OP2 encontram-se no Apêndice C.

**Tabela 4.13:** Erro relativo percentual entre a máxima redução de variabilidade estimada e a Alteração real para os processos no ponto de operação OP3 sob os efeitos dos *DNMs*  $d_1$  e  $d_2$ .

Processo	ERP(%)					
	VRE1		VRE2		Harris	
	$d_1$	$d_2$	$d_1$	$d_2$	$d_1$	$d_2$
I	0,009	0,041	0,007	0,009	0,25	0,34
II	0,61	1,8	1,42	1,92	7,6	9,89
III	0,94	0,12	0,68	3,08	5,8	9,09
IV	28,39	6,47	10,10	0,51	55,72	18,03
V	10,01	8,95	1,62	1,46	32,62	20,59
VI	0,057	0,96	0,49	1,05	5,78	7,96
VII	34,8	58,98	1,49	0,40	70,86	98,10
VIII	6,46	28,65	12,05	10,57	97,42	192,6


Através dos valores obtidos para as predições de alteração de variabilidade e os correspondentes *ERP* calculados em relação aos valores reais esperados pôde-se concluir que o valor estimado através do índice *VRE2* é o que apresenta maior capacidade de predição do valor real para alteração de variabilidade em comparação ao *VRE1* e a *Harris*, observada principalmente nos casos onde existe a presença de tempo morto, processos V a VIII, o que mostra que a estimação confiável deste parâmetro está intimamente relacionada a qualidade da predição da redução da variabilidade do processo. Como visto através dos resultados apresentados na seção 4.2, os modelos determinados via metodologia intrusiva para os processo V a VIII apresentaram uma maior capacidade de representação dos modelos reais da planta em relação aos modelos identificados de forma não intrusiva (via metodologia proposta) o que pode explicar a qualidade de *VRE2* em relação a *VRE1*.

Nos processos I a IV é possível verificar que *VRE1* consegue predizer de forma coerente o potencial de redução de variabilidade, obtendo valores até mais realísticos do que os obtidos através do índice de *Harris*. A predição de *VRE1* para os casos dos processos V a VIII poderia ser melhorada a partir do conhecimento do tempo morto no processo, uma vez que este fator é um limitante do desempenho do controlador e crucial para estabilidade do sistema como um todo, sendo desta forma a qualidade da predição de alteração de variabilidade diretamente relacionada à qualidade do modelo identificado utilizado para estimação do potencial de variabilidade. Desta forma, uma vez disponível uma estimativa coerente do tempo morto seria possível melhorar a capacidade de predição da alteração de variabilidade.

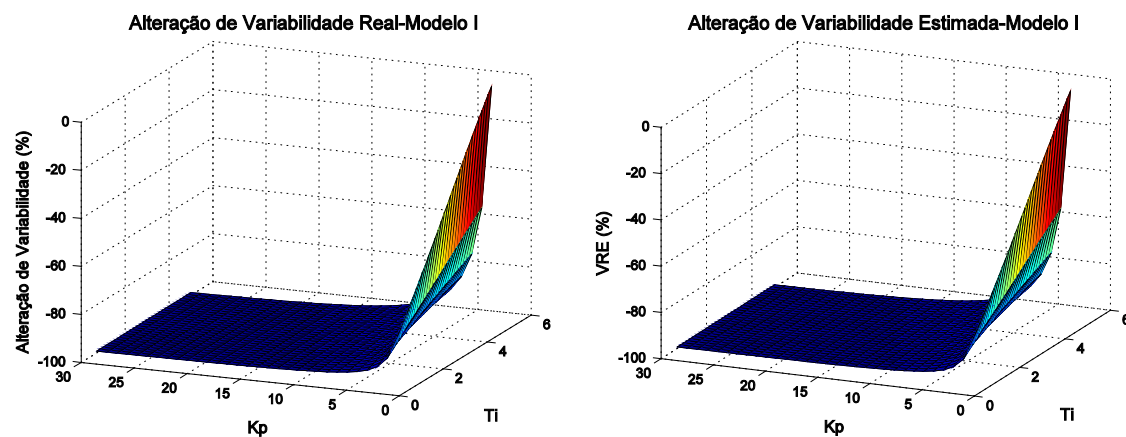
Através de uma comparação entre os valores obtidos pelo índice *Harris* e os valores obtidos para a alteração real é possível verificar discrepância entre eles, o que já era

esperado, uma vez que métricas que utilizam a variância mínima como referência para condições desejadas não levam em consideração as limitações do controlador real em operação e aproximam o *DNM* por um sinal de variância nula, não levando em consideração a real variância do sinal do *DNM*. Esses fatores têm influência direta sobre o desempenho do controlador e essas razões acabam fazendo com que índices dessa natureza possam não quantificar de forma adequada o potencial real de redução da variabilidade da malha analisada.

Uma característica do índice *VRE* é a possibilidade de determiná-lo em configurações específicas, desejadas para controlador, por exemplo, se existe o interesse de observar a variabilidade do sistema em relação a uma variação somente no parâmetro  $Kp$ , como mostrado na Figura 4.16 ou em uma variação simultânea de  $Kp$  e  $Ti$ , como apresentado na Figura 4.17.



**Figura 4.16:** Comparação de *VRE2* com a alteração real de variabilidade para o processo VII na presença de  $d_5$  para alterações somente no parâmetro  $Ti$  do controlador.



**Figura 4.17:** Comparação do perfil de *VRE1* com o perfil de alteração real de variabilidade para o processo I na presença de  $d_2$ .

Através das Figuras 4.16 e 4.17 é possível verificar a qualidade, e uma das vantagens, do índice  $VRE$  na predição de variabilidade a partir de uma estimativa do distúrbio e de um modelo identificado de planta, afinal desta forma é possível além de verificar a máxima redução de variabilidade verificar também a sensibilidade desta variação em função dos parâmetros do controlador, podendo assim detectar qual o ajuste do controlador PID que possibilita obter a máxima redução de variabilidade, entre outras possibilidades. Estas possibilidades do índice  $VRE$ , bem como a viabilidade de predições do potencial de redução de variabilidade mais realistas em relação ao índice clássico de *Harris* podem ser destacadas como uma das contribuições deste trabalho.

## Capítulo 5 – Considerações Finais

### 5.1 Conclusões

O presente trabalho propõe uma metodologia não intrusiva capaz de estimar o sinal referente à ação de distúrbios não medidos em sistemas SISO, bem como apresenta, também, outras duas metodologias não intrusivas que utilizam desse conhecimento para identificar o modelo do processo e prever o potencial de redução de variabilidade.

Os resultados obtidos através dos estudos de casos realizados permitem concluir que o estimador de distúrbios não medidos, proposto neste trabalho, tem uma boa capacidade de estimar o sinal correspondente aos *DNMs*, devido à alta capacidade de representação dos sinais reais através dos sinais estimados, se mostrando uma boa solução quanto à necessidade de estimação dos *DNMs* em sistemas de controle SISO, de forma não intrusiva.

Foi possível observar também que a presença de *DNMs* interfere negativamente, e de forma significativa, nos modelos de planta identificados através de métodos clássicos de identificação direta mostrando que estas técnicas são ineficazes em casos onde existem somente dados em condição normal de operação sob a presença de *DNMs* significativos. Porém, foi observado que uma estimativa confiável do *DNM* é de grande auxílio neste tipo de procedimento de identificação sendo observado através da melhoria na qualidade dos modelos de planta identificados quando havia o conhecimento do *DNM* estimado.

Através dos resultados foi possível constatar uma forte relação entre a qualidade do modelo identificado e a qualidade de predição do índice *VRE*, proposto. Desta forma é necessário um maior investimento no aperfeiçoamento da etapa de identificação do modelo do processo para obtenção de uma melhor capacidade de predição do potencial de redução de variabilidade do processo, principalmente na estimação do tempo morto do processo uma vez que os resultados obtidos mediante um valor mais coerente para este parâmetro possibilitaram uma maior aproximação dos valores obtidos para o índice *VRE* dos valores reais obtidos para a redução de variabilidade.

Outra característica importante é a facilidade de leitura e interpretação do índice *VRE*, que traduz de forma clara a variação em porcentagem de aumento ou diminuição

na variabilidade do sinal de saída do processo, obtido através de uma configuração específica do controlador.

Vale ressaltar que o objeto de estudo é um sistema em atuação no qual se têm conhecimento apenas da configuração do controlador PID e dados de saída e ação de controle, em condição normal de operação, e sofre com o efeito de um *DNM* que influencia diretamente a resposta do sistema. Através das análises é possível constatar que o conhecimento de uma estimativa deste sinal é uma ferramenta de fundamental importância nos estudos em torno do processo em questão tal como a identificação do modelo de planta e a auditoria de desempenho da malha de controle.

## 5.2 Sugestões para Trabalhos Futuros

A partir dos resultados para metodologia de identificação foi possível verificar uma forte dependência da qualidade de predição da redução de variabilidade em função do modelo de planta identificado. Uma característica importante observada é que nem o modelo de filtro nem o modelo identificado de forma não intrusiva foram capazes de estimar de forma coerente o valor do tempo morto no processo. Estes resultados demonstram a possibilidade de investimento no estudo de métodos que viabilizem um aprimoramento na etapa de identificação do modelo de planta.

Como alternativas é possível a formulação de um problema de otimização em etapas, que permita a estimação do tempo morto do processo paralelamente aos demais parâmetros do modelo da planta, sendo formulado de forma a forçar uma solução mais precisa deste parâmetro, esta divisão em etapas reduziria, também, a interação entre os parâmetros do modelo podendo melhorar a capacidade de estimação do tempo morto. A otimização por sua vez pode ser realizada unindo uma etapa de identificação direta do modelo da planta com o procedimento de estimação do distúrbio.

Outra possibilidade, visto a melhoria na estimação do tempo morto através de dados intrusivos, seria a realização de um estudo sobre ensaios de perturbação, minimamente intrusivos, com a finalidade de obter dados suficientemente ricos com a capacidade de viabilizar a extração de um valor mais coerente do tempo morto do processo, de forma a interferir o mínimo possível no processo.

Desta forma é pretendido em ambas as possibilidades aperfeiçoar a estimativa dos parâmetros do modelo da planta, melhorando assim a capacidade de representatividade do modelo identificado e da predição do potencial de redução de variabilidade do processo. É pretendido a extensão das metodologias propostas para os cenários multivariáveis.

## Apêndice A. Métodos de Identificação

Neste apêndice serão apresentadas com maiores detalhes algumas das principais técnicas disponíveis na literatura para identificação de modelos de processo. Estas por sua vez, serão apresentadas de acordo com sua classificação em relação aos métodos utilizados.

### A.1 Métodos Discretos

Um grande conjunto dos sistemas de controle coletam seus dados de forma discreta, ou seja, através de determinado intervalo de tempo de amostragem. Os métodos de identificação discretos utilizam de um modelo pré-definido que se adequa ao sistema, para representá-lo. Isto se faz possível devido à estrutura na qual este modelo está baseado, cada modelo é formado por parâmetros que são ajustados conforme os dados de entrada e saída que foram coletados. De forma geral os modelos de estruturas utilizados podem ser representados conforme a Equação A.1.

$$\begin{aligned}A(q)y(t) &= \frac{B(q)}{F(q)}u(t) + \frac{C(q)}{D(q)}v(t) \\y(t) &= \frac{B(q)}{F(q)A(q)}u(t) + \frac{C(q)}{D(q)A(q)}v(t) \\y(t) &= G(q)u(t) + H(q)v(t)\end{aligned}\tag{A.1}$$

As funções  $G(q)$  e  $H(q)$  representam as funções de transferência do processo e do ruído branco,  $y$  é o sinal de saída do modelo,  $u$  é o sinal de entrada e  $v$  é o ruído branco. Os polinômios  $A$ ,  $B$ ,  $C$ ,  $D$  e  $F$  são definidos como:

$$\begin{aligned}A(q) &= 1 - a_1q^{-1} - \dots - a_{n_y}q^{-n_y} \\B(q) &= b_1q^{-1} + \dots + b_{n_u}q^{-n_u} \\C(q) &= 1 + a_1q^{-1} + \dots + C_{n_v}q^{-n_v} \\D(q) &= 1 + d_1q^{-1} + \dots + d_{n_d}q^{-n_d}\end{aligned}$$



$$F(q) = 1 + f_1q^{-1} + \dots + f_{n_f}q^{-n_f} \quad (\text{A.2})$$

Onde o operador  $q^{-1}$  representa o atraso (Aguirre, 2007).

Os principais métodos de estruturas encontrados na literatura, baseados na Equação A.1 serão apresentados a seguir.

#### A.1.1 Modelo FIR (Finite Impulse Response)

Este modelo foi amplamente empregado para os primeiros algoritmos de identificação e modelos de controladores preditivos lineares, devido sua simplicidade de implementação. O modelo FIR pode ser obtido fazendo-se  $A(q) = C(q) = D(q) = F(q) = 1$  e  $B \neq 1$  na Equação A.1, como apresentado na Equação A.3.

$$y(t) = B(q) \cdot u(t) \quad (\text{A.3})$$

O polinômio de ajuste entre  $u$  e  $y$  é representado por  $B$ , onde seus coeficientes representam a resposta a uma perturbação impulso no sistema (Aguirre, 2007), em outras palavras a saída discreta do sistema pode ser dada como:

$$y(k) = \sum_{k=0}^M h(k)u(k-j) + e(k) \quad (\text{A.4})$$


onde o índice  $k$  é o índice que representa o instante de amostragem atual. O parâmetro  $M$  é a ordem do polinômio  $B$  e  $e(k)$  é o ruído. A Equação A.4 pode ser reescrita na forma da Equação A.5.

$$y(t) = B(q)u(t) + v(t) \quad (\text{A.5})$$

Deve ser notado que, como  $C(q)/D(q) = 1$ , então o ruído acrescentado na saída  $y(t)$ ,  $e(t)$ , é branco, em função disto  $e(t) = v(t)$ . Os parâmetros do modelo FIR são então obtidos por meio do método dos mínimos quadrados (Machado, 2004), representado pela Equação A.6.

$$B = (X^T \cdot X)^{-1}X^TY \quad (\text{A.6})$$

Onde  $X$  é a chamada matriz de regressores e  $Y$  é o vetor contendo a resposta do sistema em todos os instantes do intervalo dos dados identificados. Saliendo que a integral dos coeficientes da resposta impulso fornecem a resposta a um degrau unitário. A estrutura do modelo FIR pode ser representada em diagrama de blocos como dado na Figura A.1.



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

### A.1.2 Modelo ARX

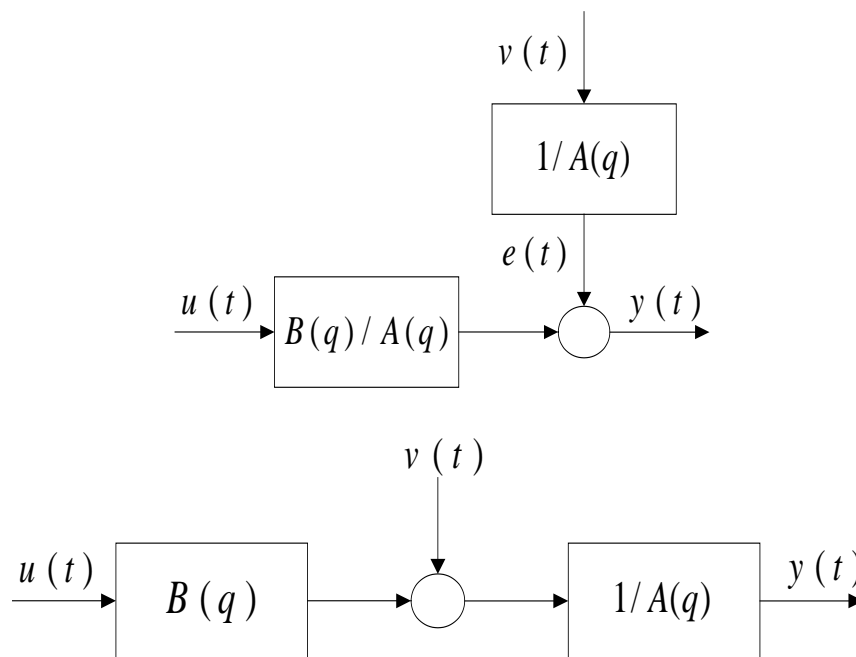
O modelo auto-regressivo com entradas externas (ARX do inglês *auto-regressive whit exogenous inputs*) pode ser obtido fazendo-se  $C(q) = D(q) = F(q) = 1$ , sendo  $A(q)$  e  $B(q)$  polinômios arbitrários. Desta forma a Equação A.1 torna-se:

$$A(q)y(t) = B(q)u(t) + v(t)$$

$$y(t) = \frac{B(q)}{A(q)}u(t) + \frac{1}{A(q)}v(t) \quad (\text{A.7})$$

A Equação A.7 coloca em evidência as funções de transferência do sistema  $G(q) = B(q)/A(q)$  e de ruído  $H(q) = 1/A(q)$ , conforme pode ser observado na Figura A.2.

Diferente do modelo FIR, o modelo ARX possui um ruído na saída não branco. Ou seja, para o ARX o ruído é modelado como um processo branco filtrado por um filtro auto-regressivo, com polos iguais ao do processo, que são as raízes do polinômio  $A(q)$  (Aguirre, 2007).



**Figura A.2:** Representação em diagrama de blocos da estrutura de modelo ARX. (a) É equivalente ao modelo expresso na Equação A.7 que após algumas manipulações pode ser representado na forma apresentado em (b) que evidencia que o erro não aparece na saída.

### A.1.3 Modelo ARMAX

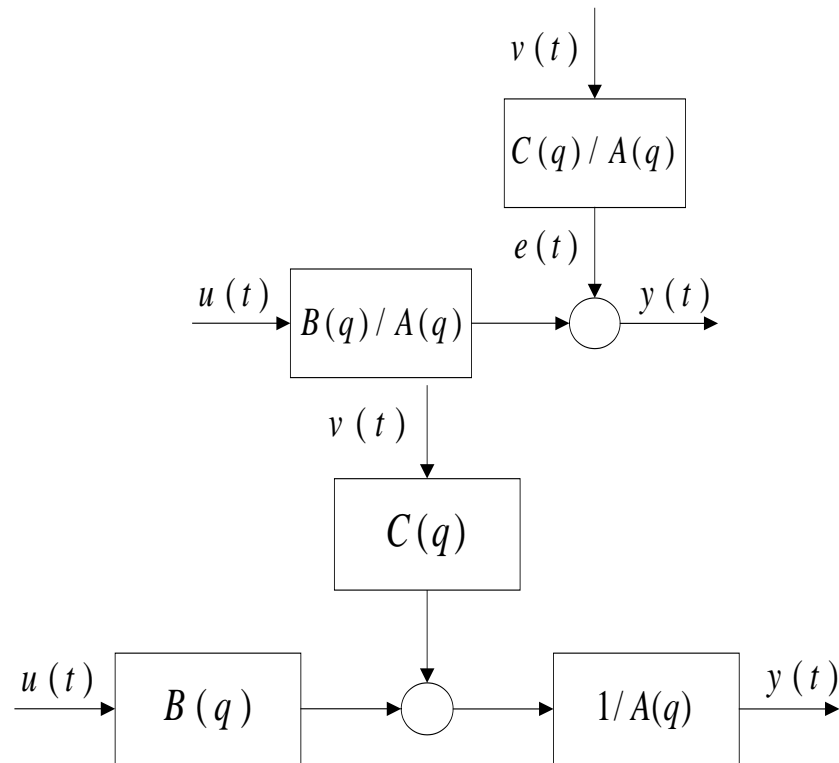
O modelo auto-regressivo com média móvel e entradas exógenas (ARMAX-*autoregressive moving average with exogenous inputs*) pode ser obtido a partir do modelo geral (Equação A.1) fazendo-se  $D(q) = F(q) = 1$  onde  $A(q)$ ,  $B(q)$  e  $C(q)$  são polinômios arbitrários, como apresentado na Equação A.8.

$$A(q)y(t) = B(q)u(t) + C(q)v(t)$$

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

$$y(t) = G(q)u(t) + e(t) \quad (\text{A.8})$$

Sendo  $e(t)$  não branco. O esquema representativo do modelo ARMAX pode ser ilustrado conforme a Figura A.3.



**Figura A.3:** Representação em diagrama de blocos da estrutura de modelo ARMAX. (a) expressa como na Equação A.8 e em (b) após sofrer algumas modificações.

Neste tipo de modelo, o erro contido na equação é modelado como um processo de média móvel (MA) e o ruído adicionado a saída,  $e(t)$ , é modelado como um ruído branco filtrado pelo filtro ARMA ( $C(q)/A(q)$ ), este modelo pode ser então, representado como um modelo de erro na saída (Aguirre, 2007).

#### A.1.4 Modelo ARMA

Este modelo é um caso particular do modelo anterior, ARMAX, quando  $u(k) = 0$ , transformando a Equação A.1 em:

$$A(q)y(t) = B(q)u(t) + C(q)v(t)$$

$$y(t) = \frac{C(q)}{A(q)}v(t)$$

$$y(t) = H(q)v(t) \quad (\text{A.9})$$

como  $H(q)$  representa a função de transferência do ruído, ela quantifica como o processo aleatório branco  $v(t)$  afeta a saída  $y(t)$ . Neste tipo de representação, a entrada do sistema é dada como o sinal aleatório  $v(t)$ . Sendo assim a saída do sistema pode ser lida como um sinal filtrado da entrada  $v(t)$  através de  $H(q)$  (Aguirre, 2007). Modelos ARMA são comumente utilizados como modelos de séries temporais, ou seja, situações em que se tem somente um sinal  $y(t)$ . Nestes casos, estima-se  $H(q)$  usando-se tal sinal e mais uma realização de  $v(t)$  tomada de uma distribuição de probabilidade ou utilizando-se os próprios resíduos do modelo estimado no lugar de  $v(t)$  (Ljung, 1998).

#### A.1.5 Modelos de Erro na Saída


Este tipo de modelo admite que o polinômio  $A(q)$  na Equação A.1 é igual a 1. Um exemplo simples deste tipo de modelo é tomando-se  $A(q) = C(q) = D(q) = 1$ , com  $B(q)$  e  $F(q)$  polinômios arbitrários, o que resulta em:

$$y(t) = \frac{B(q)}{F(q)}u(t) + v(t) \quad (\text{A.10})$$

O fato do ruído  $v(t)$  ser adicionado diretamente à saída justifica o nome do modelo. É importante notar a diferença entre este tipo de modelo e o modelo ARX, a diferença pode ser observada ao tentar-se representar a Equação A.10 como um modelo ARX, ao tentar-se fazer isso, chega-se a:

$$\begin{aligned} F(q)w(t) &= B(q)u(t) \\ y(t) &= w(t) + v(t) \end{aligned} \quad (\text{A.11})$$

Onde  $w(t)$  é uma variável auxiliar sem ruído, que não é medida. Assim, a saída  $y(t)$  do modelo (A.10) pode ser interpretado como a superposição de ruído branco com processo ARX sem ruído, como apresentado na Figura A.4 (Aguirre, 2007).




**Figura A.4:** Representação em diagrama de blocos da estrutura de modelo de erro na saída.

#### A.1.6 Modelo Box-Jenkins

Este modelo toma o polinômio  $A(q) = 1$  e admite os outros polinômios arbitrários, desta forma a Equação A.1 resulta em:

$$y(t) = \frac{B(q)}{F(q)}u(t) + \frac{C(q)}{D(q)}v(t) \quad (\text{A.12})$$

As funções de transferência do sistema  $G(q)$  e do ruído  $H(q)$  são independentemente parametrizadas. O modelo Box-Jenkins também pode ser considerado um modelo do tipo erro na saída, como pode ser observado na Figura A.5 (Aguirre, 2007).



**Figura A.5:** Representação em diagrama de blocos da estrutura de modelo Box-Jenkins.

## A.2 Métodos em Espaço de Estado

Os principais algoritmos de identificação em espaço de estado presentes na literatura são: *SUBID* (*Subspace Identification*), *N4SID* (*Numerical Algorithms For Subspace State Space System Identification*), *MOESP* (*Multivariable Output Error State Space*) e *CVA* (*Canonical Variate Analysis*). Embora também sejam algoritmos de identificação discretos, ao invés de representarem o processo através de funções de transferência como fazem os algoritmos da seção A.1, os métodos de identificação em espaço de estado determinam as matrizes que representam o sistema no espaço de estados. Esta representação é dada como:

$$\frac{dx(t)}{dt} = Ax(t) + Bu(t) + w(t)$$

$$y(t) = Cx(t) + Du(t) + v(t) \quad (\text{A.13})$$

Em que  $A, B, C$  e  $D$  representam as matrizes de estados,  $x(t)$  é o vetor de estados,  $u(t)$  e  $y(t)$  são os vetores de entrada e saídas do sistema, respectivamente.  $w(t)$  e  $v(t)$  são os vetores de sinais não medidos e denominados de ruído de medição e de ruído do sistema, respectivamente, assumindo que esses ruídos sejam brancos, estacionários e com média zero (Overschee e Moor, 1994).

Algoritmos desta natureza aplicam refinadas técnicas de álgebra linear para identificar as matrizes  $A, B, C$  e  $D$  da Equação A.13 a partir de dados de entrada e saída do sistema, no caso os dados de planta. Estes métodos admitem que o par de matrizes  $\{A, C\}$  é observável, o que admite que todos os modos no sistema podem ser observados na saída  $y(t)$ , portanto, sendo assim identificável. Assume-se também que o par de matrizes  $\{A, B\}$  é assumido ser controlável, implicando que todos os modos do sistema são excitados pela entrada determinística  $u(t)$ , e/ou pela entrada estocástica  $w(t)$ . Para maiores informações sobre identificação estocástica e a combinação entre identificação estocásticas e determinísticas podem ser encontradas em Van Overschee e De Moor



$$\Gamma_i \equiv \begin{pmatrix} C \\ CA \\ CA^2 \\ \dots \\ CA^{i-1} \end{pmatrix}$$

$$H_i^d \equiv \begin{pmatrix} D & 0 & 0 & \dots & 0 \\ CB & D & 0 & \dots & 0 \\ CAB & CB & D & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots \\ CA^{i-2}B & CA^{i-3}B & CA^{i-4}B & \dots & D \end{pmatrix}$$

$$\Delta_i^d \equiv (A^{i-1}B \quad A^{i-2}B \quad \dots \quad AB \quad A) \quad (\text{A.16})$$

De posse destas definições, sabe-se que:

$$O_i = \Gamma_i X_f^d \quad (\text{A.17})$$

Para que a projeção oblíqua  $O_i$  seja separada em  $\Gamma_i$  e em  $X_f^d$ , para sistemas puramente determinísticos, o posto de  $O_i$  deverá ser igual à ordem  $n$  do sistema e,  $\Gamma_i$  e  $X_f^d$  podem ser recuperados de forma precisa pela decomposição SVD, expressa por:

$$O_i = (U_1 \quad U_2) \begin{pmatrix} S_1 & 0 \\ 0 & 0 \end{pmatrix} \begin{pmatrix} V_1^T \\ V_2^T \end{pmatrix} = U_1 S_1 V_1^T \quad (\text{A.18})$$

Em que  $S_1$  é uma submatriz de  $S$  contendo os valores singulares não-nulos de  $O_i$ ,  $U_1$  e  $V_1^T$ . A ordem  $n$  do sistema da Equação A.13 é igual ao número de valores singulares da Equação A.18, diferentes de zero. A matriz de observabilidade pode ser estimada através da Equação A.19.

$$\Gamma_i = U_1 S_1^{1/2} \quad (\text{A.19})$$

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

$$X_i^d \equiv \Gamma_i^{pinv} O_i$$

$$X_{i+1}^d = \Gamma_{i-1}^{pinv} O_{i-1} \quad (\text{A.20})$$

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

$$\begin{pmatrix} X_{i+1}^d \\ Y_{i|i} \end{pmatrix} = \begin{pmatrix} A & B \\ C & D \end{pmatrix} \begin{pmatrix} X_i^d \\ U_{i|i} \end{pmatrix} \quad (\text{A.21})$$


No método *N4SID*, as matrizes do sistema  $A$ ,  $B$ ,  $C$  e  $D$  são estimadas em um único passo, resolvendo o problema apresentado na Equação A.21.

### A.3 Métodos com Modos de Operação de Plantas Industriais

O modo em que os dados utilizados para a determinação do modelo são coletados tem influência nos resultados obtidos. Na prática existem duas classificações quanto ao modo de operação em que estes dados podem ser coletados: modo malha aberta e modo malha fechada. De forma geral a diferença entre estes é dada pela presença ou não do controlador no momento da coleta dos dados. No modo malha aberta o controlador está ausente, enquanto o modo malha fechada existe a presença do controlador. Cada um destes modos produz dados com características distintas, devido à presença ou não do controlador. Estes modos serão descritos, de forma sucinta, nas próximas subseções.

#### A.3.1 Modo Malha Aberta

Neste modo de operação, os controladores, quando presentes, são colocados em modo manual, ou seja, desabilitados. As variáveis manipuladas são variadas, de acordo com algum projeto pré-determinado de perturbações, ou de forma manual, o que por vezes pode levar o sistema a pontos de operação indesejados. No decorrer dos testes para identificação, o sistema está sujeito a fatores estocásticos  $v(t)$ , além das excitações determinísticas,  $u(t)$ . A configuração do sistema nestas condições pode ser representada através do esquema mostrado na Figura A.6.



**Figura A.6:** Representação do sistema em malha aberta.


Este método tem como grande vantagem a facilidade de implementação das perturbações e do acompanhamento da resposta do sistema  $y(t)$ , tendo a possibilidade de um conhecimento prévio das resposta do processo, em especial para os casos onde são utilizadas perturbações do tipo degrau não simultâneo. Por outro lado, este método tem como desvantagem a necessidade de desativação do controlador, o que acaba por vezes, aumentando a variabilidade dos dados coletados e sendo inviável de aplicação em sistemas instáveis em malha aberta.

Uma característica importante deste tipo de método é a não correlação entre os sinais  $e(t)$  e  $u(t)$  o que não ocorre em sistemas em malha fechada, onde a variável  $e(t)$  acaba exercendo efeito sobre a variável  $u(t)$ .



### A.3.2 Modo Malha Fechada

Neste modo de operação, o controlador encontra-se ativo, de modo a reduzir a variabilidade do processo. O controlador atua para que a saída,  $y(t)$ , esteja em torno do *setpoint* ( $r(t)$ ) desejado. De forma análoga ao sistema em malha aberta, o sistema em malha fechada também está sujeito a ação de distúrbios não medidos, representados pelo sinal  $v(t)$ . O esquema de geração de dados para identificação em malha fechada pode ser representado pela Figura A.7.



**Figura A.7:** Representação do sistema em malha fechada.

Da Figura A.7, pode-se observar que a ação de controle  $u(t)$ , é decorrente da ação calculada pelo controlador e do sinal  $p(t)$ , ou ação de controle de referência (*ubias*). Para realizar a identificação em malha fechada, as perturbações podem ser feitas tanto em  $r(t)$  quanto em  $p(t)$ . Deve-se observar que a presença do controlador produz uma correlação entre  $u(t)$  e  $e(t)$ , fato que contribui para uma possível incoerência na determinação do modelo da planta, caso o modelo que caracteriza o distúrbio,  $H(q)$ , seja mal determinado.

Os métodos de identificação em malha fechada podem ainda ser divididos em método direto e indireto, ambos serão melhor discutidos a seguir.

### A.3.3 Método Direto

A identificação em malha fechada toma os dados em malha fechada das variáveis manipulada ( $u(t)$ ) e controlada ( $y(t)$ ) ignorando a retroalimentação, tratando o problema como se fosse malha aberta. Os dados são inseridos em algoritmos de identificação discreta, através de métodos de erros de predição, e por fim obtém-se o modelo da planta. A vantagem deste método é sua simplicidade e o fato de dispensar o conhecimento da equação do controlador, a qual em muitos casos é de difícil obtenção devido à presença de elementos *anti-windup's*, saturação das variáveis controladas, etc.

### A.3.4 Métodos Indiretos

A identificação indireta procura a equação do controlador na obtenção do modelo da planta. Dependendo das variáveis disponíveis, este método de identificação pode ser do tipo série ou paralelo. É importante enfatizar que modelos identificados a partir de dados

de entrada e saída podem ser obtidos através de estruturas de identificação discretas ou contínuas, já discutidas anteriormente.

## Apêndice B. Funções de Restrição para os Modelos

Neste Apêndice serão apresentadas as funções objetivo e suas relações de restrição utilizadas para resolução dos problemas de otimização para os formatos de filtros utilizados na determinação do estimador e posteriormente utilizados para identificação dos modelos do processo. As relações utilizadas tomaram como base as condições estabelecidas pelo método de ajuste IMC mostradas na Tabela B.1. As fórmulas presentes na Tabela B.1 foram desenvolvidas para um controlador PID em paralelo. O filtro IMC ( $f$ ) foi selecionado de acordo com a Equação 2.15 com  $r = 1$  para modelos de primeira e segunda ordem. Para modelos com elemento integrador a função  $f$  foi definida como apresentado na Equação B.1.

$$f = \frac{(2\tau_{cl}-C)s+1}{(\tau_{cl}s+1)^2} \text{ onde } C = \left. \frac{d\tilde{G}_+}{ds} \right|_{s=0} \quad (\text{B.1})$$

**Tabela B.1:** Relações de sintonia para um controlador PID ideal (Seborg, 2004).

<i>Modelo</i>	<i>KpK</i>	<i>Ti</i>	<i>Td</i>
$\frac{K}{\tau s + 1}$	$\frac{\tau}{\tau_{cl}}$	$\tau$	—
$\frac{K}{(\tau_1 s + 1)(\tau_2 s + 1)}$	$\frac{\tau_1 + \tau_2}{\tau_{cl}}$	$\tau_1 + \tau_2$	$\frac{\tau_1 \tau_2}{\tau_1 + \tau_2}$
$\frac{K}{\tau^2 s^2 + 2\zeta \tau s + 1}$	$\frac{2\zeta \tau}{\tau_{cl}}$	$2\zeta \tau$	$\frac{\tau}{2\zeta}$
$\frac{K(-\beta s + 1)}{\tau^2 s^2 + 2\zeta \tau s + 1}; \beta > 0$	$\frac{2\zeta \tau}{\tau_{cl} + \beta}$	$2\zeta \tau$	$\frac{\tau}{2\zeta}$
$\frac{K}{s}$	$\frac{2}{\tau_{cl}}$	$2\tau_{cl}$	—

$\frac{K}{s(\tau s + 1)}$	$\frac{2\tau_{cl} + \tau}{\tau_{cl}^2}$	$2\tau_{cl} + \tau$	$\frac{2\tau_{cl}\tau}{2\tau_{cl} + \tau}$
$\frac{K}{\tau s + 1}e^{-\theta s}$	$\frac{\tau}{\tau_{cl} + \theta}$	$\tau$	—
$\frac{K}{\tau s + 1}e^{-\theta s}$	$\frac{\tau + \frac{\theta}{2}}{\tau_{cl} + \frac{\theta}{2}}$	$\tau + \frac{\theta}{2}$	$\frac{\tau\theta}{2\tau + \theta}$
$\frac{K(\tau_3 s + 1)}{(\tau_1 s + 1)(\tau_2 s + 1)}e^{-\theta s}$	$\frac{\tau_1 + \tau_2 - \tau_3}{\tau_{cl} + \theta}$	$\tau_1 + \tau_2 - \tau_3$	$\frac{\tau_1\tau_2 - (\tau_1 + \tau_2 - \tau_3)\tau_3}{\tau_1 + \tau_2 - \tau_3}$
$\frac{K(\tau_3 s + 1)}{\tau^2 s^2 + 2\zeta\tau s + 1}e^{-\theta s}$	$\frac{2\zeta\tau - \tau_3}{\tau_{cl} + \theta}$	$2\zeta\tau - \tau_3$	$\frac{\tau^2 - (2\zeta\tau - \tau_3)\tau_3}{2\zeta\tau - \tau_3}$
$\frac{K(-\tau_3 s + 1)}{(\tau_1 s + 1)(\tau_2 s + 1)}e^{-\theta s}$	$\frac{\tau_1 + \tau_2 + \frac{\tau_3\theta}{\tau_{cl} + \tau_3 + \theta}}{\tau_{cl} + \tau_3 + \theta}$	$\frac{\tau_1 + \tau_2}{\tau_{cl} + \tau_3 + \theta} + \frac{\tau_3\theta}{\tau_{cl} + \tau_3 + \theta}$	$\frac{\tau_3\theta}{\tau_{cl} + \tau_3 + \theta} + \frac{\tau_1\tau_2}{\tau_1 + \tau_2 + \frac{\tau_3\theta}{\tau_{cl} + \tau_3 + \theta}}$
$\frac{K(-\tau_3 s + 1)}{\tau^2 s^2 + 2\zeta\tau s + 1}e^{-\theta s}$	$\frac{2\zeta\tau + \frac{\tau_3\theta}{\tau_{cl} + \tau_3 + \theta}}{\tau_{cl} + \tau_3 + \theta}$	$2\zeta\tau + \frac{\tau_3\theta}{\tau_{cl} + \tau_3 + \theta}$	$\frac{\tau_3\theta}{\tau_{cl} + \tau_3 + \theta} + \frac{\tau^2}{2\zeta\tau + \frac{\tau_3\theta}{\tau_{cl} + \tau_3 + \theta}}$
$\frac{K}{s}e^{-\theta s}$	$\frac{2\tau_{cl} + \theta}{(\tau_{cl} + \theta)^2}$	$2\tau_{cl} + \theta$	—
$\frac{K}{s}e^{-\theta s}$	$\frac{2\tau_{cl} + \theta}{(\tau_{cl} + \frac{\theta}{2})^2}$	$2\tau_{cl} + \theta$	$\frac{\tau_{cl}\theta + \frac{\theta^2}{4}}{2\tau_{cl} + \theta}$
$\frac{K}{s(\tau s + 1)}e^{-\theta s}$	$\frac{2\tau_{cl} + \tau + \theta}{(\tau_{cl} + \theta)^2}$	$2\tau_{cl} + \tau + \theta$	$\frac{(2\tau_{cl} + \theta)\tau}{2\tau_{cl} + \tau + \theta}$

Na Tabela B.1  $K$  representa o ganho da função,  $\tau$  a constante de tempo,  $-1/\tau_1$  e  $-1/\tau_2$  são os pólos,  $-1/\tau_3$  representa o zero,  $\tau_{cl}$  é a constante de tempo desejada para o sistema em malha fechada,  $\theta$  representa o tempo morto,  $\zeta$  é o fator de amortecimento.

A identificação dos parâmetros dos modelos é feita através de otimização buscando a minimização da função objetivo dada pela soma da raiz do erro quadrado médio -  $RMSE$  (do inglês *root mean squared error*) de  $y$  e  $u$ ,  $RMSE_y$  e  $RMSE_u$ , dados como:

$$RMSE_y = \sqrt{\frac{\sum(y - y_{sim})^2}{n}} \text{ e } RMSE_u = \sqrt{\frac{\sum(u - u_{sim})^2}{n}} \quad (\text{B.2})$$

$$J_I(Kp, Ti, Td, y, u) = \min_x (RMSE_y + RMSE_u) \quad (B.3)$$

### B.1 Modelo Primeira Ordem

Este modelo é dado por uma função de transferência de primeira ordem sem tempo morto representada pela função expressa na Equação B.4.

$$G(s) = \frac{K}{\tau s + 1} \quad (B.4)$$

Da Tabela B.1 pode-se tirar as seguintes relações para este tipo de função:

$$KpK = \frac{\tau}{\tau_{cl}}; Ti = \tau \quad (B.5)$$

rearranjando:

$$K = \frac{Ti}{Kp\tau_{cl}}; \tau = Ti \quad (B.6)$$

e substituindo em  $G(s)$ :

$$G(s) = \frac{\frac{Ti}{Kp\tau_{cl}}}{(Ti s + 1)} \quad (B.7)$$

para a otimização tem-se então:

$$J_I(Kp, Ti, Td, y, u) = \min_{\tau_{cl}} (RMSE_y + RMSE_u) \quad (B.8)$$

$$x = \tau_{cl}$$

### B.2 Modelo Segunda Ordem

Este modelo é dado por uma função de transferência de segunda ordem sem tempo morto representada pela função expressa na Equação B.9.

$$G(s) = \frac{K}{(\tau_1 s + 1)(\tau_2 s + 1)} = \frac{K}{\tau_1 \tau_2 s^2 + (\tau_1 + \tau_2) s + 1} \quad (B.9)$$

Da Tabela B.1 pode-se tirar as seguintes relações para este tipo de função:

$$KpK = \frac{\tau_1 + \tau_2}{\tau_{cl}}; Ti = \tau_1 + \tau_2; Td = \frac{\tau_1 \tau_2}{\tau_1 + \tau_2} \quad (B.10)$$

rearranjando:

$$K = \frac{Ti}{Kp\tau_{cl}}; \tau_1 \tau_2 = Td Ti \quad (B.11)$$

e substituindo em  $G(s)$ :

$$G(s) = \frac{\frac{Ti}{Kp\tau_{cl}}}{TdTs^2 + Tis + 1} \quad (\text{B.12})$$

para a otimização tem-se então:

$$J_I(Kp, Ti, Td, y, u) = \min_{\tau_{cl}} (RMSE_y + RMSE_u)$$

$$x = \tau_{cl} \quad (\text{B.13})$$

### B.3 Modelo Primeira Ordem com Tempo Morto

Este modelo é dado por uma função de transferência de primeira ordem com tempo morto representada pela função expressa na Equação B.14.

$$G(s) = \frac{K}{\tau s + 1} e^{-\theta s} \quad (\text{B.14})$$

Da Tabela B.1, considerando o controlador um PI, pode-se tirar as seguintes relações para este tipo de função:

$$KpK = \frac{\tau}{\tau_{cl} + \theta}; Ti = \tau; Td = 0 \quad (\text{B.15})$$

rearranjando:

$$K = \frac{Ti}{Kp(\tau_{cl} + \theta)}; \tau = Ti \quad (\text{B.16})$$

substituindo em  $G(s)$ :

$$G(s) = \frac{\frac{Ti}{Kp(\tau_{cl} + \theta)}}{Tis + 1} e^{-\theta s} \quad (\text{B.17})$$

para a otimização tem-se então:

$$J_I(Kp, Ti, Td, y, u) = \min_{\tau_{cl}, \theta} (RMSE_y + RMSE_u)$$

$$x = [\tau_{cl} \ \theta] \quad (\text{B.18})$$

### B.4 Modelo Segunda Ordem com Tempo Morto

Este modelo é dado por uma função de transferência de primeira ordem com tempo morto representada pela função expressa na Equação B.19.

$$G(s) = \frac{K(\tau_3 s + 1)}{(\tau_1 s + 1)(\tau_2 s + 1)} e^{-\theta s} = \frac{K(\tau_3 s + 1)}{\tau_1 \tau_2 s^2 + (\tau_1 + \tau_2)s + 1} e^{-\theta s} \quad (\text{B.19})$$

Da Tabela B.1, considerando o controlador um PI, pode-se tirar as seguintes relações para este tipo de função:

$$KpK = \frac{\tau_1 + \tau_2 - \tau_3}{\tau_{cl} + \theta}; Ti = \tau_1 + \tau_2 - \tau_3; Td = \frac{\tau_1 \tau_2 - (\tau_1 + \tau_2 - \tau_3)\tau_3}{\tau_1 + \tau_2 - \tau_3} \quad (\text{B.20})$$

rearranjando:

$$K = \frac{Ti}{Kp(\tau_{cl} + \theta)}; \tau_1 + \tau_2 = Ti + \tau_3; \tau_1\tau_2 = Ti(Td + \tau_3) \quad (\text{B.21})$$

substituindo em  $G(s)$ :

$$G(s) = \frac{\frac{Ti}{Kp(\tau_{cl} + \theta)}(\tau_3 + 1)}{Ti(Td + \tau_3)s^2 + (Ti + \tau_3)s + 1} e^{-\theta s} \quad (\text{B.22})$$

para a otimização tem-se então:

$$J_1(Kp, Ti, Td, y, u) = \min_{\tau_{cl}, \theta, \tau_3} (RMSE_y + RMSE_u)$$

$$x = [\tau_{cl} \ \theta \ \tau_3] \quad (\text{B.23})$$

## Apêndice C. Resultados Gerais

Este Apêndice compreende todos os resultados obtidos para as análises realizada no estudo de casos que constituem este trabalho.

### C.1 Resultados das Análises sobre a eficiência da estimação dos *DNMs*

#### C.1.1 Modelos de Filtro encontrados através do problema de otimização

**Tabela C.1:** Modelos de Filtros encontrados para serem aplicados na obtenção de  $\hat{d}$  para os *DNM*  $d_1$ ,  $d_2$ ,  $d_3$  e  $d_4$  no ponto de operação OP1.

	Processo $Gp(s)$	Modelo de Filtro			
		$d_1$	$d_2$	$d_3$	$d_4$
I	$\frac{1}{5s+1}$	$\frac{0,78}{2,3s+1}$	$\frac{0,93}{2,3s+1}$	$\frac{0,8}{2,3s+1}$	$\frac{0,8}{2,3s+1}$
II	$\frac{1}{15s^2+8s+1}$	$\frac{0,34}{3,56s+1}$	$\frac{0,89}{3,56s+1}$	$\frac{0,59}{3,56s+1}$	$\frac{0,68}{3,56s+1}$
III	$\frac{1}{9s^2+3s+1}$	$\frac{0,89}{1,92s^2+2,78s+1}$	$\frac{0,95}{1,93s^2+2,78s+1}$	$\frac{0,90}{1,93s^2+2,78s+1}$	$\frac{0,92}{1,93s^2+2,78s+1}$
IV	$\frac{-3s+1}{25s^2+40s+1}$	$\frac{0,39}{19,23s+1}$	$\frac{0,34}{19,23s+1}$	$\frac{1,16}{19,23s+1}$	$\frac{1,73}{19,23s+1}$
V	$\frac{8}{15s+1}e^{-5s}$	$\frac{20,84}{10,44s+1}e^{-0,23s}$	$\frac{20,84}{10,44s+1}e^{-0,2s}$	$\frac{20,84}{10,44s+1}e^{-0,23s}$	$\frac{20,44}{10,44s+1}e^{-0,43s}$
VI	$\frac{1}{5s+1}e^{-1s}$	$\frac{0,61}{1,2s^2+2,17s+1}$	$\frac{0,89}{1,2s^2+2,17s+1}$	$\frac{0,65}{1,2s^2+2,17s+1}$	$\frac{0,72}{1,2s^2+2,17s+1}$
VII	$\frac{2(3s+1)}{24s^2+10s+1}e^{-5s}$	$\frac{3,57}{7,5s+1}e^{-7,1s}$	$\frac{66,19s+3,6}{162s^2+25,9s+1}e^{-6s}$	$\frac{37,58s+3,5}{105s^2+18,22s+1}e^{-6s}$	$\frac{25,15s+3,5}{78,93s^2+14,69s+1}e^{-6s}$
VIII	$\frac{2s+1}{12s^2+3s+1}e^{-1s}$	$\frac{0,87}{1,34s^2+2,28s+1}$	$\frac{0,95}{1,3s^2+2,3s+1}$	$\frac{0,90}{1,3s^2+2,3s+1}$	$\frac{0,92}{1,3s^2+2,3s+1}$



**Tabela C.2:** Modelos de Filtros encontrados para serem aplicados na obtenção de  $\hat{d}$  para os *DNM*  $d_5, d_6, d_7$  e  $d_8$  no ponto de operação OP1.

	Processo $Gp(s)$	Modelo de Filtro			
		$d_5$	$d_6$	$d_7$	$d_8$
I	$\frac{1}{5s+1}$	$\frac{0,91}{2,3s+1}$	$\frac{0,52}{2,3s+1}$	$\frac{0,48}{2,3s+1}$	$\frac{0,66}{2,3s+1}$
II	$\frac{1}{15s^2+8s+1}$	$\frac{0,86}{3,56s+1}$	$\frac{0,64}{3,56s+1}$	$\frac{0,48}{3,56s+1}$	$\frac{0,76}{3,56s+1}$
III	$\frac{1}{9s^2+3s+1}$	$\frac{0,94}{1,92s^2+2,78s+1}$	$\frac{0,83}{1,93s^2+2,78s+1}$	$\frac{1,55}{2,78s+1}e^{-1,93s}$	$\frac{1,53}{2,78s+1}e^{-1,95s}$
IV	$\frac{-3s+1}{25s^2+40s+1}$	$\frac{0,39}{19,23s+1}$	$\frac{0,34}{19,23s+1}$	$\frac{1,16}{19,23s+1}$	$\frac{1,73}{19,23s+1}$
V	$\frac{8}{15s+1}e^{-5s}$	$\frac{20,84}{10,44s+1}e^{-0,24s}$	$\frac{20,84}{10,44s+1}e^{-0,47s}$	$\frac{20,84}{10,44s+1}e^{-0,31s}$	$\frac{20,44}{10,44s+1}e^{-0,54s}$
VI	$\frac{1}{5s+1}e^{-1s}$	$\frac{0,86}{1,2s^2+2,17s+1}$	$\frac{0,62}{1,2s^2+2,17s+1}$	$\frac{0,54}{1,2s^2+2,17s+1}$	$\frac{0,78}{1,2s^2+2,17s+1}$
VII	$\frac{2(3s+1)}{24s^2+10s+1}e^{-5s}$	$\frac{24,67s+3,6}{76,43s^2+14,36s+1}e^{-6s}$	$\frac{12,81s+3,4}{53s^2+11s+1}e^{-6s}$	$\frac{3,7}{7,7s+1}e^{-7s}$	$\frac{20,6s+3,5}{69,62s^2+13,45s+1}e^{-5s}$
VIII	$\frac{2s+1}{12s^2+3s+1}e^{-1s}$	$\frac{0,93}{1,34s^2+2,28s+1}$	$\frac{0,82}{1,3s^2+2,3s+1}$	$\frac{1,76}{2,3s+1}e^{-1,61s}$	$\frac{1,76}{2,3s+1}e^{-1,63s}$

**Tabela C.3:** Modelos de Filtros encontrados para serem aplicados na obtenção de  $\hat{d}$  para os *DNM*  $d_1, d_2, d_3$  e  $d_4$  no ponto de operação OP2.

	Processo $Gp(s)$	Modelo de Filtro			
		$d_1$	$d_2$	$d_3$	$d_4$
I	$\frac{1}{5s+1}$	$\frac{1}{1,64s+1}$	$\frac{1}{1,64s+1}$	$\frac{1}{1,64s+1}$	$\frac{1}{1,64s+1}$
II	$\frac{1}{15s^2+8s+1}$	$\frac{0,97}{4s+1}$	$\frac{0,97}{4s+1}$	$\frac{0,97}{4s+1}$	$\frac{0,98}{4s+1}$
III	$\frac{1}{9s^2+3s+1}$	$\frac{1}{2s^2+3,14s+1}$	$\frac{1}{2s^2+3,14s+1}$	$\frac{1}{2s^2+3,14s+1}$	$\frac{1}{2s^2+3,14s+1}$
IV	$\frac{-3s+1}{25s^2+40s+1}$	$\frac{1}{41,67s+1}$	$\frac{1}{41,67s+1}$	$\frac{0,66}{41,67s+1}e^{-0,25s}$	$\frac{0,66}{41,67s+1}e^{-0,32s}$
V	$\frac{8}{15s+1}e^{-5s}$	$\frac{8}{12,5s+1}e^{-0,3s}$	$\frac{8}{12,5s+1}e^{-0,2s}$	$\frac{8}{12,5s+1}e^{-0,5s}$	$\frac{8}{12,5s+1}e^{-0,4s}$
VI	$\frac{1}{5s+1}e^{-1s}$	$\frac{1}{5s+1}$	$\frac{1}{5s+1}$	$\frac{1}{5s+1}$	$\frac{1}{5s+1}$
VII	$\frac{2(3s+1)}{24s^2+10s+1}e^{-5s}$	$\frac{1,54}{8,6s+1}e^{-3,3s}$	$\frac{1,54}{8,6s+1}e^{-3,3s}$	$\frac{1,54}{8,6s+1}e^{-3,3s}$	$\frac{16,9s+1,6}{97,8s^2+19,28s+1}e^{-3s}$
VIII	$\frac{2s+1}{12s^2+3s+1}e^{-1s}$	$\frac{1}{0,67s^2+5,7s+1}$	$\frac{1}{0,67s^2+5,7s+1}$	$\frac{1}{0,67s^2+5,7s+1}$	$\frac{1}{0,67s^2+5,7s+1}$

**Tabela C.4:** Modelos de Filtros encontrados para serem aplicados na obtenção de  $\hat{d}$  para os DNM  $d_5, d_6, d_7$  e  $d_8$  no ponto de operação OP2.

	Processo $Gp(s)$	Modelo de Filtro			
		$d_5$	$d_6$	$d_7$	$d_8$
I	$\frac{1}{5s+1}$	$\frac{1}{1,64s+1}$	$\frac{1}{1,64s+1}$	$\frac{1}{1,64s+1}$	$\frac{1}{1,64s+1}$
II	$\frac{1}{15s^2+8s+1}$	$\frac{0,98}{4s+1}$	$\frac{0,96}{4s+1}$	$\frac{0,93}{4s+1}$	$\frac{0,91}{4s+1}$
III	$\frac{1}{9s^2+3s+1}$	$\frac{1}{2s^2+3,14s+1}$	$\frac{1}{2s^2+3,14s+1}$	$\frac{1}{2s^2+3,14s+1}$	$\frac{1}{2s^2+3,14s+1}$
IV	$\frac{-3s+1}{25s^2+40s+1}$	$\frac{1,61}{41,67s+1}$	$\frac{0,66}{41,67s+1}e^{-0,3s}$	$\frac{1,31}{41,67s+1}$	$\frac{0,66}{41,67s+1}e^{-0,16s}$
V	$\frac{8}{15s+1}e^{-5s}$	$\frac{8}{12,5s+1}e^{-0,23s}$	$\frac{8}{12,5s+1}e^{-0,4s}$	$\frac{8}{12,5s+1}e^{-0,3s}$	$\frac{8}{12,5s+1}e^{-0,5s}$
VI	$\frac{1}{5s+1}e^{-1s}$	$\frac{1}{5s+1}$	$\frac{1}{5s+1}$	$\frac{1}{5s+1}$	$\frac{1}{5s+1}$
VII	$\frac{2(3s+1)}{24s^2+10s+1}e^{-5s}$	$\frac{1,54}{8,6s+1}e^{-3,3s}$	$\frac{16,9s+1,6}{97,8s^2+19,28s+1}e^{-3s}$	$\frac{1,54}{8,6s+1}e^{-3,4s}$	$\frac{1,54}{8,6s+1}e^{-3,3s}$
VIII	$\frac{2s+1}{12s^2+3s+1}e^{-1s}$	$\frac{1}{0,67s^2+5,7s+1}$	$\frac{1}{0,67s^2+5,7s+1}$	$\frac{1}{0,67s^2+5,7s+1}$	$\frac{1}{0,67s^2+5,7s+1}$

**Tabela C.5:** Modelos de Filtros encontrados para serem aplicados na obtenção de  $\hat{d}$  para os DNM  $d_1, d_2, d_3$  e  $d_4$  no ponto de operação OP3.

	Processo $Gp(s)$	Modelo de Filtro			
		$d_1$	$d_2$	$d_3$	$d_4$
I	$\frac{1}{5s+1}$	$\frac{0,97}{3,72s+1}$	$\frac{0,99}{3,72s+1}$	$\frac{0,98}{3,72s+1}$	$\frac{0,98}{3,72s+1}$
II	$\frac{1}{15s^2+8s+1}$	$\frac{0,96}{6s+1}$	$\frac{0,99}{5,92s+1}$	$\frac{0,97}{5,92s+1}$	$\frac{0,97}{5,92s+1}$
III	$\frac{1}{9s^2+3s+1}$	$\frac{0,96}{20s^2+5s+1}$	$\frac{0,97}{20s^2+5s+1}$	$\frac{0,94}{20s^2+5s+1}$	$\frac{0,94}{20s^2+5s+1}$
IV	$\frac{-3s+1}{25s^2+40s+1}$	$\frac{0,96}{22,22s+1}$	$\frac{0,96}{22,22s+1}$	$\frac{0,74}{22,22s+1}$	$\frac{0,74}{22,22s+1}$
V	$\frac{8}{15s+1}e^{-5s}$	$\frac{9,87}{18,2s+1}e^{-0,25s}$	$\frac{9,88}{18,2s+1}e^{-0,23s}$	$\frac{9,76}{18,2s+1}e^{-0,46s}$	$\frac{9,77}{18,2s+1}e^{-0,42s}$
VI	$\frac{1}{5s+1}e^{-1s}$	$\frac{0,97}{4,23s+1}$	$\frac{0,99}{4,23s+1}$	$\frac{0,97}{4,23s+1}$	$\frac{0,97}{4,23s+1}$
VII	$\frac{2(3s+1)}{24s^2+10s+1}e^{-5s}$	$\frac{3,23}{7,7s+1}e^{-0,25s}$	$\frac{3,28}{7,7s+1}e^{-0,12s}$	$\frac{3,12}{7,7s+1}e^{-0,35s}$	$\frac{3,12}{7,7s+1}e^{-0,28s}$
VIII	$\frac{2s+1}{12s^2+3s+1}e^{-1s}$	$\frac{0,97}{1,5s^2+2,53s+1}$	$\frac{0,98}{1,5s^2+2,53s+1}$	$\frac{0,98}{1,5s^2+2,53s+1}$	$\frac{0,98}{1,5s^2+2,53s+1}$

**Tabela C.6:** Modelos de Filtros encontrados para serem aplicados na obtenção de  $\hat{d}$  para os *DNM*  $d_5$ ,  $d_6$ ,  $d_7$  e  $d_8$  no ponto de operação OP3.

	Processo $Gp(s)$	Modelo de Filtro			
		$d_5$	$d_6$	$d_7$	$d_8$
I	$\frac{1}{5s+1}$	$\frac{0,99}{3,72s+1}$	$\frac{0,97}{3,72s+1}$	$\frac{0,95}{3,72s+1}$	$\frac{0,94}{3,72s+1}$
II	$\frac{1}{15s^2+8s+1}$	$\frac{0,99}{5,9s+1}$	$\frac{0,94}{5,92s+1}$	$\frac{0,93}{5,92s+1}$	$\frac{0,88}{5,92s+1}$
III	$\frac{1}{9s^2+3s+1}$	$\frac{0,97}{20s^2+5s+1}$	$\frac{0,88}{20s^2+5s+1}$	$\frac{0,89}{20s^2+5s+1}$	$\frac{0,81}{20s^2+5s+1}$
IV	$\frac{1}{25s^2+40s+1}$	$\frac{0,93}{22,22s+1}$	$\frac{0,37}{22,22s+1}$	$\frac{0,86}{22,22s+1}$	$\frac{0,58}{22,22s+1}$
V	$\frac{8}{15s+1}e^{-5s}$	$\frac{9,85}{18,2s+1}e^{-0,26s}$	$\frac{9,85}{18,2s+1}e^{-0,43s}$	$\frac{9,86}{18,2s+1}e^{-0,28s}$	$\frac{9,8}{18,2s+1}e^{-0,43s}$
VI	$\frac{1}{5s+1}e^{-1s}$	$\frac{0,98}{4,23s+1}$	$\frac{0,96}{4,23s+1}$	$\frac{0,93}{4,23s+1}$	$\frac{0,91}{4,23s+1}$
VII	$\frac{2(3s+1)}{24s^2+10s+1}e^{-5s}$	$\frac{3,2}{7,7s+1}e^{-0,17s}$	$\frac{3,2}{7,7s+1}e^{-0,31s}$	$\frac{3,1}{7,7s+1}e^{-0,25s}$	$\frac{3,12}{7,7s+1}e^{-0,37s}$
VIII	$\frac{2s+1}{12s^2+3s+1}e^{-1s}$	$\frac{0,98}{1,5s^2+2,53s+1}$	$\frac{0,96}{1,5s^2+2,53s+1}$	$\frac{0,9}{1,5s^2+2,53s+1}$	$\frac{0,92}{1,5s^2+2,53s+1}$

### C.1.2 Valores da função objetivo do problema de otimização avaliada no ponto inicial e no ponto ótimo

**Tabela C.7:** Valor da função objetivo obtida como resultado da otimização para os ponto de operação OP1 com os *DNMs*  $d_1$ ,  $d_2$ ,  $d_3$  e  $d_4$ .

	Processo $Gp(s)$	Valor da Função objetivo avaliada no ponto inicial ( $X_0$ )( $\times 10^2$ )				Valor da Função objetivo para a solução( $\times 10^5$ )			
		$d_1$	$d_2$	$d_3$	$d_4$	$d_1$	$d_2$	$d_3$	$d_4$
I	$\frac{1}{5s+1}$	0,7	3,2	2,23	7,19	3,15	4,8	5,82	17,14
II	$\frac{1}{15s^2+8s+1}$	1,5	2,5	2,35	9,5	1,16	4,04	3,13	11,64
III	$\frac{1}{9s^2+3s+1}$	0,03	0,6	2,82	4	21,2	33,1	31,9	74,1
IV	$\frac{1}{25s^2+40s+1}$	1,5	3	2,16	7,3	309	496,3	1540	4570
V	$\frac{8}{15s+1}e^{-5s}$	1,04	2,8	1,67	11,7	2,1	3,24	19,5	52,7
VI	$\frac{1}{5s+1}e^{-1s}$	1,7	3,3	2,9	9,1	5,9	10,5	9,2	25,44
VII	$\frac{2(3s+1)}{24s^2+10s+1}e^{-5s}$	0,5	0,6	1,3	0,93	99,7	172,25	165,9	435,9
VIII	$\frac{2s+1}{12s^2+3s+1}e^{-1s}$	1,8	1,2	0,95	6,2	18,1	29,1	28,8	62,5

**Tabela C.8:** Valor da função objetivo obtida como resultado da otimização para os ponto de operação OP1 com os DNMs  $d_5, d_6, d_7$  e  $d_8$ .

	Processo $Gp(s)$	Valor da Função objetivo avaliada no ponto inicial ( $X_0$ )( $\times 10^2$ )				Valor da Função objetivo para a solução( $\times 10^5$ )			
		$d_5$	$d_6$	$d_7$	$d_8$	$d_5$	$d_6$	$d_7$	$d_8$
I	$\frac{1}{5s+1}$	0,7	2,1	2,9	12,4	7,1	465	297,7	6633
II	$\frac{1}{15s^2+8s+1}$	3,1	7,6	3,8	17	5,2	2512	699	9857
III	$\frac{1}{9s^2+3s+1}$	0,3	7,3	1,8	7,9	58,4	97,3	51,2	1021
IV	$\frac{-3s+1}{25s^2+40s+1}$	3,5	3,9	2	7,3	479	3081	724,7	5137
V	$\frac{8}{15s+1}e^{-5s}$	5,9	4,3	2,5	45	7	76,4	10	120
VI	$\frac{1}{5s+1}e^{-1s}$	4,3	7,1	1,5	12,4	16	2298	854	1016
VII	$\frac{2(3s+1)}{24s^2+10s+1}e^{-5s}$	0,9	3,2	1,2	8,9	292	573	429	1975
VIII	$\frac{2s+1}{12s^2+3s+1}e^{-1s}$	1,6	1,2	1,4	2,3	52,4	85,7	365,1	1712

**Tabela C.9:** Valor da função objetivo obtida como resultado da otimização para os ponto de operação OP2 com os DNMs  $d_1, d_2, d_3$  e  $d_4$ .

	Processo $Gp(s)$	Valor da Função objetivo avaliada no ponto inicial ( $X_0$ )( $\times 10^2$ )				Valor da Função objetivo para a solução( $\times 10^5$ )			
		$d_1$	$d_2$	$d_3$	$d_4$	$d_1$	$d_2$	$d_3$	$d_4$
I	$\frac{1}{5s+1}$	6	7,5	11,7	16,6	5,7	7,9	9,3	23,7
II	$\frac{1}{15s^2+8s+1}$	0,2	2,2	2,53	3,9	4,3	5,7	7,7	21,1
III	$\frac{1}{9s^2+3s+1}$	1,3	4,3	4,46	20	38,6	71,4	57,5	135,4
IV	$\frac{-3s+1}{25s^2+40s+1}$	1,6	2,7	2,84	4,9	0,4	0,8	0,5	1,9
V	$\frac{8}{15s+1}e^{-5s}$	1,2	4,7	1,78	5,07	3	3,4	14	39
VI	$\frac{1}{5s+1}e^{-1s}$	1,2	0,8	7,03	0,4	4,1	5,4	7,2	19,4
VII	$\frac{2(3s+1)}{24s^2+10s+1}e^{-5s}$	0,5	0,5	1,14	6,3	19,9	33,4	36,1	93,4
VIII	$\frac{2s+1}{12s^2+3s+1}e^{-1s}$	0,25	2,83	0,5	1,44	7,98	13,57	12,03	29,74

**Tabela C.10:** Valor da função objetivo obtida como resultado da otimização para os ponto de operação OP2 com os *DNMs*  $d_5$ ,  $d_6$ ,  $d_7$  e  $d_8$ .

	Processo $Gp(s)$	Valor da Função objetivo avaliada no ponto inicial ( $X_0$ )( $\times 10^2$ )				Valor da Função objetivo para a solução( $\times 10^5$ )			
		$d_5$	$d_6$	$d_7$	$d_8$	$d_5$	$d_6$	$d_7$	$d_8$
I	$\frac{1}{5s+1}$	1,97	1,84	8,5	54,8	13,32	31,07	22,15	102,7
II	$\frac{1}{15s^2+8s+1}$	1,2	3	1	7,5	9,21	24,16	9,22	57,51
III	$\frac{1}{9s^2+3s+1}$	8,05	13,88	1,4	24,41	123	177,8	236	617,3
IV	$\frac{-3s+1}{25s^2+40s+1}$	4,1	3,1	1,34	8,8	0,34	1,9	0,72	4,9
V	$\frac{8}{15s+1}e^{-5s}$	2,54	14,7	3,6	12,8	5,55	59,06	12,25	134,8
VI	$\frac{1}{5s+1}e^{-1s}$	8,22	7,12	5,2	11,6	8,76	23,26	10,71	62,6
VII	$\frac{2(3s+1)}{24s^2+10s+1}e^{-5s}$	1,4	6	1,92	13,9	52,6	129,8	102	362,5
VIII	$\frac{2s+1}{12s^2+3s+1}e^{-1s}$	1,67	1,2	0,64	27,43	40,32	47,36	125,4	154,26

**Tabela C.11:** Valor da função objetivo obtida como resultado da otimização para os ponto de operação OP3 com os *DNMs*  $d_1$ ,  $d_2$ ,  $d_3$  e  $d_4$ .

	Processo $Gp(s)$	Valor da Função objetivo avaliada no ponto inicial ( $X_0$ )( $\times 10^2$ )				Valor da Função objetivo para a solução( $\times 10^5$ )			
		$d_1$	$d_2$	$d_3$	$d_4$	$d_1$	$d_2$	$d_3$	$d_4$
I	$\frac{1}{5s+1}$	1,42	2,39	0,27	0,9	4,16	5,45	7,44	20,16
II	$\frac{1}{15s^2+8s+1}$	0,05	0,53	0,8	0,34	3,29	4,57	5,96	16,95
III	$\frac{1}{9s^2+3s+1}$	1,23	0,92	0,74	3,5	232,7	357,3	334,7	763,53
IV	$\frac{-3s+1}{25s^2+40s+1}$	1,77	2,77	1,76	9,39	0,71	1,23	0,52	2,07
V	$\frac{8}{15s+1}e^{-5s}$	2,31	6,27	7,98	14,46	2,15	3,46	13,59	40,74
VI	$\frac{1}{5s+1}e^{-1s}$	0,44	1,6	1,94	5,64	3,96	5,28	7,13	19,52
VII	$\frac{2(3s+1)}{24s^2+10s+1}e^{-5s}$	0,37	0,84	0,49	1,67	2,15	1,67	6,39	15,60
VIII	$\frac{2s+1}{12s^2+3s+1}e^{-1s}$	1,44	4,44	2,76	1,98	31,16	50,85	47,57	106,12

**Tabela C.12:** Valor da função objetivo obtida como resultado da otimização para os ponto de operação OP3 com os DNMs  $d_5$ ,  $d_6$ ,  $d_7$  e  $d_8$ .

	Processo $Gp(s)$	Valor da Função objetivo avaliada no ponto inicial ( $X_0$ )( $\times 10^2$ )				Valor da Função objetivo para a solução( $\times 10^5$ )			
		$d_5$	$d_6$	$d_7$	$d_8$	$d_5$	$d_6$	$d_7$	$d_8$
I	$\frac{1}{5s+1}$	1,19	4,18	1,66	9,7	8,72	23,61	9,51	58,83
II	$\frac{1}{15s^2+8s+1}$	0,29	1,58	2,46	1,8	6,81	17,35	5,82	32,17
III	$\frac{1}{9s^2+3s+1}$	2,15	2,49	2,02	8,8	574,26	1130	992	4530
IV	$\frac{-3s+1}{25s^2+40s+1}$	3,68	6,32	2,02	7,9	0,5	135	0,8	3,66
V	$\frac{8}{15s+1}e^{-5s}$	5,7	23,77	11,18	61,61	6,2	47,27	7,34	71,17
VI	$\frac{1}{5s+1}e^{-1s}$	0,31	2,43	0,4	5,25	8,33	22,10	8,3	50,37
VII	$\frac{2(3s+1)}{24s^2+10s+1}e^{-5s}$	0,84	1,79	1,22	14,28	3,07	26,42	8,43	90,61
VIII	$\frac{2s+1}{12s^2+3s+1}e^{-1s}$	5,03	6,01	0,44	13,55	98,24	148,69	181	478,01

### C.1.3 Valores do índice *Fit* para as estruturas ARX, Box-Jenkins, N4SID e Filtros identificados

**Tabela C.13:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal  $y$ , para os processos sob o efeito do distúrbio  $d_1$ .

Processo	$ARX_{(y u)}$	Ordem dos polinômios $[na, nb, nk]$	$BJ_{(y u)}$	Ordem dos polinômios $[nb, nc, nd, nf, nk]$	$N4SID_{(y u)}$	Ordem do modelo N4SID
I	100	[2,3,0]	100	[3,2,2,2,0]	-121,62	2
II	100	[2,3,0]	-90,3	[3,2,2,2,0]	-135,3	2
III	100	[3,3,0]	89,30	[3,2,2,3,0]	97	3
IV	100	[2,3,0]	99,99	[3,2,2,2,0]	-388,66	2
V	100	[2,3,0]	99,99	[3,2,2,2,0]	-272,6	2
VI	100	[3,3,0]	100	[3,2,2,3,0]	0,87	3
VII	100	[3,3,0]	100	[3,2,2,3,0]	99,89	3
VIII	100	[3,3,0]	99,99	[3,2,2,3,0]	98,05	3

**Tabela C.14:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal  $\hat{w}$ , para os processos sob o efeito do distúrbio  $d_1$ .

Processo	$ARX_{(\hat{w} u)}$	Ordem dos polinômios	$BJ_{(\hat{w} u)}$	Ordem dos polinômios	$N4SID_{(\hat{w} u)}$	Ordem do modelo	$Filtro_{(\hat{w} u)}$
		$[na, nb, nk]$		$[nb, nc, nd, nf, nk]$		N4SID	
I	99,95	[2,2,0]	98,65	[2,2,2,2,1]	99,96	2	99,83
II	99,87	[2,2,0]	98,37	[2,2,2,2,0]	99,92	2	99,80
III	96,29	[3,1,99]	99,99	[1,2,2,3,99]	99,99	3	99,15
IV	99,80	[2,3,0]	99,45	[3,2,2,2,0]	99,90	2	99,90
V	99,83	[2,3,0]	99,99	[3,2,2,2,0]	99,96	2	99,84
VI	99,92	[2,4,5]	99,94	[4,2,2,2,5]	99,94	4	99,81
VII	100	[3,4,0]	100	[4,2,2,3,0]	99,72	3	99,72
VIII	99,25	[3,2,0]	99,99	[2,2,2,3,0]	99,99	4	99,61

**Tabela C.15:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal  $y$ , para os processos sob o efeito do distúrbio  $d_2$ .

Processo	$ARX_{(y u)}$	Ordem dos polinômios	$BJ_{(y u)}$	Ordem dos polinômios	$N4SID_{(y u)}$	Ordem do modelo
		$[na, nb, nk]$		$[nb, nc, nd, nf, nk]$		N4SID
I	100	[2,3,0]	100	[3,2,2,2,0]	-308,13	2
II	100	[2,3,0]	86,15	[3,2,2,2,0]	-268,7	2
III	100	[3,3,0]	100	[3,2,2,3,0]	95,56	3
IV	100	[2,3,0]	73,33	[3,2,2,2,0]	-188,51	2
V	100	[2,3,0]	100	[3,2,2,2,0]	-279,93	2
VI	100	[3,3,0]	100	[3,2,2,3,0]	86,69	3
VII	100	[6,5,0]	99,99	[5,2,2,6,0]	99,94	3
VIII	100	[3,3,0]	100	[3,2,2,3,0]	89,57	3

**Tabela C.16:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal  $\hat{w}$ , para os processos sob o efeito do distúrbio  $d_2$ .

Processo	$ARX_{(\hat{w} u)}$	Ordem dos polinômios [na, nb, nk]	$BJ_{(\hat{w} u)}$	Ordem dos polinômios [nb, nc, nd, nf, nk]	$N4SID_{(\hat{w} u)}$	Ordem do modelo N4SID	Filtro $_{(\hat{w} u)}$
I	99,98	[2,2,1]	99,89	[2,2,2,2,1]	99,93	2	99,91
II	99,97	[2,2,1]	99,95	[2,2,2,2,1]	99,88	2	99,90
III	99,64	[3,2,0]	98,59	[2,2,2,3,0]	99,99	3	99,80
IV	100	[2,3,0]	99,99	[3,2,2,2,0]	-48,43	2	33,14
V	100	[2,3,0]	100	[3,2,2,2,0]	97,45	2	99,84
VI	-173.10 <sup>9</sup>	[3,1,55]	3,59	[1,2,2,3,55]	99,99	4	99,84
VII	100	[5,6,0]	100	[6,2,2,5,0]	94,21	3	95,24
VIII	99,61	[3,2,0]	98,65	[2,2,2,3,0]	99,99	4	99,81

**Tabela C.17:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal  $y$ , para os processos sob o efeito do distúrbio  $d_3$ .

Processo	$ARX_{(y u)}$	Ordem dos polinômios [na, nb, nk]	$BJ_{(y u)}$	Ordem dos polinômios [nb, nc, nd, nf, nk]	$N4SID_{(y u)}$	Ordem do modelo N4SID
I	100	[2,3,0]	100	[3,2,2,2,0]	-6,78	2
II	100	[2,3,0]	100	[3,2,2,2,0]	-6,19	2
III	100	[3,3,0]	100	[3,2,2,3,0]	97,66	3
IV	100	[2,3,0]	100	[3,2,2,2,0]	55,84	2
V	100	[2,5,0]	100	[5,2,2,2,0]	21,13	2
VI	100	[3,3,0]	100	[3,2,2,3,0]	97,83	3
VII	99,67	[5,2,15]	98,49	[2,2,2,5,15]	99,97	3
VIII	100	[3,3,0]	100	[3,2,2,3,0]	95,31	3



**Tabela C.18:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal  $\hat{w}$ , para os processos sob o efeito do distúrbio  $d_3$ .

<i>Processo</i>	$ARX_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [ <i>na, nb, nk</i> ]	$BJ_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [ <i>nb, nc, nd, nf, nk</i> ]	$N4SID_{(\hat{w} u)}$	<i>Ordem do modelo</i> <i>N4SID</i>	$Filtro_{(\hat{w} u)}$
I	99,97	[2,2,1]	99,92	[2,2,2,2,1]	99,92	2	99,85
II	99,88	[2,2,0]	99,85	[2,2,2,2,0]	0,091	2	99,82
III	99,93	[3,2,0]	99,99	[2,2,2,3,0]	99,99	4	99,63
IV	99,99	[2,3,0]	-117,42	[3,2,2,2,0]	30,32	2	-21,09
V	99,99	[2,5,0]	99,99	[5,2,2,2,0]	98,52	2	99,90
VI	-1759	[3,1,0]	74,35	[1,2,2,3,0]	99,99	4	99,73
VII	99,99	[3,4,0]	99,99	[4,2,2,3,0]	76,56	3	94,96
VIII	99,94	[3,2,0]	99,99	[2,2,2,3,0]	99,99	4	99,71

**Tabela C.19:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal  $y$ , para os processos sob o efeito do distúrbio  $d_4$ .

<i>Processo</i>	$ARX_{(y u)}$	<i>Ordem dos polinômios</i> [ <i>na, nb, nk</i> ]	$BJ_{(y u)}$	<i>Ordem dos polinômios</i> [ <i>nb, nc, nd, nf, nk</i> ]	$N4SID_{(y u)}$	<i>Ordem do modelo</i> <i>N4SID</i>
I	100	[2,3,0]	100	[3,2,2,2,0]	-33,63	2
II	100	[2,3,0]	88,98	[3,2,2,2,0]	3,73	2
III	100	[3,3,0]	100	[3,2,2,3,0]	97,81	3
IV	100	[2,3,0]	99,99	[3,2,2,2,0]	54,13	2
V	100	[2,3,0]	100	[3,2,2,2,0]	-62,50	2
VI	100	[3,3,0]	100	[3,2,2,3,0]	98,01	3
VII	99,91	[3,1,53]	98,90	[1,2,2,3,53]	99,99	3
VIII	100	[3,3,0]	98,06	[3,2,2,3,0]	97,98	3

**Tabela C.20:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal  $\hat{w}$ , para os processos sob o efeito do distúrbio  $d_4$ .

<i>Processo</i>	$ARX_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(\hat{w} u)}$	<i>Ordem do modelo N4SID</i>	$Filtro_{(\hat{w} u)}$
I	99,98	[2,2,1]	99,83	[2,2,2,2,1]	99,95	2	99,87
II	99,96	[2,2,1]	99,76	[2,2,2,2,1]	99,91	2	99,85
III	99,92	[3,2,0]	99,24	[2,2,2,3,0]	99,99	3	99,66
IV	99,99	[2,3,0]	99,99	[3,2,2,2,0]	60,42	2	-11,45
V	99,99	[2,3,0]	99,99	[3,2,2,2,0]	97,23	2	99,87
VI	99,97	[3,2,0]	99,99	[2,2,2,3,0]	99,99	4	99,76
VII	99,99	[3,4,0]	99,99	[4,2,2,3,0]	87,04	3	96,02
VIII	99,92	[3,2,0]	99,99	[2,2,2,3,0]	99,99	4	99,73

**Tabela C.21:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal  $y$ , para os processos sob o efeito do distúrbio  $d_5$ .

<i>Processo</i>	$ARX_{(y u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(y u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(y u)}$	<i>Ordem do modelo N4SID</i>
I	100	[2,3,0]	100	[3,2,2,2,0]	-23,54	2
II	100	[2,3,0]	100	[3,2,2,2,0]	-14,95	2
III	100	[3,3,0]	100	[3,2,2,3,0]	93,56	3
IV	100	[2,3,0]	99,99	[3,2,2,2,0]	28,40	2
V	100	[2,3,0]	99,99	[3,2,2,2,0]	-13,55	2
VI	100	[3,3,0]	99,99	[3,2,2,3,0]	97,00,	3
VII	100	[3,6,0]	100	[6,2,2,3,0]	99,97	3
VIII	100	[3,3,0]	100	[3,2,2,3,0]	96,19	3

**Tabela C.22:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal  $\hat{w}$ , para os processos sob o efeito do distúrbio  $d_5$ .

Processo	$ARX_{(\hat{w} u)}$	Ordem dos polinômios [na, nb, nk]	$BJ_{(\hat{w} u)}$	Ordem dos polinômios [nb, nc, nd, nf, nk]	$N4SID_{(\hat{w} u)}$	Ordem do modelo N4SID	Filtro $_{(\hat{w} u)}$
I	99,97	[2,2,1]	99,97	[2,2,2,2,1]	99,90	2	99,89
II	99,95	[2,2,1]	99,90	[2,2,2,2,1]	99,94	2	99,89
III	99,62	[3,2,0]	99,99	[2,2,2,3,0]	99,99	3	99,77
IV	99,99	[2,3,0]	99,99	[3,2,2,2,0]	99,59	2	99,98
V	99,99	[2,3,0]	99,99	[3,2,2,2,0]	99,35	2	99,91
VI	99,93	[3,2,0]	99,99	[2,2,2,3,0]	99,99	4	99,83
VII	99,99	[3,4,0]	99,99	[4,2,2,3,0]	78,98	3	95,96
VIII	99,67	[3,2,0]	99,99	[2,2,2,3,0]	99,99	4	99,79

**Tabela C.23:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal  $y$ , para os processos sob o efeito do distúrbio  $d_6$ .

Processo	$ARX_{(y u)}$	Ordem dos polinômios [na, nb, nk]	$BJ_{(y u)}$	Ordem dos polinômios [nb, nc, nd, nf, nk]	$N4SID_{(y u)}$	Ordem do modelo N4SID
I	100	[2,9,0]	100	[9,2,2,2,0]	5,21	2
II	100	[2,7,0]	100	[7,2,2,2,0]	23,31	2
III	100	[3,3,0]	100	[3,2,2,3,0]	98,92	3
IV	100	[2,3,0]	100	[3,2,2,2,0]	-96,17	2
V	100	[2,3,0]	100	[3,2,2,2,0]	25,49	2
VI	100	[3,3,0]	100	[3,2,2,3,0]	99,20	3
VII	99,96	[3,1,49]	99,99	[1,2,2,3,49]	99,99	3
VIII	100	[3,3,0]	100	[3,2,2,3,0]	98,73	3

**Tabela C.24:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal  $\hat{w}$ , para os processos sob o efeito do distúrbio  $d_6$ .

<i>Processo</i>	$ARX_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(\hat{w} u)}$	<i>Ordem do modelo</i> <i>N4SID</i>	$Filtro_{(\hat{w} u)}$
I	99,99	[2,3,0]	99,99	[3,2,2,2,0]	99,15	3	93,05
II	99,99	[2,3,0]	99,99	[3,2,2,2,0]	91,50	3	56,56
III	99,94	[3,2,0]	99,96	[2,2,2,3,0]	99,99	4	99,37
IV	99,99	[2,3,0]	75,39	[3,2,2,2,0]	92,05	2	99,87
V	99,99	[2,3,0]	99,99	[3,2,2,2,0]	98,09	2	99,88
VI	99,99	[3,3,0]	99,99	[3,2,2,3,0]	99,94	5	61,80
VII	99,99	[3,4,0]	99,99	[4,2,2,3,0]	92,81	3	92,67
VIII	99,95	[3,2,0]	99,99	[2,2,2,3,0]	99,99	4	99,48

**Tabela C.25:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal  $y$ , para os processos sob o efeito do distúrbio  $d_7$ .

<i>Processo</i>	$ARX_{(y u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(y u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(y u)}$	<i>Ordem do modelo</i> <i>N4SID</i>
I	100	[2,3,0]	100	[3,2,2,2,0]	-86,86	2
II	100	[2,3,0]	100	[3,2,2,2,0]	-99,04	2
III	100	[3,3,0]	100	[3,2,2,3,0]	96,57	3
IV	100	[2,3,0]	100	[3,2,2,2,0]	9,37	2
V	100	[2,3,0]	100	[3,2,2,2,0]	-40,95	2
VI	100	[3,3,0]	100	[3,2,2,3,0]	98,56	3
VII	100	[5,4,0]	98,77	[4,2,2,5,0]	99,95	3
VIII	100	[3,3,0]	100	[3,2,2,3,0]	97,71	3

**Tabela C.26:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal  $\hat{w}$ , para os processos sob o efeito do distúrbio  $d_7$ .

<i>Processo</i>	$ARX_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(\hat{w} u)}$	<i>Ordem do modelo</i> <i>N4SID</i>	$Filtro_{(\hat{w} u)}$
I	99,99	[2,3,0]	99,92	[3,2,2,2,0]	94,73	3	84,44
II	99,99	[2,3,0]	99,98	[3,2,2,2,0]	87,52	3	53,20
III	99,99	[3,4,0]	99,99	[4,2,2,3,0]	95,73	3	96,71
IV	99,99	[2,3,0]	99,99	[3,2,2,2,0]	99,45	2	99,95
V	99,99	[2,3,0]	99,99	[3,2,2,2,0]	98,21	2	99,84
VI	99,94	[3,3,0]	99,87	[3,2,2,3,0]	99,76	5	49,36
VII	99,99	[3,4,0]	99,99	[4,2,2,3,0]	79,78	3	87,85
VIII	99,99	[3,4,0]	99,99	[4,2,2,3,0]	-377,86	3	97,08

**Tabela C.27:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal  $y$ , para os processos sob o efeito do distúrbio  $d_8$ .

<i>Processo</i>	$ARX_{(y u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(y u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(y u)}$	<i>Ordem do modelo</i> <i>N4SID</i>
I	100	[2,3,0]	100	[3,2,2,2,0]	-1,78	2
II	100	[2,3,0]	100	[3,2,2,2,0]	-55,50	2
III	100	[3,3,0]	97,84	[3,2,2,3,0]	98,87	3
IV	100	[2,3,0]	100	[3,2,2,2,0]	-28,45	2
V	100	[2,3,0]	100	[3,2,2,2,0]	-11,45	2
VI	100	[3,3,0]	100	[3,2,2,3,0]	99,25	3
VII	99,99	[1,4,4]	99,98	[4,2,2,1,4]	99,97	3
VIII	100	[3,3,0]	100	[3,2,2,3,0]	98,32	3

**Tabela C.28:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP1 utilizando como saída o sinal  $\hat{w}$ , para os processos sob o efeito do distúrbio  $d_8$ .

<i>Processo</i>	$ARX_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(\hat{w} u)}$	<i>Ordem do modelo N4SID</i>	$Filtro_{(\hat{w} u)}$
I	99,99	[2,3,0]	99,99	[3,2,2,2,0]	91,85	3	43,09
II	99,99	[2,3,0]	99,99	[3,2,2,2,1]	83,32	3	12,38
III	99,99	[3,4,0]	98,71	[4,2,2,3,0]	98,14	3	97,94
IV	99,99	[2,3,0]	99,99	[3,2,2,2,0]	98,52	2	99,91
V	99,99	[5,4,0]	91,09	[4,2,2,5,0]	96,01	2	99,77
VI	99,98	[3,3,0]	99,99	[3,2,2,3,1]	99,88	5	13,69
VII	99,99	[3,5,0]	99,99	[5,2,2,3,0]	85,15	3	86,00
VIII	99,99	[4,4,0]	99,99	[4,2,2,4,0]	98,42	3	98,26

**Tabela C.29:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal  $y$ , para os processos sob o efeito do distúrbio  $d_1$ .

<i>Processo</i>	$ARX_{(y u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(y u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(y u)}$	<i>Ordem do modelo N4SID</i>
I	100	[2,3,0]	100	[3,2,2,2,0]	7,81	2
II	100	[2,3,0]	41,29	[3,2,2,2,0]	-135,68	2
III	100	[2,3,0]	99,99	[3,2,2,3,0]	-30,46	3
IV	100	[3,3,0]	100	[3,2,2,2,0]	-259,27	2
V	100	[2,3,0]	95,61	[3,2,2,2,0]	-205,52	2
VI	100	[2,3,0]	85,15	[3,2,2,2,0]	-8,77	2
VII	100	[3,3,0]	99,99	[3,2,2,3,0]	98,26	3
VIII	97,38	[2,8,0]	100	[8,2,2,2,0]	97,84	3

**Tabela C.30:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal  $\hat{w}$ , para os processos sob o efeito do distúrbio  $d_1$ .

<i>Processo</i>	$ARX_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [ <i>na, nb, nk</i> ]	$BJ_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [ <i>nb, nc, nd, nf, nk</i> ]	$N4SID_{(\hat{w} u)}$	<i>Ordem do modelo</i> <i>N4SID</i>	<i>Filtro</i> $_{(\hat{w} u)}$
I	99,98	[2,2,1]	99,99	[2,2,2,2,1]	99,99	2	99,87
II	99,91	[2,2,1]	99,96	[2,2,2,2,1]	99,87	2	99,80
III	99,01	[3,2,0]	99,99	[2,2,2,3,0]	99,99	3	99,50
IV	99,33	[2,2,0]	99,15	[2,2,2,2,0]	99,90	2	99,92
V	99,99	[2,3,0]	99,99	[3,2,2,2,0]	96,14	2	99,78
VI	99,95	[2,2,1]	99,99	[2,2,2,2,1]	99,97	2	99,83
VII	99,99	[3,4,0]	99,99	[4,2,2,3,0]	91,52	3	97,20
VIII	99,46	[2,2,0]	99,99	[2,2,2,2,0]	99,99	3	99,78

**Tabela C.31:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal  $y$ , para os processos sob o efeito do distúrbio  $d_2$ .

<i>Processo</i>	$ARX_{(y u)}$	<i>Ordem dos polinômios</i> [ <i>na, nb, nk</i> ]	$BJ_{(y u)}$	<i>Ordem dos polinômios</i> [ <i>nb, nc, nd, nf, nk</i> ]	$N4SID_{(y u)}$	<i>Ordem do modelo</i> <i>N4SID</i>
I	100	[2,3,0]	100	[3,2,2,2,0]	-214,70	2
II	100	[2,3,0]	100	[3,2,2,2,0]	-101,79	2
III	100	[3,3,0]	99,45	[3,2,2,3,0]	94,73	3
IV	100	[2,3,0]	100	[3,2,2,2,0]	-341,15	2
V	100	[2,3,0]	100	[3,2,2,2,0]	-259,42	2
VI	100	[2,3,0]	100	[3,2,2,2,0]	-47,07	2
VII	100	[3,3,0]	99,99	[3,2,2,3,0]	96,56	3
VIII	98,35	[2,9,0]	100	[9,2,2,2,0]	70,69	3

**Tabela C.32:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal  $\hat{w}$ , para os processos sob o efeito do distúrbio  $d_2$ .

<i>Processo</i>	$ARX_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(\hat{w} u)}$	<i>Ordem do modelo</i> <i>N4SID</i>	$Filtro_{(\hat{w} u)}$
I	99,99	[2,2,1]	99,94	[2,2,2,2,1]	99,99	2	99,93
II	99,97	[2,2,1]	99,90	[2,2,2,2,1]	99,94	2	99,90
III	99,07	[3,2,0]	99,99	[2,2,2,3,0]	99,99	3	99,73
IV	99,54	[2,2,0]	83,63	[2,2,2,2,0]	99,90	2	99,92
V	99,99	[2,3,0]	99,99	[3,2,2,2,0]	97,00	2	99,83
VI	99,97	[2,2,1]	99,97	[2,2,2,2,1]	99,98	2	99,91
VII	99,99	[3,4,0]	99,99	[4,2,2,3,0]	86,85	3	97,98
VIII	99,74	[2,3,1]	99,99	[3,2,2,2,1]	99,99	3	99,89

**Tabela C.33:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal  $y$ , para os processos sob o efeito do distúrbio  $d_3$ .

<i>Processo</i>	$ARX_{(y u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(y u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(y u)}$	<i>Ordem do modelo</i> <i>N4SID</i>
I	100	[2,3,0]	100	[3,2,2,2,0]	3,65	2
II	100	[2,3,0]	80,74	[3,2,2,2,0]	4,05	2
III	100	[3,3,0]	97,41	[3,2,2,3,0]	97,47	3
IV	100	[2,3,0]	100	[3,2,2,2,0]	1,65	2
V	100	[2,3,0]	100	[3,2,2,2,0]	1,34	2
VI	100	[2,3,0]	100	[3,2,2,2,0]	-48,25	2
VII	100	[3,3,0]	100	[3,2,2,3,0]	97,60	3
VIII	99,75	[2,9,0]	100	[9,2,2,2,0]	97,48	3



**Tabela C.34:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal  $\hat{w}$ , para os processos sob o efeito do distúrbio  $d_3$ .

<i>Processo</i>	$ARX_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(\hat{w} u)}$	<i>Ordem do modelo</i> <i>N4SID</i>	$Filtro_{(\hat{w} u)}$
I	99,99	[2,2,1]	99,99	[2,2,2,2,1]	99,99	2	99,94
II	99,97	[2,2,1]	99,74	[2,2,2,2,1]	99,94	2	99,87
III	99,86	[3,2,0]	99,99	[2,2,2,3,0]	99,99	3	99,55
IV	98,60	[2,2,1]	89,71	[2,2,2,2,1]	99,20	2	99,96
V	99,99	[2,3,0]	99,99	[3,2,2,2,0]	98,22	2	99,89
VI	99,98	[2,2,1]	99,97	[2,2,2,2,1]	99,98	2	99,89
VII	99,99	[3,4,0]	99,99	[4,2,2,3,0]	90,43	3	98,51
VIII	99,25	[3,2,0]	99,99	[2,2,2,3,0]	99,99	4	99,61

**Tabela C.35:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal  $y$ , para os processos sob o efeito do distúrbio  $d_4$ .

<i>Processo</i>	$ARX_{(y u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(y u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(y u)}$	<i>Ordem do modelo</i> <i>N4SID</i>
I	100	[2,3,0]	100	[3,2,2,2,0]	4,63	2
II	100	[2,3,0]	100	[3,2,2,2,0]	0,81	2
III	100	[3,3,0]	100	[3,2,2,3,0]	97,68	3
IV	100	[2,3,0]	100	[3,2,2,2,0]	-20,68	2
V	100	[2,3,0]	100	[3,2,2,2,0]	-31,07	2
VI	100	[2,3,0]	100	[3,2,2,2,0]	-12,43	2
VII	100	[3,3,0]	100	[3,2,2,3,0]	95,33	2
VIII	99,81	[2,10,0]	100	[10,2,2,2,0]	95,50	3

**Tabela C.36:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal  $\hat{w}$ , para os processos sob o efeito do distúrbio  $d_4$ .

<i>Processo</i>	$ARX_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(\hat{w} u)}$	<i>Ordem do modelo</i> <i>N4SID</i>	$Filtro_{(\hat{w} u)}$
I	99,99	[2,2,1]	99,99	[2,2,2,2,1]	99,99	2	99,94
II	99,98	[2,2,1]	99,74	[2,2,2,2,1]	99,97	2	99,87
III	99,79	[3,2,0]	99,99	[2,2,2,3,0]	99,99	3	99,61
IV	99,70	[2,2,3]	91,50	[2,2,2,2,3]	97,73	2	99,96
V	99,99	[2,3,0]	99,99	[3,2,2,2,0]	97,52	2	99,88
VI	99,98	[2,2,1]	98,32	[2,2,2,2,1]	99,98	2	99,91
VII	99,99	[3,4,0]	99,99	[4,2,2,3,0]	94,06	3	98,74
VIII	99,96	[2,3,2]	99,89	[3,2,2,2,2]	99,99	3	99,83

**Tabela C.37:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal  $y$ , para os processos sob o efeito do distúrbio  $d_5$ .

<i>Processo</i>	$ARX_{(y u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(y u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(y u)}$	<i>Ordem do modelo</i> <i>N4SID</i>
I	100	[2,3,0]	100	[3,2,2,2,0]	-63,10	2
II	100	[2,3,0]	100	[3,2,2,2,0]	-25,39	2
III	100	[3,3,0]	100	[3,2,2,3,0]	95,08	3
IV	100	[2,3,0]	99,99	[3,2,2,2,0]	-39,95	2
V	100	[2,3,0]	100	[3,2,2,2,0]	-207,42	2
VI	100	[2,3,0]	100	[3,2,2,2,0]	-56,11	2
VII	100	[3,3,0]	99,99	[3,2,2,3,0]	96,19	3
VIII	99,61	[2,10,0]	93,47	[10,2,2,2,0]	94,754	3

**Tabela C.38:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal  $\hat{w}$ , para os processos sob o efeito do distúrbio  $d_5$ .

<i>Processo</i>	$ARX_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(\hat{w} u)}$	<i>Ordem do modelo</i> <i>N4SID</i>	<i>Filtro</i> $_{(\hat{w} u)}$
I	99,99	[2,2,1]	99,97	[2,2,2,2,1]	99,98	2	99,92
II	99,96	[2,2,1]	99,83	[2,2,2,2,1]	99,96	2	99,88
III	99,03	[3,2,0]	99,35	[2,2,2,3,0]	99,99	3	99,67
IV	99,49	[2,2,0]	92,88	[2,2,2,2,0]	99,96	2	99,92
V	99,99	[2,3,0]	99,99	[3,2,2,2,0]	99,57	2	99,88
VI	99,96	[2,2,1]	96,93	[2,2,2,2,1]	99,98	2	99,90
VII	100	[3,4,0]	100	[4,2,2,3,0]	90,35	3	98,14
VIII	99,87	[2,3,2]	99,86	[3,2,2,2,0]	99,99	3	99,87

**Tabela C.39:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal  $y$ , para os processos sob o efeito do distúrbio  $d_6$ .

<i>Processo</i>	$ARX_{(y u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(y u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(y u)}$	<i>Ordem do modelo</i> <i>N4SID</i>
I	100	[2,3,0]	100	[3,2,2,2,0]	-52,38	2
II	100	[2,3,0]	100	[3,2,2,2,0]	19,46	2
III	100	[3,3,0]	100	[3,2,2,3,0]	98,46	3
IV	100	[2,3,0]	100	[3,2,2,2,0]	0,94	2
V	100	[2,3,0]	100	[3,2,2,2,0]	32,17	2
VI	100	[2,3,0]	100	[3,2,2,2,0]	-43,25	2
VII	100	[3,3,0]	100	[3,2,2,3,0]	99,24	3
VIII	100	[3,3,0]	100	[3,2,2,3,0]	89,81	3

**Tabela C.40:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal  $\hat{w}$ , para os processos sob o efeito do distúrbio  $d_6$ .

<i>Processo</i>	$ARX_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(\hat{w} u)}$	<i>Ordem do modelo N4SID</i>	$Filtro_{(\hat{w} u)}$
I	99,99	[2,2,1]	99,97	[2,2,2,2,1]	99,98	2	99,91
II	99,97	[2,2,1]	99,81	[2,2,2,2,1]	99,93	2	99,80
III	99,83	[3,2,0]	98,98	[2,2,2,3,0]	99,59	4	99,20
IV	99,55	[2,2,0]	81,24	[2,2,2,2,2]	98,68	2	99,93
V	100	[4,5,0]	99,99	[5,2,2,4,0]	98,24	2	99,88
VI	99,97	[2,2,1]	99,86	[2,2,2,2,1]	99,95	2	99,84
VII	100	[3,4,0]	99,99	[4,2,2,3,0]	96,24	3	97,95
VIII	99,98	[2,4,1]	99,99	[4,2,2,2,1]	99,99	3	99,69

**Tabela C.41:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal  $y$ , para os processos sob o efeito do distúrbio  $d_7$ .

<i>Processo</i>	$ARX_{(y u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(y u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(y u)}$	<i>Ordem do modelo N4SID</i>
I	100	[2,3,0]	100	[3,2,2,2,0]	-246,68	2
II	100	[2,3,0]	100	[3,2,2,2,0]	-242,67	2
III	100	[3,3,0]	100	[3,2,2,3,0]	97,20	3
IV	100	[2,3,0]	99,99	[3,2,2,2,0]	-70,13	2
V	100	[2,3,0]	100	[3,2,2,2,0]	-45,20	2
VI	100	[2,3,0]	100	[3,2,2,2,0]	-11,00	2
VII	100	[3,3,0]	99,99	[3,2,2,3,0]	97,83	3
VIII	100	[3,3,0]	100	[3,2,2,3,0]	97,00	3

**Tabela C.42:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal  $\hat{w}$ , para os processos sob o efeito do distúrbio  $d_7$ .

<i>Processo</i>	$ARX_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, n]	$N4SID_{(\hat{w} u)}$	<i>Ordem do modelo N4SID</i>	$Filtro_{(\hat{w} u)}$
I	99,95	[2,2,1]	99,99	[2,2,2,2,1]	99,98	3	99,72
II	99,87	[2,2,1]	99,99	[2,2,2,2,1]	99,70	2	99,68
III	98,32	[3,2,0]	99,99	[2,2,2,3,0]	99,99	4	99,20
IV	98,24	[2,2,0]	99,99	[2,2,2,2,0]	99,94	2	99,93
V	99,99	[2,3,0]	99,99	[3,2,2,2,0]	97,42	2	99,83
VI	99,99	[2,3,0]	99,99	[3,2,2,2,0]	99,92	2	99,70
VII	99,99	[3,4,0]	99,99	[3,2,2,2,0]	92,35	3	95,81
VIII	99,91	[2,5,1]	99,94	[5,2,2,2,1]	99,99	4	99,71

**Tabela C.43:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal  $y$ , para os processos sob o efeito do distúrbio  $d_8$ .

<i>Processo</i>	$ARX_{(y u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(y u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(y u)}$	<i>Ordem do modelo N4SID</i>
I	100	[2,3,0]	100	[3,2,2,2,0]	-51,60	2
II	100	[2,3,0]	100	[3,2,2,2,0]	-12,63	2
III	100	[3,3,0]	100	[3,2,2,3,0]	98,49	3
IV	100	[2,3,0]	100	[3,2,2,2,0]	-58,65	2
V	100	[8,10,0]	100	[10,2,2,8,0]	-70,62	2
VI	100	[2,3,0]	100	[3,2,2,2,0]	-3,10	2
VII	100	[3,3,0]	100	[3,2,2,3,0]	99,12	3
VIII	100	[3,3,0]	100	[3,2,2,3,0]	98,51	3

**Tabela C.44:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP2 utilizando como saída o sinal  $\hat{w}$ , para os processos sob o efeito do distúrbio  $d_8$ .

Processo	$ARX_{(\hat{w} u)}$	Ordem dos polinômios [na, nb, nk]	$BJ_{(\hat{w} u)}$	Ordem dos polinômios [nb, nc, nd, nf, nk]	$N4SID_{(\hat{w} u)}$	Ordem do modelo N4SID	Filtro $_{(\hat{w} u)}$
I	100	[2,3,0]	100	[3,2,2,2,0]	99,99	3	99,81
II	100	[2,3,0]	100	[3,2,2,2,0]	99,82	2	99,65
III	99,96	[3,2,1]	99,99	[2,2,2,3,1]	99,99	4	98,53
IV	98,91	[2,2,2]	79,39	[2,2,2,2,2]	98,67	2	99,93
V	100	[2,6,0]	100	[6,2,2,2,0]	95,35	2	99,82
VI	100	[2,3,0]	100	[3,2,2,2,0]	99,87	2	99,71
VII	100	[3,4,0]	100	[4,2,2,3,0]	95,62	3	96,12
VIII	99,97	[2,6,0]	99,94	[6,2,2,2,0]	99,99	3	99,50

**Tabela C.45:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal  $y$ , para os processos sob o efeito do distúrbio  $d_1$ .

Processo	$ARX_{(y u)}$	Ordem dos polinômios [na, nb, nk]	$BJ_{(y u)}$	Ordem dos polinômios [nb, nc, nd, nf, nk]	$N4SID_{(y u)}$	Ordem do modelo N4SID
I	100	[2,3,0]	100	[3,2,2,2,0]	-155,62	2
II	100	[2,3,0]	100	[3,2,2,2,0]	-127,8	2
III	100	[3,3,0]	100	[3,2,2,2,0]	98,19	3
IV	100	[2,3,0]	100	[3,2,2,2,0]	-124,17	2
V	100	[2,3,0]	100	[3,2,2,2,0]	-158,57	2
VI	100	[2,3,0]	100	[3,2,2,2,0]	0,22	2
VII	100	[2,3,0]	99,99	[3,2,2,2,0]	-180,8	2
VIII	100	[3,3,0]	100	[3,2,2,3,0]	97,37	3

**Tabela C.46:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal  $\hat{w}$ , para os processos sob o efeito do distúrbio  $d_1$ .

<i>Processo</i>	$ARX_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(\hat{w} u)}$	<i>Ordem do modelo</i> <i>N4SID</i>	<i>Filtro</i> $_{(\hat{w} u)}$
I	99,95	[2,2,1]	98,65	[2,2,2,2,1]	99,96	2	99,83
II	99,87	[2,2,1]	98,37	[2,2,2,2,1]	99,92	2	99,80
III	96,29	[3,2,0]	99,99	[2,2,2,3,0]	99,99	3	99,15
IV	99,80	[2,2,0]	99,45	[2,2,2,2,0]	99,90	2	99,90
V	99,83	[2,3,0]	99,99	[3,2,2,2,0]	99,96	2	99,84
VI	99,92	[2,2,1]	99,94	[2,2,2,2,1]	99,94	2	99,81
VII	100	[2,3,0]	100	[3,2,2,2,0]	99,72	2	99,72
VIII	99,25	[3,2,0]	99,99	[2,2,2,3,0]	99,99	4	99,61

**Tabela C.47:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal  $y$ , para os processos sob o efeito do distúrbio  $d_2$ .

<i>Processo</i>	$ARX_{(y u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(y u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(y u)}$	<i>Ordem do modelo</i> <i>N4SID</i>
I	100	[2,3,0]	100	[3,2,2,2,0]	-51,71	2
II	100	[2,3,0]	89,06	[3,2,2,2,0]	-145,66	2
III	100	[3,3,0]	100	[3,2,2,2,0]	96,48	3
IV	100	[2,3,0]	99,99	[3,2,2,2,0]	-248,23	2
V	100	[2,3,0]	100	[3,2,2,2,0]	-309,02	2
VI	100	[2,3,0]	100	[3,2,2,2,0]	-82,70	2
VII	100	[2,3,0]	100	[3,2,2,2,0]	-246,54	2
VIII	100	[3,3,0]	99,99	[3,2,2,3,0]	94,65	3

**Tabela C.48:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal  $\hat{w}$ , para os processos sob o efeito do distúrbio  $d_2$ .

<i>Processo</i>	$ARX_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(\hat{w} u)}$	<i>Ordem do modelo N4SID</i>	$Filtro_{(\hat{w} u)}$
I	99,97	[2,2,1]	99,97	[2,2,2,2,1]	99,97	2	99,91
II	99,96	[2,2,1]	99,77	[2,2,2,2,1]	99,95	2	99,90
III	97,24	[3,2,0]	99,99	[2,2,2,3,0]	99,99	3	99,64
IV	99,77	[2,2,0]	90,86	[2,2,2,2,0]	99,88	2	99,91
V	99,99	[2,3,0]	99,99	[3,2,2,2,0]	96,66	2	99,86
VI	99,97	[2,2,1]	99,91	[2,2,2,2,1]	99,96	2	99,91
VII	99,99	[2,3,0]	99,99	[3,2,2,2,0]	98,18	2	99,80
VIII	99,25	[3,2,0]	98,04	[2,2,2,3,0]	99,99	4	99,78

**Tabela C.49:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal  $y$ , para os processos sob o efeito do distúrbio  $d_3$ .

<i>Processo</i>	$ARX_{(y u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(y u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(y u)}$	<i>Ordem do modelo N4SID</i>
I	100	[2,3,0]	100	[3,2,2,2,0]	-3,49	2
II	100	[2,3,0]	89,06	[3,2,2,2,0]	25,41	2
III	100	[3,3,0]	100	[3,2,2,2,0]	97,75	3
IV	100	[2,3,0]	100	[3,2,2,2,0]	32,77	2
V	100	[2,3,0]	100	[3,2,2,2,0]	9,26	2
VI	100	[2,3,0]	100	[3,2,2,2,0]	-29,37	2
VII	100	[2,3,0]	100	[3,2,2,2,0]	-50,53	2
VIII	100	[3,3,0]	100	[3,2,2,3,0]	97,39	3



**Tabela C.50:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal  $\hat{w}$ , para os processos sob o efeito do distúrbio  $d_3$ .

<i>Processo</i>	$ARX_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [ <i>na, nb, nk</i> ]	$BJ_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [ <i>nb, nc, nd, nf, nk</i> ]	$N4SID_{(\hat{w} u)}$	<i>Ordem do modelo</i> <i>N4SID</i>	$Filtro_{(\hat{w} u)}$
I	99,98	[2,2,1]	97,51	[2,2,2,2,1]	99,97	2	99,88
II	99,96	[2,2,1]	99,92	[2,2,2,2,1]	99,95	2	99,85
III	99,88	[3,2,0]	96,33	[2,2,2,3,0]	99,98	3	97,69
IV	99,73	[2,2,0]	99,99	[2,2,2,2,0]	99,94	2	99,86
V	99,99	[2,3,0]	99,99	[3,2,2,2,0]	98,75	2	99,932
VI	99,97	[2,2,1]	98,13	[2,2,2,2,1]	99,96	2	99,87
VII	99,99	[2,3,0]	99,99	[3,2,2,2,0]	97,60	2	99,84
VIII	99,90	[3,2,0]	99,99	[2,2,2,3,0]	99,99	4	99,65

**Tabela C.51:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal  $y$ , para os processos sob o efeito do distúrbio  $d_4$ .

<i>Processo</i>	$ARX_{(y u)}$	<i>Ordem dos polinômios</i> [ <i>na, nb, nk</i> ]	$BJ_{(y u)}$	<i>Ordem dos polinômios</i> [ <i>nb, nc, nd, nf, nk</i> ]	$N4SID_{(y u)}$	<i>Ordem do modelo</i> <i>N4SID</i>
I	100	[2,3,0]	100	[3,2,2,2,0]	5,46	2
II	100	[2,3,0]	86,37	[3,2,2,2,0]	6,33	2
III	100	[3,3,0]	100	[3,2,2,3,0]	97,25	3
IV	100	[2,3,0]	100	[3,2,2,2,0]	-25,53	2
V	100	[2,5,0]	100	[5,2,2,2,0]	-69,03	2
VI	100	[2,3,0]	100	[3,2,2,2,0]	-14,63	2
VII	100	[2,3,0]	99,99	[3,2,2,2,0]	-13,12	2
VIII	100	[3,3,0]	100	[3,2,2,3,0]	97,66	3

**Tabela C.52:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal  $\hat{w}$ , para os processos sob o efeito do distúrbio  $d_4$ .

<i>Processo</i>	$ARX_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(\hat{w} u)}$	<i>Ordem do modelo N4SID</i>	$Filtro_{(\hat{w} u)}$
I	99,98	[2,2,1]	99,87	[2,2,2,2,1]	99,97	2	99,90
II	99,97	[2,2,1]	99,83	[2,2,2,2,1]	99,96	2	99,87
III	99,85	[3,2,0]	90,43	[2,2,2,3,0]	99,95	3	97,75
IV	99,93	[2,2,0]	99,99	[2,2,2,2,0]	99,87	2	99,86
V	99,99	[2,3,0]	99,99	[3,2,2,2,0]	97,10	2	99,91
VI	99,98	[2,2,1]	99,99	[2,2,2,2,1]	99,97	2	99,89
VII	99,99	[2,3,0]	99,99	[3,2,2,2,0]	98,60	2	99,83
VIII	99,96	[3,2,1]	99,99	[2,2,2,3,1]	99,99	4	99,69

**Tabela C.53:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal  $y$ , para os processos sob o efeito do distúrbio  $d_5$ .

<i>Processo</i>	$ARX_{(y u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(y u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(y u)}$	<i>Ordem do modelo N4SID</i>
I	100	[2,3,0]	100	[3,2,2,2,0]	-42,00	2
II	100	[2,3,0]	93,04	[3,2,2,2,0]	-25,58	2
III	100	[3,3,0]	100	[3,2,2,3,0]	95,93	3
IV	100	[2,3,0]	100	[3,2,2,2,0]	-13,67	2
V	100	[2,3,0]	100	[3,2,2,2,0]	-28,45	2
VI	100	[2,3,0]	100	[3,2,2,2,0]	-97,37	2
VII	100	[2,3,0]	99,99	[3,2,2,2,0]	-23,76	2
VIII	100	[3,3,0]	100	[3,2,2,3,0]	95,78	3

**Tabela C.54:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal  $\hat{w}$ , para os processos sob o efeito do distúrbio  $d_5$ .

<i>Processo</i>	$ARX_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(\hat{w} u)}$	<i>Ordem do modelo N4SID</i>	$Filtro_{(\hat{w} u)}$
I	99,97	[2,2,1]	97,98	[2,2,2,2,1]	99,97	2	99,90
II	99,94	[2,2,1]	99,83	[2,2,2,2,1]	99,96	2	99,89
III	97,60	[3,2,0]	94,96	[2,2,2,3,0]	99,99	3	99,41
IV	99,73	[2,2,0]	95,05	[2,2,2,2,0]	99,97	2	99,91
V	99,99	[2,3,0]	99,99	[3,2,2,2,0]	99,20	2	99,93
VI	99,96	[2,2,1]	97,56	[2,2,2,2,1]	99,96	2	99,89
VII	99,99	[2,3,0]	99,99	[3,2,2,2,0]	99,07	2	99,83
VIII	99,84	[3,2,1]	99,99	[2,2,2,3,1]	99,99	4	99,72

**Tabela C.55:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal  $y$ , para os processos sob o efeito do distúrbio  $d_6$ .

<i>Processo</i>	$ARX_{(y u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(y u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(y u)}$	<i>Ordem do modelo N4SID</i>
I	100	[2,3,0]	100	[3,2,2,2,0]	5,98	2
II	100	[2,3,0]	100	[3,2,2,2,0]	23,98	2
III	100	[3,3,0]	100	[3,2,2,2,0]	99,12	3
IV	100	[2,3,0]	100	[3,2,2,2,0]	5,45	2
V	100	[2,3,0]	100	[3,2,2,2,0]	28,35	2
VI	100	[2,3,0]	100	[3,2,2,2,0]	5,16	2
VII	100	[2,3,0]	99,99	[3,2,2,2,0]	18,45	2
VIII	100	[3,3,0]	100	[3,2,2,3,0]	98,38	3

**Tabela C.56:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal  $\hat{w}$ , para os processos sob o efeito do distúrbio  $d_6$ .

<i>Processo</i>	$ARX_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(\hat{w} u)}$	<i>Ordem do modelo N4SID</i>	$Filtro_{(\hat{w} u)}$
I	99,97	[2,2,1]	99,91	[2,2,2,2,1]	99,93	2	99,82
II	99,95	[2,2,1]	73,26	[2,2,2,2,1]	99,92	2	99,78
III	99,74	[3,2,0]	14,58	[2,2,2,3,0]	99,93	3	95,96
IV	99,99	[2,2,0]	95,83	[2,2,2,2,0]	92,30	2	91,85
V	99,99	[2,3,0]	80,09	[3,2,2,2,0]	98,22	2	99,94
VI	99,96	[2,2,1]	99,71	[2,2,2,2,1]	99,91	2	99,81
VII	99,99	[2,3,0]	99,99	[3,2,2,2,0]	98,54	2	99,79
VIII	99,97	[3,2,0]	99,99	[2,2,2,3,0]	99,99	4	99,37

**Tabela C.57:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal  $y$ , para os processos sob o efeito do distúrbio  $d_7$ .

<i>Processo</i>	$ARX_{(y u)}$	<i>Ordem dos polinômios</i> [na, nb, nk]	$BJ_{(y u)}$	<i>Ordem dos polinômios</i> [nb, nc, nd, nf, nk]	$N4SID_{(y u)}$	<i>Ordem do modelo N4SID</i>
I	100	[2,3,0]	100	[3,2,2,2,0]	-88,14	2
II	100	[2,3,0]	100	[3,2,2,2,0]	-20,77	2
III	100	[3,3,0]	100	[3,2,2,2,0]	97,93	3
IV	100	[2,3,0]	100	[3,2,2,2,0]	-54,74	2
V	100	[2,3,0]	100	[3,2,2,2,0]	-472,76	2
VI	100	[2,3,0]	100	[3,2,2,2,0]	-11,86	2
VII	100	[2,3,0]	99,99	[3,2,2,2,0]	-32,25	2
VIII	100	[3,3,0]	100	[3,2,2,3,0]	97,28	3

**Tabela C.58:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal  $\hat{w}$ , para os processos sob o efeito do distúrbio  $d_7$ .

<i>Processo</i>	$ARX_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [ <i>na, nb, nk</i> ]	$BJ_{(\hat{w} u)}$	<i>Ordem dos polinômios</i> [ <i>nb, nc, nd, nf, nk</i> ]	$N4SID_{(\hat{w} u)}$	<i>Ordem do modelo</i> <i>N4SID</i>	<i>Filtro</i> $_{(\hat{w} u)}$
I	99,87	[2,2,1]	99,98	[2,2,2,2,1]	99,70	2	99,71
II	99,83	[2,2,1]	97,04	[2,2,2,2,1]	99,84	2	99,73
III	88,92	[3,2,0]	99,99	[2,2,2,3,0]	99,91	3	98,32
IV	99,02	[2,2,0]	99,99	[2,2,2,2,0]	99,93	2	99,90
V	99,99	[2,3,0]	99,99	[3,2,2,2,0]	94,31	2	99,88
VI	99,83	[2,2,1]	99,99	[2,2,2,2,1]	99,64	2	99,70
VII	99,99	[2,3,0]	99,99	[3,2,2,2,0]	96,65	2	99,77
VIII	99,82	[3,2,1]	99,99	[2,2,2,3,1]	99,98	4	99,37

**Tabela C.59:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal  $y$ , para os processos sob o efeito do distúrbio  $d_8$ .

<i>Processo</i>	$ARX_{(y u)}$	<i>Ordem dos polinômios</i> [ <i>na, nb, nk</i> ]	$BJ_{(y u)}$	<i>Ordem dos polinômios</i> [ <i>nb, nc, nd, nf, nk</i> ]	$N4SID_{(y u)}$	<i>Ordem do modelo</i> <i>N4SID</i>
I	100	[2,3,0]	100	[3,2,2,2,0]	-1,18	2
II	100	[2,3,0]	100	[3,2,2,2,0]	-18,44	2
III	100	[3,3,0]	100	[3,2,2,3,0]	99,14	3
IV	100	[2,3,0]	100	[3,2,2,2,0]	-95,39	2
V	100	[2,4,0]	100	[4,2,2,2,0]	-109,36	2
VI	100	[2,3,0]	100	[3,2,2,2,0]	-58,47	2
VII	100	[2,3,0]	99,99	[3,2,2,2,0]	-10,72	2
VIII	100	[3,3,0]	100	[3,2,2,3,0]	98,494	3

**Tabela C.60:** Índice *Fit* e ordens dos polinômios das estruturas para os modelos identificados na condição OP3 utilizando como saída o sinal  $\hat{w}$ , para os processos sob o efeito do distúrbio  $d_8$ .

Processo	ARX <sub>(<math>\hat{w} u</math>)</sub>	Ordem dos polinômios [na, nb, nk]	BJ <sub>(<math>\hat{w} u</math>)</sub>	Ordem dos polinômios [nb, nc, nd, nf, nk]	N4SID <sub>(<math>\hat{w} u</math>)</sub>	Ordem do	Filtro <sub>(<math>\hat{w} u</math>)</sub>
						modelo	
I	99,99	[2,3,0]	99,99	[3,2,2,2,0]	99,79	2	99,68
II	99,99	[2,3,0]	99,99	[3,2,2,2,0]	99,71	2	99,66
III	99,68	[3,2,0]	99,06	[2,2,2,3,0]	99,95	3	96,74
IV	99,17	[2,2,0]	87,12	[2,2,2,2,0]	99,88	2	99,89
V	99,99	[2,4,0]	99,99	[4,2,2,2,0]	95,78	2	99,85
VI	99,99	[2,3,0]	99,99	[3,2,2,2,0]	99,74	2	99,66
VII	99,99	[2,3,0]	99,99	[3,2,2,2,0]	94,72	2	99,77
VIII	99,99	[3,4,0]	99,99	[4,2,2,3,0]	99,99	4	98,85

**C.1.4** Valores do índice *Fit* para as estruturas ARX, Box-Jenkins, N4SID e Filtros identificados através de dados com perturbação

**Tabela C.61:** Índice *Fit* para cada um dos modelos identificados, no ponto de operação OP1 sob o efeito de  $d_1$ ,  $d_2$ ,  $d_3$  e  $d_4$ .

	$d_1$			$d_2$			$d_3$			$d_4$		
	ARX	BJ	N4SID	ARX	BJ	N4SID	ARX	BJ	N4SID	ARX	BJ	N4SID
I	92,0	93,81	91,60	89,38	88,40	83,71	80,77	81,64	81,24	44,81	47,22	40,70
II	91,15	94,08	91,12	85,11	87,68	84,79	82,90	83,56	82,65	67,53	44,43	61,47
III	89,59	90,93	89,65	82,10	86,53	82,12	80,35	80,40	79,88	62,51	69,71	43,44
IV	86,89	91,43	84,57	82,06	86,99	75,61	76,72	73,51	63,47	38,94	75,61	59,31
V	99,02	99,15	66,45	98,24	98,51	61,73	97,90	97,96	76,55	94,25	95,15	74,53
VI	92,89	92,77	89,62	90,54	86,95	83,21	83,17	83,42	82,49	50,27	40,51	55,82
VII	95,83	97,29	60,53	93,50	94,79	51,21	90,63	92,26	69,52	76,76	77,14	74,68
VIII	89,93	92,25	79,59	82,96	86,27	73,65	81,23	81,29	74,24	60,76	38,52	47,02

**Tabela C.62:** Índice *Fit* para cada um dos modelos identificados, no ponto de operação OP1 sob o efeito de  $d_5$ ,  $d_6$ ,  $d_7$  e  $d_8$ .

	$d_5$			$d_6$			$d_7$			$d_8$		
	ARX	BJ	N4SID	ARX	BJ	N4SID	ARX	BJ	N4SID	ARX	BJ	N4SID
I	76,24	77,28	76,48	74,82	61,41	73,54	80,43	80,82	81,20	38,78	45,08	41,38
II	78,14	78,34	78,39	69,00	69,69	67,59	83,08	83,65	83,09	51,15	51,24	50,80
III	74,87	75,53	74,90	59,99	57,34	62,28	81,45	81,17	81,55	26,78	27,97	54,77
IV	73,36	66,99	62,46	66,13	77,65	33,93	70,11	39,91	73,20	39,14	41,98	24,00
V	97,09	97,14	77,79	96,82	96,64	82,15	97,61	97,82	58,86	90,94	90,64	85,58
VI	79,07	78,55	76,79	77,63	66,27	66,65	81,96	82,59	81,68	34,93	54,38	50,65
VII	89,85	89,63	-20,12	88,75	90,72	-795,6	92,15	92,85	51,15	73,74	73,98	70,06
VIII	76,29	49,12	68,21	60,06	61,03	58,92	82,04	81,53	74,69	-0,86	35,91	35,88

**Tabela C.63:** Índice *Fit* para cada um dos modelos identificados, no ponto de operação OP2 sob o efeito de  $d_1$ ,  $d_2$ ,  $d_3$  e  $d_4$ .

	$d_1$			$d_2$			$d_3$			$d_4$		
	ARX	BJ	N4SID	ARX	BJ	N4SID	ARX	BJ	N4SID	ARX	BJ	N4SID
I	73,77	71,13	72,81	65,08	47,94	51,77	35,75	19,24	31,78	-55,46	-69,05	-87,39
II	87,32	91,07	87,25	78,37	83,04	78,44	75,84	77,24	75,56	59,25	66,44	50,56
III	82,24	84,08	82,36	69,21	70,08	69,45	67,03	66,15	66,15	51,12	38,97	0,38
IV	82,76	86,56	81,23	76,93	78,50	69,33	62,97	43,65	59,75	29,30	24,70	53,09
V	98,78	99,05	66,75	97,69	98,82	68,37	97,44	96,96	70,18	92,06	92,63	58,48
VI	82,19	82,05	72,61	73,38	68,55	56,17	55,66	58,95	48,68	-16,12	-9,88	13,93
VII	94,81	96,73	66,58	91,89	93,36	66,14	87,90	90,24	-23410	76,86	70,90	42,96
VIII	80,51	84,29	65,28	68,12	74,30	52,31	64,86	66,47	47,87	29,67	1,50	17,03

**Tabela C.64:** Índice *Fit* para cada um dos modelos identificados, no ponto de operação OP2 sob o efeito de  $d_5$ ,  $d_6$ ,  $d_7$  e  $d_8$ .

	$d_5$			$d_6$			$d_7$			$d_8$		
	ARX	BJ	N4SID	ARX	BJ	N4SID	ARX	BJ	N4SID	ARX	BJ	N4SID
I	32,79	27,03	34,96	-49,3	-182	-52,81	9,13	40,52	20,20	-5,80	-25231	-1,00
II	69,72	68,08	70,12	53,23	53,34	52,12	76,62	77,41	76,68	24,14	47,39	27,96
III	57,99	58,34	57,07	46,40	22,01	15,62	67,30	66,71	67,98	-1,33	-77,46	44,59
IV	60,06	54,98	53,00	38,80	40,29	34,25	62,92	64,73	62,86	13,77	36,27	22,93
V	96,33	96,35	71,88	96,22	96,14	75,38	97,15	97,65	53,64	89,00	89,80	81,69
VI	51,97	51,23	38,77	15,22	7,87	28,90	50,86	59,55	51,61	20,95	-34,37	11,13
VII	87,39	86,18	-7174	79,44	82,69	-18111	89,62	90,88	50,94	63,13	62,53	56,23
VIII	56,52	66,74	38,04	33,67	30,72	32,20	64,15	60,62	54,55	-99,51	-43,39	11,26

**Tabela C.65:** Índice *Fit* para cada um dos modelos identificados, no ponto de operação OP3 sob o efeito de  $d_1$ ,  $d_2$ ,  $d_3$  e  $d_4$ .

	$d_1$			$d_2$			$d_3$			$d_4$		
	ARX	BJ	N4SID	ARX	BJ	N4SID	ARX	BJ	N4SID	ARX	BJ	N4SID
I	87,87	87,05	87,32	83,41	82,89	75,22	69,81	45,23	69,65	19,25	24,99	2,77
II	87,52	91,57	87,48	78,80	82,51	78,89	76,07	76,31	75,91	59,06	62,92	50,41
III	84,72	89,28	84,29	72,92	75,85	73,14	70,14	72,40	71,98	52,89	16,27	20,71
IV	86,66	89,93	85,24	82,06	86,89	75,24	72,01	57,07	65,34	39,83	19,04	58,44
V	98,85	98,94	68,11	97,86	98,50	70,49	97,46	97,17	71,99	93,07	91,04	63,78
VI	89,25	89,46	83,70	85,33	80,57	74,05	73,75	75,46	71,25	27,21	29,17	37,61
VII	95,58	97,18	72,58	93,03	94,51	72,50	89,32	91,55	76,28	79,57	76,46	68,69
VIII	86,45	88,08	73,30	77,28	82,43	64,77	75,11	75,11	62,70	49,27	23,74	34,62

**Tabela C.66:** Índice *Fit* para cada um dos modelos identificados, no ponto de operação OP3 sob o efeito de  $d_5$ ,  $d_6$ ,  $d_7$  e  $d_8$ .

	$d_5$			$d_6$			$d_7$			$d_8$		
	ARX	BJ	N4SID	ARX	BJ	N4SID	ARX	BJ	N4SID	ARX	BJ	N4SID
I	64,44	68,53	64,88	54,50	49,44	47,18	69,91	70,05	70,60	36,91	13,71	46,68
II	69,95	70,41	70,44	53,37	54,36	52,21	76,58	77,58	76,63	28,66	28,68	28,55
III	62,13	60,62	62,11	44,39	40,77	47,38	71,75	70,93	71,81	2,73	-12,12	39,56
IV	67,51	62,08	59,15	61,75	77,90	44,72	69,63	71,47	68,85	34,03	33,70	7,24
V	96,48	96,54	74,64	96,08	96,29	78,40	97,18	97,32	51,42	89,18	87,39	-27774
VI	69,02	71,40	63,50	58,89	47,99	50,46	72,30	72,51	70,56	35,90	6,69	29,34
VII	89,06	89,15	76,67	83,96	84,11	-328,1	91,23	92,27	53,85	70,80	72,51	64,73
VIII	68,81	67,44	55,82	52,73	52,14	47,26	75,48	74,12	67,21	-20,62	6,65	29,78

**C.1.5** Valores estimados para a alteração de variabilidades dos sistemas comparados a real alteração de variabilidade

**Tabela C.67:** Percentual de máxima redução de variabilidade estimados comparados a índice de Harris e Alteração real para os processos no ponto de operação OP1 sob os efeitos dos *DNMs*  $d_1$  e  $d_2$ .

Processo	VRE1(%)		VRE2(%)		Harris(%)		Alteração real(%)	
	$d_1$	$d_2$	$d_1$	$d_2$	$d_1$	$d_2$	$d_1$	$d_2$
I	-99,61	-99,62	-99,60	-99,39	-100	-100	-99,63	-99,43
II	-88,29	-96,86	-94,78	-94,53	-100	-100	-96,12	-95,25
III	-76,25	-73,63	-69,03	-59,12	-100	-100	-75,72	-62,01
IV	-53,87	-51,60	-65,30	-80,96	-100	-100	-58,05	-77,02
V	-96,07	-97,26	-84,86	-93,27	-99,97	-99,78	-77,64	-87,73
VI	-89,13	-92,33	-90,30	-88,03	-100	-100	-91,80	-89,49
VII	-67,76	-74,50	-79,77	-89,56	-99,97	-99,21	-67,06	-72,91
VIII	-50,45	-47,77	-35,72	-35,50	-99,99	-100	-48,67	-45,44

**Tabela C.68:** Percentual de máxima redução de variabilidade estimados comparados a índice de Harris e Alteração real para os processos no ponto de operação OP1 sob os efeitos dos *DNMs*  $d_3$  e  $d_4$ .

Processo	VRE1(%)		VRE2(%)		Harris(%)		Alteração real(%)	
	$d_3$	$d_4$	$d_3$	$d_4$	$d_3$	$d_4$	$d_3$	$d_4$
I	-99,70	-99,73	-99,69	-99,72	-100	-100	-99,72	-99,74
II	-95,63	-96,76	-96,49	-96,34	-100	-100	-97,17	-97,68
III	-79,69	-82,02	-73,67	-77,49	-100	-100	-78,20	-79,51
IV	-99,37	-97,18	-71,53	-77,77	-100	-100	-68,79	-71,29
V	-97,07	-97,07	-92,11	-94,32	-99,91	-99,95	-87,71	-91,15
VI	-91,50	-91,56	-92,63	-92,45	-100	-100	-93,78	-94,57
VII	-77,15	-87,07	-87,24	-89,18	-99,83	-99,86	-79,54	-83,52
VIII	-54,42	-54,64	-42,21	-50,15	-100	-100	-54,35	-56,43



**Tabela C.69:** Percentual de máxima redução de variabilidade estimados comparados a índice de Harris e Alteração real para os processos no ponto de operação OP1 sob os efeitos dos *DNMs*  $d_5$  e  $d_6$ .

Processo	VRE1(%)		VRE2(%)		Harris(%)		Alteração real(%)	
	$d_5$	$d_6$	$d_5$	$d_6$	$d_5$	$d_6$	$d_5$	$d_6$
I	-99,53	-99,33	-99,30	-99,68	-100	-100	-99,33	-99,69
II	-96,00	-88,13	-92,12	-96,53	-100	-100	-93,36	-97,07
III	-69,88	-78,27	-48,77	-75,96	-100	-100	-56,02	-80,43
IV	-97,39	-95,95	-91,29	-38,29	-100	-100	-71,81	-14,15
V	-95,98	-96,64	-81,69	-89,02	-99,30	-99,91	-72,53	-83,50
VI	-90,75	-90,77	-86,05	-93,28	-100	-99,99	-87,33	-93,52
VII	-68,68	-75,54	-78,68	-83,62	-98,61	-99,72	-58,20	-74,04
VIII	-43,87	-52,81	-17,16	-42,51	-100	-99,99	-31,36	-54,15

**Tabela C.70:** Percentual de máxima redução de variabilidade estimados comparados a índice de Harris e Alteração real para os processos no ponto de operação OP1 sob os efeitos dos *DNMs*  $d_7$  e  $d_8$ .

Processo	VRE1(%)		VRE2(%)		Harris(%)		Alteração real(%)	
	$d_7$	$d_8$	$d_7$	$d_8$	$d_7$	$d_8$	$d_7$	$d_8$
I	-93,70	-78,50	-98,26	-99,63	-100	-100	-98,51	-99,57
II	-61,52	-31,12	-80,39	-96,11	-100	-100	-83,96	-95,01
III	-60,67	-80,36	-48,26	-85,91	-100	-100	-43,69	-77,00
IV	-93,98	-92,00	-68,70	-54,67	-100	-100	-30,69	-3,59
V	-94,96	-95,08	-68,88	-68,56	-98,23	-99,71	-51,88	-54,92
VI	-73,45	-89,10	-71,67	-90,00	-99,98	-100	-74,29	-89,48
VII	-26,70	-70,78	-64,99	-61,70	-96,52	-99,50	-32,19	-47,86
VIII	-49,86	-60,50	-17,93	-53,13	-99,98	-100	-18,14	-52,54

**Tabela C.71:** Percentual de máxima redução de variabilidade estimados comparados a índice de Harris e Alteração real para os processos no ponto de operação OP2 sob os efeitos dos *DNMs*  $d_1$  e  $d_2$ .

Processo	VRE1(%)		VRE2(%)		Harris(%)		Alteração real(%)	
	$d_1$	$d_2$	$d_1$	$d_2$	$d_1$	$d_2$	$d_1$	$d_2$
I	-99,42	-99,37	-99,42	-99,32	-100	-100	-99,44	-99,36
II	-94,94	-94,17	-91,37	-87,51	-100	-100	-93,11	-88,97
III	-41,92	-36,06	-32,13	-18,05	-100	-100	-40,16	-25,00
IV	-86,20	-94,39	-82,16	-91,42	-100	-100	-82,18	-92,41
V	-88,83	-91,30	-75,71	-71,94	-99,98	-99,39	-77,62	-75,51
VI	-89,88	-87,69	-89,22	-85,70	-99,98	-99,97	-89,96	-87,66
VII	-46,59	-42,73	-40,49	-28,69	-99,34	-97,49	-46,61	-32,21
VIII	-54,12	-46,17	-50,78	-34,84	-99,98	-99,98	-56,39	-49,78

**Tabela C.72:** Percentual de máxima redução de variabilidade estimados comparados a índice de Harris e Alteração real para os processos no ponto de operação OP2 sob os efeitos dos DNMs  $d_3$  e  $d_4$ .

Processo	VRE1(%)		VRE2(%)		Harris(%)		Alteração real(%)	
	$d_3$	$d_4$	$d_3$	$d_4$	$d_3$	$d_4$	$d_3$	$d_4$
I	-99,42	-99,43	-99,43	-99,40	-100	-100	-99,46	-99,45
II	-95,71	-95,87	-92,82	-93,94	-100	-100	-94,38	-95,03
III	-43,54	-45,09	-36,52	-41,95	-100	-100	-43,54	-42,34
IV	-81,79	-88,87	-85,82	-95,23	-100	-100	-90,90	-93,61
V	-91,36	-92,78	-88,52	-89,65	-99,93	-99,90	-89,67	-91,37
VI	-90,89	-91,42	-90,16	-90,36	-99,99	-99,99	-91,06	-91,57
VII	-54,82	-59,02	-56,92	-60,18	-99,30	-99,49	-61,69	-64,73
VIII	-57,41	-59,51	-57,22	-59,92	-99,99	-100	-59,10	-60,42

**Tabela C.73:** Percentual de máxima redução de variabilidade estimados comparados a índice de Harris e Alteração real para os processos no ponto de operação OP2 sob os efeitos dos DNMs  $d_5$  e  $d_6$ .

Processo	VRE1(%)		VRE2(%)		Harris(%)		Alteração real(%)	
	$d_5$	$d_6$	$d_5$	$d_6$	$d_5$	$d_6$	$d_5$	$d_6$
I	-99,35	-99,42	-99,33	-99,39	-100	-100	-99,37	-99,42
II	-93,78	-95,51	-82,33	-93,73	-100	-100	-86,20	-94,77
III	-34,49	-44,24	-21,68	-42,03	-100	-100	-29,00	-42,09
IV	-87,87	-69,75	-79,10	-83,39	-100	-100	-80,11	-83,57
V	-88,06	-90,79	-69,00	-84,86	-98,99	-99,82	-71,44	-85,81
VI	-86,77	-90,84	-85,00	-89,58	-99,97	-99,97	-86,98	-90,89
VII	-35,82	-51,19	-30,00	-53,49	-97,74	-99,09	-35,23	-56,79
VIII	-42,81	-57,42	-29,57	-55,37	-99,98	-99,97	-47,35	-58,41

**Tabela C.74:** Percentual de máxima redução de variabilidade estimados comparados a índice de Harris e Alteração real para os processos no ponto de operação OP2 sob os efeitos dos DNMs  $d_7$  e  $d_8$ .

Processo	VRE1(%)		VRE2(%)		Harris(%)		Alteração real(%)	
	$d_7$	$d_8$	$d_7$	$d_8$	$d_7$	$d_8$	$d_7$	$d_8$
I	-99,32	-99,41	-99,32	-99,64	-100	-100	-99,33	-99,46
II	-90,86	-94,06	-72,42	-91,77	-100	-100	-76,47	-93,85
III	-29,46	-41,65	-18,61	-52,49	-100	-100	-20,93	-37,32
IV	-78,18	-41,18	-60,88	-67,48	-100	-100	-58,73	-54,79
V	-81,52	-84,78	-49,67	-71,64	-97,79	-99,70	-51,26	-69,71
VI	-82,70	-89,32	-78,38	-93,40	-99,92	-99,99	-82,01	-89,55
VII	-18,22	-34,82	-14,29	-36,71	-95,65	-99,23	-16,92	-36,38
VIII	-31,15	-51,01	-15,76	-40,18	-99,95	-99,99	-32,20	-53,02

**Tabela C.75:** Percentual de máxima redução de variabilidade estimados comparados a índice de Harris e Alteração real para os processos no ponto de operação OP3 sob os efeitos dos *DNMs*  $d_1$  e  $d_2$ .

Processo	VRE1(%)		VRE2(%)		Harris(%)		Alteração real(%)	
	$d_1$	$d_2$	$d_1$	$d_2$	$d_1$	$d_2$	$d_1$	$d_2$
I	-99,76	-99,70	-99,74	-99,64	-99,99	-99,99	-99,75	-99,65
II	-93,52	-92,67	-91,61	-89,24	-99,99	-99,99	-92,94	-90,99
III	-93,61	-91,78	-95,14	-94,48	-99,99	-99,99	-94,49	-91,66
IV	-82,49	-90,20	-70,70	-84,28	-99,99	-99,99	-64,22	-84,71
V	-82,94	-90,02	-74,16	-81,40	-99,63	-99,63	-75,39	-82,61
VI	-94,59	-93,55	-94,06	-91,64	-99,99	-99,99	-94,53	-92,61
VII	-78,66	-79,02	-57,47	-49,89	-98,44	-98,44	-58,35	-49,69
VIII	-47,37	-43,96	-44,54	-30,56	-99,99	-99,99	-50,65	-34,17

**Tabela C.76:** Percentual de máxima redução de variabilidade estimados comparados a índice de Harris e Alteração real para os processos no ponto de operação OP3 sob os efeitos dos *DNMs*  $d_3$  e  $d_4$ .

Processo	VRE1(%)		VRE2(%)		Harris(%)		Alteração real(%)	
	$d_3$	$d_4$	$d_3$	$d_4$	$d_3$	$d_4$	$d_3$	$d_4$
I	-99,80	-99,81	-99,78	-99,80	-100	-100	-99,79	-99,80
II	-94,71	-95,07	-93,46	-93,88	-100	-100	-94,37	-95,06
III	-94,61	-95,55	-95,81	-95,24	-100	-100	-95,26	-95,50
IV	-83,37	-87,53	-69,88	-84,73	-100	-100	-74,35	-84,10
V	-87,66	-90,66	-84,47	-88,14	-99,87	-99,91	-85,03	-88,55
VI	-95,40	-95,71	-94,83	-94,91	-100	-100	-95,37	-95,75
VII	-81,41	-82,61	-73,24	-74,80	-99,67	-99,70	-73,69	-76,03
VIII	-48,14	-49,88	-44,34	-45,38	-100	-100	-50,08	-49,08

**Tabela C.77:** Percentual de máxima redução de variabilidade estimados comparados a índice de Harris e Alteração real para os processos no ponto de operação OP3 sob os efeitos dos *DNMs*  $d_5$  e  $d_6$ .

Processo	VRE1(%)		VRE2(%)		Harris(%)		Alteração real(%)	
	$d_5$	$d_6$	$d_5$	$d_6$	$d_5$	$d_6$	$d_5$	$d_6$
I	-99,66	-99,78	-99,61	-99,81	-100	-100	-99,62	-99,78
II	-91,65	-94,36	-85,56	-93,37	-100	-100	-88,85	-94,31
III	-90,69	-94,45	-93,91	-95,87	-100	-100	-91,57	-95,01
IV	-80,26	-35,00	-64,62	-67,73	-100	-100	-65,69	-56,20
V	-82,84	-85,14	-68,99	-79,44	-99,14	-99,85	-70,63	-80,50
VI	-92,81	-95,27	-90,86	-95,55	-99,99	-99,99	-91,86	-95,35
VII	-76,34	-80,61	-49,05	-68,12	-98,39	-99,49	-48,17	-69,18
VIII	-41,40	-48,42	-38,26	-47,60	-99,99	-99,99	-44,22	-52,54

**Tabela C.78:** Percentual de máxima redução de variabilidade estimados comparados a índice de Harris e Alteração real para os processos no ponto de operação OP3 sob os efeitos dos *DNMs*  $d_7$  e  $d_8$ .

Processo	VRE1(%)		VRE2(%)		Harris(%)		Alteração real(%)	
	$d_7$	$d_8$	$d_7$	$d_8$	$d_7$	$d_8$	$d_7$	$d_8$
I	-99,48	-99,73	-99,42	-99,89	-100	-100	-99,40	-99,74
II	-85,64	-91,21	-73,08	-91,28	-100	-100	-78,76	-91,92
III	-82,57	-91,47	-90,53	-93,98	-100	-100	-84,91	-93,76
IV	-66,41	-39,08	-40,35	-44,59	-100	-100	-38,01	-22,39
V	-73,40	-72,50	-49,25	-60,08	-97,76	-99,66	-51,42	-59,28
VI	-88,48	-93,55	-83,65	-96,07	-99,96	-100	-86,25	-94,05
VII	-67,55	-74,87	-25,34	-53,28	-96,64	-99,50	-23,37	-49,56
VIII	-35,78	-46,68	-46,94	-44,72	-99,98	-100	-45,03	-49,78

*C.1.6 Erros percentuais entre as máximas alterações de variabilidade estimadas (VRE1, VRE2 e Harris) e as reais máximas alterações de variabilidade*

**Tabela C.79:** Erro relativo percentual entre a máxima redução de variabilidade estimada e a Alteração real para os processos no ponto de operação OP1 sob os efeitos dos *DNMs*  $d_1$  e  $d_2$ .

Processo	ERP(%)					
	VRE1		VRE2		Harris	
	$d_1$	$d_2$	$d_1$	$d_2$	$d_1$	$d_2$
I	0,02	0,19	0,04	0,03	0,37	0,58
II	8,15	1,69	1,40	0,75	4,03	4,99
III	0,71	18,73	8,83	4,66	32,07	61,26
IV	100	100	12,50	5,12	72,27	29,84
V	23,74	10,86	9,30	6,31	28,76	13,73
VI	2,91	3,18	1,63	1,63	8,93	11,75
VII	1,05	2,19	18,95	22,84	49,07	36,07
VIII	3,66	5,13	26,62	21,88	105,45	120,07

**Tabela C.80:** Erro relativo percentual entre a máxima redução de variabilidade estimada e a Alteração real para os processos no ponto de operação OP1 sob os efeitos dos *DNMs*  $d_3$  e  $d_4$ .

Processo	ERP(%)					
	VRE1		VRE2		Harris	
	$d_3$	$d_4$	$d_3$	$d_4$	$d_3$	$d_4$
I	0,03	0,02	0,03	0,03	0,28	0,26
II	1,59	0,95	0,70	1,38	2,91	2,37
III	1,90	3,15	5,79	2,55	27,88	25,76
IV	44,45	36,32	3,98	9,09	45,36	40,28
V	10,67	6,90	5,02	3,48	13,91	9,66
VI	2,43	1,54	1,23	2,24	6,63	5,74
VII	3,00	5,00	9,69	6,78	25,51	19,57
VIII	0,14	3,63	22,33	11,13	84,00	77,21

**Tabela C.81:** Erro relativo percentual entre a máxima redução de variabilidade estimada e a Alteração real para os processos no ponto de operação OP1 sob os efeitos dos *DNMs*  $d_5$  e  $d_6$ .

Processo	ERP(%)					
	VRE1		VRE2		Harris	
	$d_5$	$d_6$	$d_5$	$d_6$	$d_5$	$d_6$
I	0,20	0,37	0,03	0,01	0,68	0,31
II	2,83	9,21	1,33	0,55	7,11	3,02
III	24,74	2,68	12,94	5,56	78,52	24,34
IV	35,63	578,32	27,14	170,67	39,26	606,93
V	32,34	15,74	12,63	6,61	36,91	19,65
VI	3,91	2,94	1,46	0,25	14,50	6,93
VII	18,01	2,03	35,19	12,94	69,43	34,68
VIII	39,90	2,48	45,28	21,50	218,85	84,65

**Tabela C.82:** Erro relativo percentual entre a máxima redução de variabilidade estimada e a Alteração real para os processos no ponto de operação OP1 sob os efeitos dos *DNMs*  $d_7$  e  $d_8$ .

Processo	ERP(%)					
	VRE1		VRE2		Harris	
	$d_7$	$d_8$	$d_7$	$d_8$	$d_7$	$d_8$
I	4,89	21,16	0,26	0,06	1,51	0,43
II	26,73	67,25	4,25	1,16	19,10	5,25
III	38,85	4,37	10,46	11,57	128,87	29,87
IV	206,20	2463,82	123,85	1423,34	225,83	2686,67
V	83,04	73,12	32,77	24,83	89,34	81,54
VI	1,13	0,42	3,53	0,58	34,59	11,76
VII	17,08	47,87	101,86	28,91	199,81	107,89
VIII	174,83	15,14	1,17	1,13	451,11	90,33

**Tabela C.83:** Erro relativo percentual entre a máxima redução de variabilidade estimada e a Alteração real para os processos no ponto de operação OP2 sob os efeitos dos *DNMs*  $d_1$  e  $d_2$ .

Processo	ERP(%)					
	VRE1		VRE2		Harris	
	$d_1$	$d_2$	$d_1$	$d_2$	$d_1$	$d_2$
I	0,02	0,01	0,02	0,04	0,56	0,64
II	1,97	5,84	1,86	1,64	7,40	12,39
III	4,38	44,24	20,00	27,80	148,99	299,95
IV	4,89	2,14	0,02	1,07	21,68	8,22
V	14,44	20,91	2,46	4,73	28,80	31,63
VI	0,09	0,03	0,82	2,24	11,14	14,04
VII	0,05	32,64	13,14	10,94	113,11	202,66
VIII	4,04	7,26	9,96	30,03	77,28	100,82

**Tabela C.84:** Erro relativo percentual entre a máxima redução de variabilidade estimada e a Alteração real para os processos no ponto de operação OP2 sob os efeitos dos *DNMs*  $d_3$  e  $d_4$ .

Processo	ERP(%)					
	VRE1		VRE2		Harris	
	$d_3$	$d_4$	$d_3$	$d_4$	$d_3$	$d_4$
I	0,04	0,02	0,02	0,04	0,54	0,56
II	1,41	0,88	1,65	1,15	5,95	5,23
III	0,01	6,49	16,11	0,93	129,69	136,19
IV	10,02	5,06	5,59	1,73	10,01	6,83
V	1,88	1,54	1,28	1,88	11,44	9,34
VI	0,19	0,16	0,99	1,32	9,80	9,21
VII	11,14	8,83	7,73	7,04	60,96	53,70
VIII	2,85	1,50	3,17	0,83	69,20	65,50

**Tabela C.85:** Erro relativo percentual entre a máxima redução de variabilidade estimada e a Alteração real para os processos no ponto de operação OP2 sob os efeitos dos *DNMs*  $d_5$  e  $d_6$ .

Processo	ERP(%)					
	VRE1		VRE2		Harris	
	$d_5$	$d_6$	$d_5$	$d_6$	$d_5$	$d_6$
I	0,03	0,01	0,04	0,03	0,63	0,58
II	8,80	0,78	4,49	1,10	16,01	5,51
III	18,94	5,12	25,23	0,13	244,84	137,61
IV	9,68	16,54	1,26	0,22	24,83	19,66
V	23,26	5,80	3,43	1,11	38,56	16,33
VI	0,24	0,06	2,28	1,44	14,94	9,99
VII	1,67	9,85	14,84	5,82	177,43	74,48
VIII	9,59	1,69	37,56	5,20	111,14	71,16

**Tabela C.86:** Erro relativo percentual entre a máxima redução de variabilidade estimada e a Alteração real para os processos no ponto de operação OP2 sob os efeitos dos *DNMs*  $d_7$  e  $d_8$ .

Processo	ERP(%)					
	VRE1		VRE2		Harris	
	$d_7$	$d_8$	$d_7$	$d_8$	$d_7$	$d_8$
I	0,01	0,05	0,00	0,18	0,68	0,54
II	18,82	0,22	5,29	2,21	30,77	6,56
III	40,74	11,60	11,10	40,64	377,68	167,95
IV	33,13	24,83	3,66	23,17	70,28	82,52
V	59,03	21,62	3,10	2,77	90,77	43,02
VI	0,84	0,26	4,42	4,31	21,84	11,67
VII	7,67	4,28	15,53	0,92	465,29	172,78
VIII	3,25	3,80	51,04	24,21	210,40	88,59

**Tabela C.87:** Erro relativo percentual entre a máxima redução de variabilidade estimada e a Alteração real para os processos no ponto de operação OP3 sob os efeitos dos *DNMs*  $d_1$  e  $d_2$ .

Processo	ERP(%)					
	VRE1		VRE2		Harris	
	$d_1$	$d_2$	$d_1$	$d_2$	$d_1$	$d_2$
I	0,009	0,041	0,007	0,009	0,25	0,34
II	0,61	1,8	1,42	1,92	7,6	9,89
III	0,94	0,12	0,68	3,08	5,8	9,09
IV	28,39	6,47	10,10	0,51	55,72	18,03
V	10,01	-8,95	1,62	1,46	32,62	20,59
VI	0,057	0,96	0,49	1,05	5,78	7,96
VII	34,8	58,98	1,49	0,40	70,86	98,10
VIII	6,46	28,65	12,05	10,57	97,42	192,6

**Tabela C.88:** Erro relativo percentual entre a máxima redução de variabilidade estimada e a Alteração real para os processos no ponto de operação OP3 sob os efeitos dos *DNMs*  $d_3$  e  $d_4$ .

Processo	ERP(%)					
	VRE1		VRE2		Harris	
	$d_3$	$d_4$	$d_3$	$d_4$	$d_3$	$d_4$
I	0,005	0,002	0,01	0,01	0,21	0,20
II	0,37	0,01	0,96	1,24	5,97	5,19
III	0,68	0,05	0,58	0,27	4,98	4,72
IV	12,13	4,07	6,01	0,74	34,50	18,90
V	3,10	2,38	0,65	0,47	17,46	12,83
VI	0,03	0,04	0,57	0,87	4,85	4,44
VII	10,47	8,66	0,61	1,62	35,24	31,14
VIII	3,87	1,62	11,46	7,54	99,67	103,74

**Tabela C.89:** Erro relativo percentual entre a máxima redução de variabilidade estimada e a Alteração real para os processos no ponto de operação OP3 sob os efeitos dos *DNMs*  $d_5$  e  $d_6$ .

<i>Processo</i>	<i>ERP</i> (%)					
	<i>VRE1</i>		<i>VRE2</i>		<i>Harris</i>	
	$d_5$	$d_6$	$d_5$	$d_6$	$d_5$	$d_6$
I	0,041	0,007	0,01	0,03	0,38	0,22
II	3,15	0,05	3,70	1,00	12,55	6,03
III	0,95	0,59	2,56	0,90	9,21	5,26
IV	22,18	37,72	1,62	20,51	52,24	77,93
V	17,29	5,76	2,33	1,33	40,37	24,03
VI	1,03	0,08	1,10	0,21	8,85	4,87
VII	58,47	16,53	1,82	1,52	104,24	43,81
VIII	6,37	7,85	13,47	9,39	126,13	90,30

**Tabela C.90:** Erro relativo percentual entre a máxima redução de variabilidade estimada e a Alteração real para os processos no ponto de operação OP3 sob os efeitos dos *DNMs*  $d_7$  e  $d_8$ .

<i>Processo</i>	<i>ERP</i> (%)					
	<i>VRE1</i>		<i>VRE2</i>		<i>Harris</i>	
	$d_7$	$d_8$	$d_7$	$d_8$	$d_7$	$d_8$
I	0,080	0,006	0,02	0,15	0,61	0,26
II	8,73	0,77	7,22	0,70	26,96	8,79
III	2,75	2,44	6,62	0,24	17,77	6,66
IV	74,74	74,58	6,17	99,15	163,11	346,67
V	42,74	22,30	4,22	1,35	90,12	68,12
VI	2,59	0,53	3,01	2,15	15,90	6,33
VII	189,09	51,07	8,46	7,49	313,59	100,75
VIII	20,54	6,24	4,26	10,17	122,05	100,88



## Referências

AGUIRRE, L. A. **Introdução à Identificação de Sistemas – Técnicas Lineares e Não-Lineares Aplicadas a Sistemas Reais**. 3ª. Editora UFMG, 2007. ISBN 9788570415844.

AGÜERO, J. C.; GOODWIN, G. C.; VAN DEN HOF, P. M. J. A virtual closed loop method for closed loop identification. **Automatica**, v. 47, n. 8, p. 1626-1637, 8// 2011. ISSN 0005-1098.

ASTROM, K. J. **Introduction to stochastic control theory**. 1970

BARTLETT, M. S. Review: , The Advanced Theory of Statistics. Vol. I;; Maurice G. Kendall, The Advanced Theory of Statistics. Vol II. p. 139-142, 1947/03 1947. ISSN 0003-4851.

BRAND, F. R. **Modelo de Inferência de Variabilidade: traduzindo o desempenho de malhas de controle em alteração de variabilidade**. 2009. (mestrado). Escola de Engenharia, Universidade Federal do Rio Grande do Sul

CARNEIRO, F. G. A Metodologia dos Testes de Causalidade em Economia. **Departamento de Economia, Universidade de Brasília. Texto didático**, 1997.

CHATFIELD, C. **Time-Series Forecasting**. CRC Press, 2000. ISBN 9781420036206.

CHEN, C.-T. **Linear system theory and design**. Oxford University Press, Inc., 1995. ISBN 0030602890.

CHEN, W.-H. et al. Disturbance Observer-Based Control and Related Methods: An Overview. **Industrial Electronics, IEEE Transactions on**, v. PP, n. 99, p. 1-1, 2015. ISSN 0278-0046.

DESBOROUGH, L.; HARRIS, T. **Can. J. Chem. Eng.**, v. 70, p. 1186, 1992.

DEVRIES, W.; WU, S. Evaluation of process control effectiveness and diagnosis of variation in paper basis weight via multivariate time-series analysis. **Automatic Control, IEEE Transactions on**, v. 23, n. 4, p. 702-708, 1978. ISSN 0018-9286.

DURAIKI, R. G. **Controle Preditivo Não Linear Utilizando Linearização ao Longo da Trajetória**. 2001. (Mestrado). Departamento de Engenharia Química, Universidade Federal do Rio Grande do Sul

FARENZENA, M. **Novel methodologies for assessment and diagnostics in control loop management**. 2008. (Doutorado). Escola de Engenharia, Universidade Federal do Rio Grande do Sul

FARENZENA, M., TRIERWEILER, J.O. **Quantifying closed-loop performance based on online performance indices**. Gramado, Brasil: ADCHEM - International Symposium on Advanced Control of Chemical Processes. 2 2006a.

FARENZENA, M., TRIERWEILER, J.O. **Using the inference model as tool to quantify the loop performance and robustness**. Gramado, Brasil: SICOP - International Symposium on Advanced Control of Chemical Processes. 2: 887-892 p. 2006b.

GAO, Z. On the centrality of disturbance rejection in automatic control. **ISA Transactions**, v. 53, n. 4, p. 850-857, 7// 2014. ISSN 0019-0578.

GARCIA, C. E.; MORARI, M. Internal model control. A unifying review and some new results. **Industrial & Engineering Chemistry Process Design and Development**, v. 21, n. 2, p. 308-323, 1982/04/01 1982. ISSN 0196-4305.

GERTLER, J. J. Survey of model-based failure detection and isolation in complex plants. **Control Systems Magazine, IEEE**, v. 8, n. 6, p. 3-11, 1988. ISSN 0272-1708.

GEVERS, M.; BAZANELLA, A.; MISKOVI, L. Informative data: How to get just sufficiently rich? , *Decision and Control*, 2008. CDC 2008. 47th IEEE Conference on, 2008, 9-11 Dec. 2008. p.1962-1967.

GRANGER, C. W. J. Investigating Causal Relations by Econometric Models and Cross-spectral Methods. **Econometrica**, v. 37, n. 3, p. 424-438, 1969. ISSN 00129682.

GUO, L.; CAO, S. Anti-disturbance control theory for systems with multiple disturbances: a survey. **ISA transactions**, v. 53, n. 4, p. 846-849, 2014. ISSN 0019-0578.

HAN, J. **Control theory: is it a theory of model or control?:** System Science and Mathematical Science. 9: 328–335 p. 1989.

HAN, J. A class of extended state observers for uncertain systems. **Control and Decision**, v. 10, n. 1, p. 85-88, 1995.

HAN, J. From PID to active disturbance rejection control. **Industrial Electronics, IEEE transactions on**, v. 56, n. 3, p. 900-906, 2009. ISSN 0278-0046.

HARRIS, T. J. Assessment of control loop performance. **The Canadian Journal of Chemical Engineering**, v. 67, n. 5, p. 856-861, 1989. ISSN 1939-019X.

HARRIS, T. J.; SEPPALA, C. T.; DESBOROUGH, L. D. A review of performance monitoring and assessment techniques for univariate and multivariate control systems. **Journal of Process Control**, v. 9, n. 1, p. 1-17, 2// 1999. ISSN 0959-1524.

HUANG, B.; SHAH, S. L. **Performance assessment of control loops: theory and applications.** 1999.

JELALI, M. An overview of control performance assessment technology and industrial applications. **Control Engineering Practice**, v. 14, n. 5, p. 441-466, 2006. ISSN 0967-0661.

JOHNSON, C. Real-time disturbance-observers; origin and evolution of the idea part 1: The early years. System Theory, 2008. SSST 2008. 40th Southeastern Symposium on, 2008, IEEE. p.88-91.

JOHNSON, C. D. Accomodation of external disturbances in linear regulator and servomechanism problems. **Automatic Control, IEEE Transactions on**, v. 16, n. 6, p. 635-644, 1971. ISSN 0018-9286.

JOHNSON, C. D. Disturbance-Accommodating Control; An Overview. American Control Conference, 1986, 1986, 18-20 June 1986. p.526-536.

KELLY, W. C. **Theory of Disturbance-Utilizing Control With Application to Missile Intercept Problems.** DTIC Document. 1979

KNOCKAERT, L.; DHAENE, T. Causality Determination and Time Delay Extraction by Means of the Eigenfunctions of the Hilbert Transform. Signal Propagation on Interconnects, 2008. SPI 2008. 12th IEEE Workshop on, 2008, 12-15 May 2008. p.1-4.

KWON, S.; CHUNG, W. K. A robust tracking controller design with hierarchical perturbation compensation. **Journal of dynamic systems, measurement, and control**, v. 124, n. 2, p. 261-271, 2002. ISSN 0022-0434.

KWON, S.; CHUNG, W. K.. A discrete-time design and analysis of perturbation observer for motion control applications. **Control Systems Technology, IEEE Transactions on**, v. 11, n. 3, p. 399-407, 2003. ISSN 1063-6536.

LAGARIAS, J. C. et al. Convergence properties of the Nelder--Mead simplex method in low dimensions. **SIAM Journal on optimization**, v. 9, n. 1, p. 112-147, 1998. ISSN 1052-6234.

LEAMER, E. E. Vector autoregressions for causal inference? **Carnegie-Rochester Conference Series on Public Policy**, v. 22, p. 255-304, // 1985. ISSN 0167-2231.

LI, S. et al. **Disturbance observer-based control: methods and applications**. CRC press, 2014. ISBN 1466515791.

LJUNG, L. **System Identification: Theory for the User**. 2. Pearson Education, 1998. ISBN 9780132440530.

MACHADO, V. C. **Planejamento de Perturbações para a Identificação de Modelos Dinâmicos**. 2004. (Mestrado). Departamento de Engenharia Química, Universidade Federal do Rio Grande do Sul, Porto Alegre-RS.

NAGHETTINI, M.; PINTO, É. J. D. A. Correlação e Regressão. In: BRASIL-CPRM, S. G. D. (Ed.). **Hidrologia Estatística**. Belo Horizonte, 2007. cap. 9º, ISBN 978-85-7499-023-1.

NELDER, J. A.; MEAD, R. A Simplex Method for Function Minimization. **The Computer Journal**, v. 7, n. 4, p. 308-313, 1965.

OHISHI, K. et al. Microprocessor-controlled DC motor for load-insensitive position servo system. **IEEE Transactions on Industrial Electronics**, n. 1, p. 44-49, 1987. ISSN 0278-0046.

OHISHI, K.; OHNISHI, K.; MIYACHI, K. TORQUE - SPEED REGULATION OF DC MOTOR BASED ON LOAD TORQUE ESTIMATION METHOD. 1983. p.1209-1218.

OVERSCHEE, P. V.; MOOR, B. D. N4SID: subspace algorithms for the identification of combined deterministic-stochastic systems. **Automatica**, v. 30, n. 1, p. 75-93, 1994. ISSN 0005-1098.

RADKE, A. **On disturbance estimation and its applications in health monitoring**. 2006. 131 Cleveland State University

RIBEIRO, J. L. D.; CATEN, C. S. T. **Série monográfica Qualidade: Controle Estatístico do Processo. Cartas de Controle para Variáveis, Cartas de Controle para Atributos, Função de Perda Quadrática, Análise de Sistemas de Medição.** Porto Alegre, RS: Universidade Federal do Rio Grande do Sul 2012.

SCHRIJVER, E.; VAN DIJK, J. Disturbance observers for rigid mechanical systems: equivalence, stability, and design. **Journal of Dynamic Systems, Measurement, and Control**, v. 124, n. 4, p. 539-548, 2002. ISSN 0022-0434.

SEBORG, D. E., EDGAR, T. F., MELLICHAMP, D. A. **Process Dynamics and Control.** NJ, Wiley: 2004.

SHE, J.-H. et al. Improving disturbance-rejection performance based on an equivalent-input-disturbance approach. **Industrial Electronics, IEEE Transactions on**, v. 55, n. 1, p. 380-389, 2008. ISSN 0278-0046.

SIRA-RAMIREZ, H.; OLIVER-SALAZAR, M. A. On the robust control of Buck-converter DC-motor combinations. **Power Electronics, IEEE Transactions on**, v. 28, n. 8, p. 3912-3922, 2013. ISSN 0885-8993.

SKELTON, R. E.; LIKINS, P. W. Orthogonal filters for model error compensation in the control of nonrigid spacecraft. **Journal of Guidance, Control, and Dynamics**, v. 1, n. 1, p. 41-49, 1978. ISSN 0731-5090.

SKOGESTAD, S.; POSTLETHWAITE, I. **Multivariable Feedback Control: Analysis and Design.** John Wiley & Sons, 2005. ISBN 0470011688.

VAN DEN HOF, P. Closed-loop issues in system identification. **Annual reviews in control**, v. 22, p. 173-186, 1998. ISSN 1367-5788.

VAN DONKELAAR, E. T.; VAN DEN HOF, P. M. Analysis of closed-loop identification with a tailor-made parametrization. Control Conference (ECC), 1997 European, 1997, IEEE. p.3398-3403.

VAN OVERSCHEE, P.; DE MOOR, B. L. **Subspace Identification for Linear Systems: Theory — Implementation — Applications.** Springer US, 2012. ISBN 9781461304654.

YAN, Z.; CHAN, C.-L.; YAO, Y. Multivariate Control Performance Assessment and Control System Monitoring via Hypothesis Test on Output Covariance Matrices. **Industrial & Engineering Chemistry Research**, v. 54, n. 19, p. 5261-5272, 2015/05/20 2015. ISSN 0888-5885.

ZHENG, W. X.; FENG, C.-B. A bias-correction method for indirect identification of closed-loop systems. **Automatica**, v. 31, n. 7, p. 1019-1024, 1995. ISSN 0005-1098.

ZHONG, Q. C.; KUPERMAN, A.; STOBART, R. Design of UDE-based controllers from their two-degree-of-freedom nature. **International Journal of Robust and Nonlinear Control**, v. 21, n. 17, p. 1994-2008, 2011. ISSN 1099-1239.

ÅSTRÖM, K. J. Computer Control of a Paper Machine-an Application of Linear Stochastic Control Theory. **IBM Journal of Research and Development**, v. 11, n. 4, p. 389-405, 1967. ISSN 0018-8646.

ÅSTRÖM, K. J.; WITTENMARK, B. **Computer-controlled systems: theory and design**. Courier Corporation, 2013. ISBN 0486284042.

ÅSTRÖM, K. J.; HÄGGLUND, T. **PID controllers: Theory, design, and tuning**. International Society Automation, 1995.