

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

**Modelo de Inferência de Variabilidade:
traduzindo o desempenho de malhas de
controle em alteração de variabilidade**

DISSERTAÇÃO DE MESTRADO

Fernanda Raquel Brand

Porto Alegre

2009

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

**Modelo de Inferência de Variabilidade:
traduzindo o desempenho de malhas de
controle em alteração de variabilidade**

Fernanda Raquel Brand

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

Área de concentração: Controle de Processos

Orientador:
Prof. Dr. Jorge Otávio Trierweiler

Porto Alegre

2009

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 *Modelo de Inferência de Variabilidade: traduzindo o desempenho de malhas de controle em alteração de variabilidade*, elaborada por Fernanda Raquel Brand, como requisito parcial para obtenção do Grau de Mestre em Engenharia.

Comissão Examinadora:

Dr.Eng. Luís Gustavo Soares Longhi – REFAP

Prof. Dr. Marcelo Farenzena – DEQUI/UFRGS

Dr. Rodrigo Ivan Goytia Mejia – PPGEQ/UFRGS

*“Tudo é uma questão de manter
a mente quieta
a espinha ereta
e o coração tranqüilo.”*

Walter Franco

Agradecimentos

À Universidade Federal do Rio Grande do Sul e ao Departamento de Engenharia Química, pela estrutura disponibilizada e pelo corpo-técnico de excelente qualidade, responsáveis pela minha formação profissional e também pessoal.

Ao meu orientador Prof^o. Jorge Trierweiler, pela sugestão do tema e pelo acompanhamento nas fases mais difíceis do mestrado.

Ao Prof^o. Marcelo Farenzena, pela disponibilidade e paciência para solucionar as inúmeras dúvidas que surgiram ao longo deste trabalho.

À banca examinadora, pelas contribuições à melhoria da versão final deste trabalho.

Ao Eng^o. Gustavo Neumann, por gentilmente ter cedido os dados para o caso de estudo e pela dedicação sempre presente no seu dia-a-dia.

À Equipe TriSolutions, por acreditarem em mim e por apoiarem a realização deste trabalho.

À todo o pessoal do Gimsco, pelo incentivo, sugestões e momentos de descontração, que tornaram esses últimos dias de trabalho menos pesados. Agradecimentos explícitos à Bruna, companheira de inúmeros finais de semana, obrigada pelos almoços e pelas conversas e ao Escobar, pelo apoio em sempre mostrar que é possível e pela correção final deste trabalho.

Ao meu “ex-estagiário” e para sempre amigo Rodrigo, pelas valiosas dicas. O seu lado “matemático” de ver a vida me ensinou muitas coisas, as quais agradeço de coração.

Aos muitos amigos da UFRGS feitos ao longo da graduação e do mestrado, minha família aqui em Porto. Todos esses anos teria sido impossível sem a presença de vocês!

Ao pessoal de Bento, família do “Sítio em Chamas”: Li, Zen, Aninha, Xali, Toni, Mai, Ciro, Lú, Diego, Guego. Cris; sempre presentes nas horas boas, ruins e nas mais improváveis, agradeço pelo amor e pela amizade dedicada durante todos esses anos.

Aos meus pais, Odilo e Nelci, pelo amor e apoio incondicionais. Obrigado por me ensinarem o certo, por apostarem na minha educação e por acreditarem que minhas ausências nos finais de semana eram para um bom motivo. Essa vitória é uma conquista de vocês também.

Um especial agradecimento à minha irmã, Fabiane, por ter “tentado” entender meu trabalho, me auxiliando nas correções e sempre me estimulando nas horas mais difíceis. Sem o seu exemplo e sua força, certamente eu não seria o que sou hoje.

Ao meu porto seguro, Tai, por tudo o que tem feito por nós durante todos esses anos, pela paciência e compreensão com minhas dificuldades e minhas muitas ausências, por me agüentar e, simplesmente, por fazer parte da minha vida.

A três anjos, que me fazem querer o melhor todo o dia e que me mostram como a vida pode ser simples.

Essa dissertação foi feita por muitas mãos. A todas essas e mais àquelas que, de uma maneira ou de outra, sempre torceram pela conclusão de mais essa etapa, meu **MUITO OBRIGADA!**

Fernanda Raquel Brand

Resumo

Diminuir a variabilidade de variáveis chaves do processo tornou-se um dos principais caminhos para quantificar os benefícios potenciais da melhoria do controle de processos, ou seja, com maior confiabilidade dos resultados é possível trabalhar em uma região próxima ao ponto de operação ótimo, o que se converte em ganho. Tal ganho pode ser materializado na forma de aumento da capacidade de produção da unidade, redução do consumo de energia, decréscimo de produtos fora de especificação, redução do tempo de transição entre produtos, melhoria na operabilidade, melhoria na qualidade final do produto, entre outros.

Na presente dissertação é realizada uma revisão das principais metodologias que visam quantificar o potencial de alteração de variabilidade a qual uma malha de controle possa estar sujeita, além de propor um modelo de inferência que possa ser utilizado para prever esse potencial de alteração de variabilidade, baseado em índices dados pelo Modelo de Inferência para Desempenho e Robustez.

Neste trabalho é mostrado o procedimento utilizado para a construção do Modelo de Inferência de Variabilidade, o qual utiliza como entradas índices que possam ser facilmente quantificáveis e de características da planta (tempo morto e constante de tempo), usando somente dados em operação normal (sem mudanças no valor do *setpoint*). Para a sua obtenção, três diferentes métodos foram testados (a saber, Rede Neural, Mínimos Quadrados Parciais e Mínimos Quadrados Parciais Quadráticos), sendo os melhores resultados conseguidos ao se aplicar redes neurais.

A eficácia do modelo de inferência proposto é ilustrada pela aplicação em casos de estudo nos quais o modelo de planta pode ser representado por funções de transferência de 1ª e de 2ª ordem com tempo morto e a aplicabilidade do mesmo é

ilustrada ao utilizá-lo em um caso de estudo, desenvolvido em uma planta industrial. Nesse caso de estudo, procurou-se ainda analisar as principais malhas encontradas no cenário industrial. Os resultados obtidos para ambos os casos de estudo mostraram que a ferramenta desenvolvida apresenta um grande potencial de ser utilizada em projetos que contemplem a análise de pontos de melhoria da camada regulatória, uma vez que apresenta uma excelente capacidade de prever a alteração de variabilidade a qual uma malha possa estar sujeita.

Palavras-Chave: Auditoria econômica, auditoria de desempenho e robustez, alteração de variabilidade, modelo de inferência.

Abstract

Reduction of the process variability has a significant impact into the process profitability. A reduction in the variance allows shifting the mean of the controlled variable closer to the constraint and thus ensures better performance like increase product throughput, increase yield of higher valued products, improve energy efficiency, decrease off-specification product, safer operation and reduced environmental impact, among others. In this dissertation, a bibliographic review of the main methodology used to estimate and assess the variance reduction is done.

The main contribution of this work is to propose an inferential model to estimate the potential alteration in variance, based on indices determined by the Performance and Robustness Inferential Model. This work shows the procedure to build the Variability Inferential Model that assesses the potential alteration in variance of a given loop. The inputs variables are indices that can be easily calculated on-line and information about the plant (time delay and time constant) using only normal operating data (without excitation and/or setpoint activity). The set of input – output variables are fitted using different techniques (i.e., Neural Networks, Partial Least Squares and Quadratic Partial Least Squares). The best results are obtained by Neural Network.

The efficacy of the Inferential Model is illustrated by application to first order plus time delay and second order plus time delay models. The proposed methodology was also applied to on a polyolefin plant, providing very good results, in a set of five loops, where the potential variance alteration is computed with small error, showing the efficacy of the methodology.

Keywords: Economic assessment, performance assessment, variance alteration, inferential model.

Sumário

1. Introdução	1
1.1 Auditoria de malhas de controle	1
1.2 Quais os benefícios em se auditar malhas de controle?	2
1.3 Motivação.....	4
1.4 Estrutura da Dissertação.....	5
2. Auditoria Econômica	7
2.1 Histórico.....	7
2.2 Quantificação de Benefícios	10
3. Auditoria de Desempenho e Robustez.....	22
3.1 Índices Determinísticos.....	22
3.1.1 Índices de desempenho	23
3.1.2 Índices de robustez.....	25
3.2 Índices Não Intrusivos	27
3.2.1 Índices baseados no controlador de variância mínima.....	27
3.2.2 Índices baseados na integral do erro	29
3.3 Modelo de Inferência para Desempenho e Robustez.....	30
3.3.1 Modelo de Inferência	31
3.3.2 Entradas do IM.....	31
3.3.3 Índices gerados pelo IM.....	35
4. Desenvolvimento Teórico	36
4.1 Definição do Modelo de Inferência de Variabilidade	36
4.2 Obtenção do Modelo de Inferência de Variabilidade	38
4.2.1 Rede Neural.....	45
4.2.2 Mínimos Quadrados Parciais – PLS e Mínimos Quadrados Parciais Quadráticos – QPLS.....	48
4.3 O Modelo de Inferência de Variabilidade na Prática.....	49
4.4 Casos de Estudo	50
4.4.1 Casos de Estudo Aplicando-se Modelos de 1ª Ordem.....	50
4.4.2 Casos de Estudo Aplicando-se Modelos de 2ª Ordem.....	58
4.5 Discussões Finais	72
5. Caso de Estudo – Modelo de Inferência de Variabilidade.....	73
5.1 Estruturas de Controle.....	73
5.1.1 Torre de Stripping	74
5.1.2 Reator a Leito Fluidizado.....	78
5.2 Melhoria do Controle Regulatório	79
5.2.1 Torre de Stripping	80

5.2.2 Reator a Leito Fluidizado.....	94
5.3 Discussões Finais	97
6. Conclusões e Sugestões para Trabalhos Futuros.....	99
6.1 Considerações Finais.....	99
6.2 Transformando Variabilidade em Benefícios Econômicos.....	102
6.3 Trabalhos Futuros	103
Apêndice A. Medidas de Variabilidade	105
A.1 Importância da Análise de Dados Históricos	107
Apêndice B. Redes Neurais Artificiais	109
B.1 Neurônios Artificiais	109
B.2 Estruturas das Redes Neurais Artificiais	110
B.3 Algoritmos de Aprendizado	111
Referências Bibliográficas.....	113

Lista de figuras

Figura 1.1:	Ilustração da redução de variabilidade em uma variável de processo.	2
Figura 1.2:	Curvas de distribuição da qualidade do produto.	4
Figura 2.1:	Representação de quanto uma variável pode ser movida para o seu ponto de maior rentabilidade, Δx	11
Figura 2.2:	Distribuição gaussiana, com 5% dos dados excedendo o limite	12
Figura 2.3:	(a) Distribuição gaussiana, com uma grande percentagem de dados excedendo o limite. (b) Aplicação da Regra do igual limite.....	13
Figura 2.4:	(a) Distribuição gaussiana, com uma percentagem razoável dos dados excedendo o limite. (b) Aplicação da Regra da mesma percentagem.....	13
Figura 2.5:	Distribuição gaussiana, com poucos dados violando o limite especificado.....	14
Figura 2.6:	(a) Distribuição gaussiana, com uma percentagem significativa dos dados no limite (b) Aplicação da Regra da operação atingível.....	14
Figura 2.7:	Representação esquemática da malha <i>feedback</i> padrão.	16
Figura 2.8:	(a) Função de desempenho quadrática. (b) Função de desempenho linear, com restrições. (c) Função de desempenho <i>Clifftent</i>	20
Figura 3.1:	Crítérios de desempenho baseados na resposta de um sistema subamortecido típico para uma mudança do tipo degrau no valor da variável de referência	23
Figura 3.2:	Diagrama de Nyquist ilustrando alguns critérios de robustez.....	26
Figura 3.3:	Representação da integral do erro.	29
Figura 3.4:	Representação esquemática da decomposição do sinal de saída de um controlador	33
Figura 3.5:	Definição dos índices baseados na função de autocorrelação.....	34
Figura 3.6:	Representação esquemática do Modelo de Inferência para Desempenho e Robustez proposto.	35
Figura 4.1:	Representação esquemática do modelo de inferência proposto.	38
Figura 4.2:	Procedimento para a construção do modelo de inferência.....	39
Figura 4.3:	Malha de Controle por <i>feedback</i> padrão.	40
Figura 4.4:	Interface gráfica utilizada para seleção das entradas do modelo de inferência através do conjunto de dados gerado.	44
Figura 4.5:	Comportamento da alteração de variabilidade em função da variação dos parâmetros $RtR1$ e $RtR2$	54
Figura 4.6:	Comportamento da alteração de variabilidade em função da variação do tempo morto e da constante de tempo da planta para a análise de sensibilidade realizada para a primeira situação.	56
Figura 4.7:	Comportamento da alteração de variabilidade em função da variação do tempo morto e da constante de tempo da planta para a análise de sensibilidade realizada para a segunda situação.....	57
Figura 4.8:	Respostas para os sistemas de 2ª ordem considerados no caso estudo de 1, quando submetidos a uma perturbação do tipo degrau na sua entrada.	60
Figura 4.9:	Comportamento da alteração de variabilidade em função da variação dos parâmetros $RtR1$ e $RtR2$ para sistemas com resposta subamortecida.	63

Figura 4.10: Comportamento da alteração de variabilidade em função da variação do tempo morto e da constante de tempo da planta para sistemas com resposta subamortecida.	64
Figura 4.11: Respostas para os sistemas de 2ª ordem considerados no caso de estudo 2, quando submetidos a uma perturbação do tipo degrau na sua entrada.....	65
Figura 4.12: Comportamento da alteração de variabilidade em função da variação dos parâmetros RtR1 e RtR2 para sistemas com resposta superamortecida.....	67
Figura 4.13: Comportamento da alteração de variabilidade em função da variação do tempo morto e da constante de tempo da planta para sistemas com resposta superamortecida.	68
Figura 4.14: Respostas para os sistemas de 2ª ordem considerados no caso de estudo 3, quando submetidos a uma perturbação do tipo degrau na sua entrada.....	69
Figura 4.15: Comportamento da alteração de variabilidade em função da variação dos parâmetros RtR1 e RtR2 para sistemas com resposta inversa.....	71
Figura 4.16: Comportamento da alteração de variabilidade em função da variação do tempo morto e da constante de tempo da planta para sistemas com resposta inversa.	71
Figura 5.1: Fluxograma simplificado da torre de stripping	77
Figura 5.2: Fluxograma simplificado do sistema de controle do reator a leito fluidizado.....	79
Figura 5.3: Gráficos de tendência representativos do comportamento da pressão da torre de <i>stripping</i>	82
Figura 5.4: Potencial de alteração de variabilidade da malha de controle da pressão da torre de <i>stripping</i> em função do aumento de velocidade da mesma. ..	84
Figura 5.5: Gráficos de tendência representativos do comportamento do nível de fundo da torre de <i>stripping</i>	86
Figura 5.6: Potencial de alteração de variabilidade da malha de controle do nível de fundo da torre de <i>stripping</i> em função do aumento de velocidade da mesma.	87
Figura 5.7: Gráficos de tendência representativos do comportamento da vazão de vapor.	89
Figura 5.8: Potencial de alteração de variabilidade da malha de controle da vazão de vapor da torre de <i>stripping</i> em função do aumento de velocidade da mesma.	90
Figura 5.9: Gráficos de tendência representativos do comportamento do composição de propano.....	93
Figura 5.10: Potencial de alteração de variabilidade da malha de controle da composição de propano em função do aumento de velocidade da mesma.	93
Figura 5.11: Gráficos de tendência representativos do comportamento da temperatura de reação	95
Figura 5.12: Potencial de alteração de variabilidade da malha de controle de temperatura do reator a leito fluidizado em função do aumento de velocidade da mesma.....	96
Figura B.1: Estrutura geral de um neurônio artificial.	110
Figura B.2: Função de ativação sigmoideal.....	110
Figura B.3: Redes Neurais Multicamadas	111

Lista de tabelas

Tabela 4.1: Parâmetros do conjunto de dados utilizados para a construção do modelo de inferência.	41
Tabela 4.2: Variáveis de entrada possíveis para o modelo de inferência.	42
Tabela 4.3: Variáveis de entradas escolhidas para o conjunto de dados.	44
Tabela 4.4: Relação entre o desempenho da rede neural e número de neurônios para o conjunto de dados.	46
Tabela 4.5: Variáveis de entradas utilizadas para a geração do modelo de inferência “teste”.	47
Tabela 4.6: Relação entre o desempenho da rede neural e número de neurônios para geração do modelo de inferência “teste”.....	47
Tabela 4.7: Desempenho dos métodos PLS e QPLS.....	48
Tabela 4.8: Valores dos parâmetros b_t e τ/τ_d utilizados para a obtenção das diferentes malhas de controle.	51
Tabela 4.9: Conjunto de plantas de 1ª ordem utilizadas para os casos de estudo desenvolvidos nesta seção.	51
Tabela 4.10: Valores da constante de tempo integral (τ_i) e dos ganhos proporcionais para antes (K_p1) e depois (K_p2) do ajuste nas malhas de controle.	52
Tabela 4.11: Valores calculados pelo Modelo de Inferência para Desempenho e Robustez.	52
Tabela 4.12: Valores de V_A preditos em comparação com os valores de V_A teóricos.....	53
Tabela 4.13: Intervalo dos parâmetros RtR1 e RtR2 utilizados para a análise de sensibilidade.	54
Tabela 4.14: Intervalo dos parâmetros τ e θ utilizados para a análise de sensibilidade. ...	55
Tabela 4.15: Conjunto de plantas de 2ª ordem com resposta subamortecida utilizadas para o caso de estudo 1.....	59
Tabela 4.16: Valores calculados pelo Modelo de Inferência para Desempenho e Robustez para o caso de estudo 1.....	61
Tabela 4.17: Valores de V_A preditos em comparação com os valores de V_A teóricos para o caso de estudo 1.....	61
Tabela 4.18: Intervalo dos parâmetros RtR1 e RtR2 utilizados para a análise de sensibilidade para o caso de estudo 1.....	62
Tabela 4.19: Intervalo dos parâmetros τ e θ utilizados para a análise de sensibilidade para o caso de estudo 1.....	63
Tabela 4.20: Conjunto de plantas de 2ª ordem com resposta superamortecida utilizadas para o caso de estudo 2.....	64
Tabela 4.21: Valores dos parâmetros b_t e τ/τ_d utilizados para a obtenção das duas malhas de controle do caso de estudo 2.....	65
Tabela 4.22: Valores calculados pelo Modelo de Inferência para Desempenho e Robustez para o caso de estudo 2.....	66
Tabela 4.23: Valores de V_A preditos em comparação com os valores de V_A teóricos.....	66
Tabela 4.24: Intervalo dos parâmetros RtR1 e RtR2 utilizados para a análise de sensibilidade para o caso de estudo 2.....	66
Tabela 4.25: Intervalo dos parâmetros τ e θ utilizados para a análise de sensibilidade para o caso de estudo 2.....	67
Tabela 4.26: Conjunto de plantas de 2ª ordem com resposta inversa utilizadas para o caso de estudo 3.....	69

Tabela 4.27: Valores calculados pelo Modelo de Inferência para Desempenho e Robustez para o caso de estudo 3.	70
Tabela 4.28: Valores de V_A preditos em comparação com os valores de V_A teóricos para o caso de estudo 3.	70
Tabela 4.29: Intervalo dos parâmetros $RtR1$ e $RtR2$ utilizados para a análise de sensibilidade para o caso de estudo 3.	70
Tabela 4.30: Intervalo dos parâmetros τ e θ utilizados para a análise de sensibilidade para o caso de estudo 3.	71
Tabela 5.2: Principais índices de desempenho para a malha de controle de nível do fundo da torre de <i>stripping</i> , LIC01, antes e depois da alteração dos parâmetros de sintonia.	86
Tabela 5.3: Principais índices de desempenho para a malha de vazão de vapor, FIC03, antes e depois da alteração dos parâmetros de sintonia.	89
Tabela 5.4: Principais índices de desempenho para a malha de composição, antes e depois da alteração dos parâmetros de sintonia.	92
Tabela 5.5: Principais índices de desempenho para a malha de controle de temperatura do reator, antes e depois da alteração dos parâmetros de sintonia.	96

Simbologia e Nomenclatura

Lista de Variáveis

a_t	Sinal randômico
AcorSI	Índice baseado na inclinação da curva da autocorrelação
AcorAR	Índice baseado na soma das áreas das curvas que excedem o intervalo de confiança da função de autocorrelação
b_t	Intensidade do ruído branco
CV_{AR}	Área da curva da variável controlada
CV_{∞}	Valor da variável controlada após o processo estar operando no novo ponto de operação
D	Ganho monetário por unidade de tempo
$e(t)$	Erro entre o valor do <i>setpoint</i> (<i>SP</i>) e o valor da variável de processo (<i>PV</i>)
$erf\{z\}$	Função de erro da Gaussiana
f	Distribuição de frequência
G_w	Função de transferência referente ao ruído branco
G_p	Função de transferência referente ao processo
G_c	Função de transferência referente ao controlador
J	Número imaginário = $\sqrt{-1}$
K	Ganho estático
K_C	Ganho proporcional do controlador
MV_{AR}	Área da curva da variável manipulada
MV_{∞}	Valor da variável manipulada após o processo estar operando no novo ponto de operação
t_0	Tempo de duplicação
w_k, w_{k-1}	Ruído branco
w_i	Peso sináptico
x	Variável do processo (por exemplo: vazão, temperatura, pressão, etc.)
x_1	Limite inferior da variável x
x_2	Limite superior da variável x
x_l	Limite especificado para a variável x
x_m	Ponto ótimo operacional

\bar{x}	Média amostral da variável x
\bar{x}_c	Média amostral da variável x após o projeto de controle
\bar{x}_{OPT}	Média amostral ótima da variável x
y_o / r	Valor da variável de referência (<i>setpoint</i>)
y_t	Valor da variável controlada
y_p	Saída do modelo
Δ	Variável desvio (delta)
Ψ_i	Coefficientes do modelo resposta ao impulso
Ψ	Índice de lucratividade
β	Posição do zero do sistema
$\eta(d)$	Índice de Harris
θ	Tempo morto
$\kappa(d)$	Índice de Harris complementar
μ	Pólo do controlador
ζ	Fator de amortecimento
σ	Desvio padrão amostral
σ_c	Desvio padrão amostral da variável x após o projeto de controle
σ^2	Variância amostral
σ_1^2	Variância apresentada pela malha de controle antes das melhorias realizadas
σ_2^2	Variância apresentada pela malha de controle depois das melhorias realizadas
σ_p^2	Variância amostral do processo
σ_{mv}^2	Variância mínima
σ_w^2	Variância do ruído branco
τ	Constante de tempo
τ/τ_d	Razão entre a constante de tempo da planta e a constante de tempo da perturbação
τ_i	Constante de tempo integral
v	Fração dos dados que violam o limite especificado
ω	Frequência
ω_u	Frequência definitiva

ω_c	Frequência de corte
$\vartheta(x)$	Função de desempenho
ϑ_{quad}	Função de desempenho quadrática
ϑ_{lin}	Função de desempenho linear
ϑ_{cliff}	Função de desempenho <i>cliff</i>
ϑ_m	Lucro máximo atingível

Lista de Abreviaturas

ARMA	Modelo auto-regressivo de média móvel
CV	Variável controlada
DCS	<i>Distributed Control Systems</i> Sistemas de Controle Distribuídos
deli	Índice de tempo morto <i>Delay time index</i>
ETI	ExpertTune Index
FCOR	Abordagem baseada em filtragem e correlação para o cálculo da variância mínima
ISE	Integral do erro quadrático
IAE	Integral do erro absoluto
IAE _{OPT}	Valor ótimo da Integral do erro absoluto
IMC	Controlador por modelo interno
IM	Modelo de Inferência <i>Inferential Model</i>
MNN	Rede Neural Multicamada
MIV	Modelo de Inferência de Variabilidade
MV	Variável manipulada
MS	Máxima sensibilidade
MSE	Erro quadrático médio
MPC	<i>Model Predictive Control</i>
MG	Margem de ganho
nosi	Índice de ruído <i>Noise portion of the signal</i>
PO	Período de oscilação
PV	Variável de processo
PID	Controlador com ação proporcional, integral e derivativa
PI	Controlador com ação proporcional e integral

PLS	Mínimos quadrados parciais
QPLS	Mínimos quadrados parciais quadráticos
RF	Reserva de Fase
RMSE	Raiz do erro quadrático médio
RN	Rede Neural
R_{xx}	Função de autocorrelação
R_t	Tempo de subida <i>Rise time</i>
RtR	Razão entre o tempo de subida do sistema em malha aberta e fechada
SISO	Sistema monovariável (<i>Single-Input-Single-Output</i>)
SP	Valor do <i>setpoint</i>
S_t	Tempo de assentamento <i>Settling time</i>
SO	<i>Overshoot</i>
StR	Razão entre o tempo de assentamento do sistema em malha aberta e fechada
tuni	Índice de ajuste <i>Tuning index</i>
V_A	Alteração de Variabilidade

Capítulo 1

Introdução

1.1 Auditoria de malhas de controle

Uma das maiores preocupações dos processos produtivos atuais relaciona-se à qualidade de seu produto final, envolvendo aspectos ambientais e de segurança. Para atingir tais objetivos, fica claro que se deve monitorar constantemente o comportamento de cada variável, principalmente aquelas que possuam maior impacto na qualidade do produto. Assim, se as malhas de controle operam bem, as chances de o processo se manter dentro das especificações são consideravelmente maiores.

Falar em auditoria de malhas significa fazer esse monitoramento constante, através da avaliação de uma propriedade específica do controlador que reflita o seu desempenho. Atualmente, o termo auditoria de malhas de controle possui um sentido mais amplo, não se resume apenas a detectar quando o desempenho de um controlador em operação desvia-se do seu desempenho desejado. Atualmente, diagnosticar perturbações na planta inteira, apontar a causa raiz da perturbação, avaliar a saúde da válvula de controle, quantificar o impacto econômico de cada controlador são possíveis de forma automática, sem a necessidade de testes invasivos, e constituem-se de novas ferramentas que permitem identificar de forma mais eficiente os possíveis pontos de melhoria e direcionar para ações corretivas que possam levar a um aumento da rentabilidade do processo (Farenzena, 2008).

1.2 Quais os benefícios em se auditar malhas de controle?

“O objetivo primário de um sistema de controle aplicado em uma indústria de processos é maximizar lucros pela transformação de matérias-primas em produtos, enquanto satisfaz critérios tais como

segurança, regulamentações ambientais, especificação de produtos e restrições operacionais.”

Craig e Henning (2000)

Um sistema de controle confiável permite operar próximos aos limites impostos pela segurança, pelo meio-ambiente e pelo processo, o que permite alterar as condições da planta industrial para regiões operacionais favoráveis. A Figura 1.1 mostra o efeito da redução da variabilidade em uma variável de processo. Em malhas de controle, a variabilidade pode advir de oscilações normalmente causadas por agarramento ou histerese em válvulas, má sintonia, ruídos de medição, perturbações e não-linearidades do processo (Oliveira *et al.*, 2007), entre outros fatores.

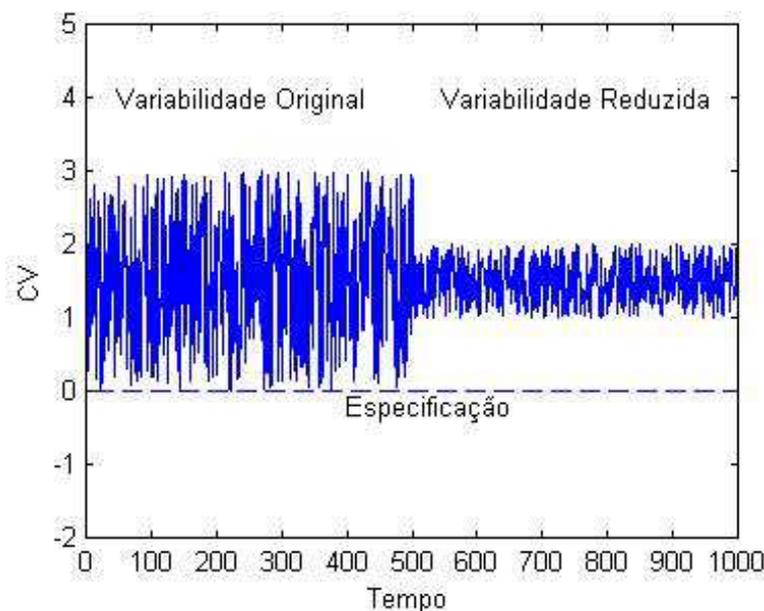


Figura 1.1: Ilustração da redução de variabilidade em uma variável de processo (Retirado de Farenzena e Trierweiler, 2007b).

Diminuir a variabilidade do processo tornou-se um dos principais caminhos para quantificar os benefícios potenciais da melhoria do controle de processos, ou seja, com maior confiabilidade dos resultados é possível trabalhar em uma região próxima ao ponto de operação ótimo, o que se converte em ganho. Autores, tais como: Bozenhardt e Dybeck (1986); Friedmann (1995); Lababidi *et al.* (2002); Canney (2003); White (2004); Edgar (2004); Brisk (2004) e Bauer e Craig (2008), discutem de que forma se materializa esse ganho, sendo possível, dentre outros:

- aumento da capacidade de produção da unidade: um dos mais importantes benefícios em termos de retorno financeiro, ou seja, tal aumento, mesmo que

em pequenas proporções e não sendo limitado pela capacidade produtiva da planta, irá ser transformado em um benefício econômico anual. Além disso, tem-se a possibilidade de se aumentar a taxa de produção de produtos mais rentáveis em detrimento aos demais. Uma pesquisa realizada por Bauer e Craig (2008) aponta que o aumento da capacidade de produção é estimado entre 5% e 10%;

- redução do consumo de energia;
- decréscimo de produtos fora de especificação: evita-se retrabalho, mistura de produtos fora de especificação, descarte de produtos ou venda de produtos por preço reduzido. Uma vez que o retrabalho aumenta o *lead time* do processo, ou seja, o tempo de produção, tem-se que uma diminuição do retrabalho implica na diminuição do tempo de produção;
- redução do tempo de transição entre produtos: contribui para a redução da produção de produtos fora de especificação;
- melhoria na operabilidade: aqui se inclui um aumento da eficiência operacional, uma extensão da vida útil dos equipamentos que contribui com a diminuição de paradas desnecessárias e, o mais importante, uma melhora na estabilidade do processo que é reflexo do baixo desvio-padrão apresentado pelas variáveis principais, fruto da capacidade do controle de rejeitar perturbações do processo. A maior estabilidade do processo assegura que as especificações do produto sejam melhor atendidas;
- aumento da segurança operacional e redução do impacto ao meio ambiente: resultado de uma operação mais estável, que permite uma redução de condições problemáticas de operação e também permite uma redução de emissões indesejáveis ao meio ambiente;
- aumento da sustentabilidade do processo: condição assegurada pelo uso mais eficiente das matérias-primas, pelo menor uso de energia e pela menor emissão de poluentes;
- melhoria na qualidade final do produto: a variabilidade e a qualidade dos produtos são inversamente proporcionais, implicando que a melhoria de qualidade consiste na redução da variabilidade dos processos e produtos.

Além da redução da variabilidade faz-se necessária uma mudança da condição operacional, conforme ilustrado na Figura 1.2, a fim de atingir os benefícios acima citados de uma forma mais eficiente. Uma vez estabelecida esta mudança da condição operacional, é possível calcular os benefícios em termos financeiros.

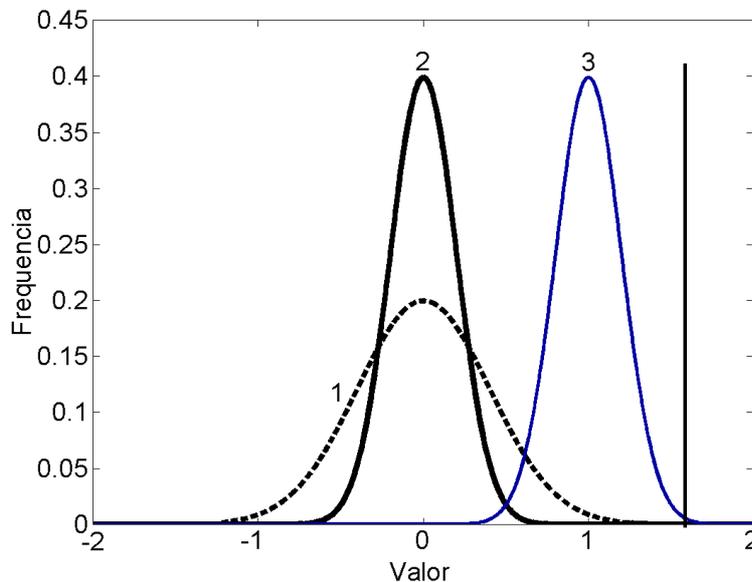


Figura 1.2: Curvas de distribuição da qualidade do produto – Linha 1) Variabilidade original. Linha 2) Variabilidade reduzida. Linha 3) Ponto de operação deslocado para mais próximo da restrição. A restrição está representada pela linha vertical (Retirado de Farenzena e Trierweiler, 2007b).

1.3 Motivação

Em um estudo apresentado por Paulonis e Cox (2003) da Eastman Chemical Company, dos Estados Unidos, do montante de 8500 malhas analisadas em suas plantas, 80% destas, ou seja, 6800 malhas aumentaram a variabilidade do processo devido a problemas de emparelhamento, de instrumentação ou nos parâmetros de ajuste.

Diante desse cenário e tendo em vista a crescente busca por qualidade, custo e disponibilidade de produto, muitas indústrias de processo estão buscando ferramentas que lhes permita operar com máxima qualidade e máxima produtividade. Um dos caminhos para alcançar tal objetivo é o aprimoramento das técnicas de controle utilizadas ou, ainda, a inclusão de outras que permitam reduzir a variabilidade do processo, garantindo assim a qualidade do produto. Estudos demonstram que benefícios significativos no desempenho de um controlador podem ser conseguidos apenas pela ressonância deste (Shah *et al.*, 2005), visto

que cerca de 38% dos casos onde havia o aumento de variabilidade no estudo de Paulonis e Cox (2003) se devia a problemas de sintonia. A avaliação e aprimoramento constante dos sistemas de controle permitem claramente uma conexão com as diretrizes de negócios, ou seja, o muitas vezes conflitante objetivo entre maximização dos lucros e a minimização do impacto ambiental é atingido.

Assim como em outros projetos, é sempre fundamental, para dar suporte às decisões gerenciais que o projeto técnico de controle esteja vinculado com sua viabilidade econômica, ou seja, os benefícios qualitativos precisam ser quantificados em termos econômicos. Nesse sentido, Bauer e Craig (2008) apresentam uma pesquisa na qual cerca de 80% dos entrevistados indicaram que um relatório quantitativo é requerido antes da implementação com o intuito de justificar um investimento, tanto em termos monetários quanto em benefícios. Destes, 75% afirmam que nenhum investimento é feito sem a aprovação, enquanto 25% afirmam que os investimentos em controle abaixo de um limite não requerem nenhuma aprovação. Esse limite reside entre US\$ 5,000 e US\$ 100,000.

Porém, a literatura é relativamente escassa em termos de uma metodologia rápida e precisa de análise de processo que possa ser aplicada para estimar quanto o desempenho pode ser melhorado através das melhorias de controle, ou seja, o quanto uma malha pode ter sua variabilidade alterada e quanto isso gerará em termos financeiros.

Nesse sentido, a presente dissertação busca desenvolver uma metodologia baseada na auditoria de desempenho e robustez para realizar este tipo de análise. Tal metodologia se mostra de grande valia no campo da auditoria de malhas de controle, uma vez que com o uso dessa será possível a realização de um monitoramento constante acerca do potencial de melhora da variabilidade de uma malha.

1.4 Estrutura da Dissertação

Esta dissertação está dividida em seis capítulos. O presente capítulo procurou introduzir o assunto desta dissertação, além de delinear as principais motivações para a realização deste trabalho.

Nos Capítulos 2 e 3, são abordados conceitos pertinentes à auditoria, tanto econômica (Capítulo 2) quanto de desempenho e robustez (Capítulo 3). Ao final do Capítulo 3 é introduzida uma ferramenta auxiliar: o Modelo de Inferência para Desempenho e Robustez.

A metodologia proposta para prever a alteração na variabilidade, a partir da melhora do desempenho do controlador é então apresentada no Capítulo 4, sendo realizada a sua

aplicação em um conjunto de casos de estudo teóricos. Sua utilização também será demonstrada com base em uma aplicação industrial apresentada no Capítulo 5.

No Capítulo 6 têm-se as principais conclusões deste trabalho, além de apresentar as principais contribuições obtidas para a área de controle de processos e sugestões para a realização de trabalhos futuros, que possam dar continuidade ao que foi desenvolvido nesta dissertação.

Para finalizar, foram incluídos dois apêndices que visam complementar os textos desenvolvidos nos capítulos. Conceitos relativos à parte estatística são apresentados no Apêndice A. No Apêndice B, são apresentados conceitos relativos a redes neurais.

Capítulo 2

Auditoria Econômica

Visto que uma das funções primordiais do controle de processos é gerenciar variabilidades, é preciso entender a conexão entre variabilidade do processo e objetivos do negócio, para que se possa fazer melhor uso dessa ferramenta (Shunta, 1995). Assim, considerando que é possível calcular a variabilidade e que melhorias e/ou implementação de técnicas de controle poderão reduzi-la, a pergunta proposta é: como a redução da variabilidade afetará à economia do processo? Ou ainda: como traduzir esse potencial de melhora em termos econômicos?

Com o intuito de responder a essas perguntas, neste capítulo é apresentada uma revisão das principais metodologias encontradas na literatura que objetivam quantificar o potencial de redução de variabilidade de uma dada malha e sua conexão com os objetivos econômicos operacionais.

2.1 Histórico

De forma geral, os benefícios apresentados por uma dada ferramenta devem ser concordantes com as chamadas diretrizes de rentabilidade econômica da empresa - necessidades ou objetivos do negócio - uma vez que são elas que direcionam os esforços e melhoramentos na indústria de processos.

Ao longo dos últimos anos essas diretrizes têm mudado drasticamente, e é função do controle de processos assegurar que essas sejam atingidas. Sendo assim, para buscar um

entendimento dos benefícios advindos do emprego de técnicas de controle de processo, faz-se necessário rever alguns conceitos vigentes ao longo das últimas décadas.

No início do século XX, os processos eram controlados manualmente, não se fazendo presente técnicas que pudessem de alguma forma trazer maiores benefícios ao negócio. Somente na década de 50, com o advento do controlador PID aliado à introdução de sistemas de controle assistidos por computador (Faccin, 2004), introduziu-se a discussão acerca do desempenho econômico: quando vale a pena investir em um sistema de controle automático e o que ele trará de benefícios para o processo?

Poucos estudos de caso na década de 50 reportaram a instalações de sucesso e demonstraram benefícios do controle automático, uma vez que o custo de implementação era muito alto, significando assim que os benefícios advindos deveriam justificar o investimento. Dessa forma, e tendo em vista que a diretriz da época era atender apenas às especificações dos clientes não importando para isso o desempenho da planta, não havia o interesse e nem a necessidade de se utilizar técnicas mais avançadas de controle. Contribuiu para tal pensamento também o fato dos insumos e matérias-primas se apresentarem com baixo custo frente ao que se observa nos dias de hoje.

A partir da década de 60, devido ao surgimento dos computadores digitais e sua paulatina inserção na área de controle de processos, começaram a ser desenvolvidas e viabilizadas novas tecnologias de controle, tais como: preditor de Smith, controle preditivo, controle adaptativo, lógica Fuzzy, gain schedule, autoajuste, redes neuronais, controle robusto, controle ótimo, entre outros (Faccin, 2004). Como resultado, Willians (1965) reportou um crescimento linear no número de aplicações de controle de processos em plantas químicas e de petróleo na década de 60. Mesmo assim, o pensamento da época ainda era o de que, se a planta estava gerando um produto satisfatório, para quê alterar a filosofia atual? Apesar dessa resistência da indústria em melhorar o controle de seu processo, diversos estudos acadêmicos foram realizados, demonstrando que era possível atingir patamares de maior qualidade com o uso do controle de processos. Relatos significativos desses avanços podem ser encontrados no trabalho de Edgar (2004).

Na década de 70, os negócios tiveram como foco principal a maximização dos lucros e com isso passou a ser evidente que a maioria dos ganhos diretos poderia vir do emprego de técnicas de controle mais avançadas. Devido ao, ainda, alto custo dos computadores e à falta de demonstração de benefícios, as instalações eram justificadas com base em critérios de retorno de investimento (Edgar, 2004). Tipicamente um período de *payback* de um ano ou menos era requerido para justificar um projeto de controle automático. Nesse contexto,

conforme citado em Harrold (2007), tem-se com a publicação do trabalho de Cutler *et al.* em 1979 – “*Dynamic Matrix Control, a computer control algorithm*” - um dos mais importantes avanços para o controle avançado de processos – a base para o controle preditivo atual (MPC - *Model Predictive Control*).

Durante as décadas de 80 e 90, o efeito da competição global no mercado causou uma busca por qualidade, uma vez que essa passou a afetar diretamente a lucratividade do negócio. O controle de processos passou a ser empregado para assegurar essa qualidade. Também passaram a ser enfocadas pelas indústrias as questões de segurança e ambientais (Edgar, 2004).

A redução nos custos de *hardware* (em face do aumento de velocidade por um fator de 100 em cada década) foi um significativo impulso para adotar o controle automático e avançadas técnicas de controle. O surgimento de pacotes de *software* e arquiteturas padrões também facilitou as aplicações no controle de processos. Os algoritmos de controle baseados na otimização não eram factíveis para computação em tempo real na década de 70, mas durante a década de 80 tais métodos começaram a ser usados devido ao aumento da velocidade de processamento. Além disso, as pesquisas realizadas no meio acadêmico aliadas com o crescente interesse da indústria pelo aumento da produtividade impulsionaram de forma significativa o uso de novos algoritmos de controle.

No começo da década de 90, a globalização começou a aumentar a pressão nas indústrias de processo para reduzir seus custos e aumentar a produtividade. Novas gerações de sistemas de controle distribuídos (DCS) também facilitaram a implementação de novas estratégias de controle. Buscou-se também um uso mais efetivo dos equipamentos além de fazer com que a planta pudesse ser operada da forma mais flexível possível a fim de adaptar-se às exigências do mercado em constante transição (Edgar, 2004).

O desenvolvimento de avaliações econômicas nas décadas de 70 e 80 foi principalmente guiado pelos fornecedores de sistemas de controle como uma motivação para o uso de seus produtos. Já na década de 90, começaram a se reportar estudos para a quantificação dos benefícios potenciais advindos de melhorias do controle de processos, com destaque para o trabalho de Martin *et al.*(1991, 2004), Muske (2003) e mais recentemente por Bauer *et al.*(2007), os quais serão detalhados a seguir. É possível observar que, na maioria desses trabalhos, tem-se a preocupação em se demonstrar que, ao diminuir a variabilidade de variáveis-chave do processo, obtêm-se benefícios financeiros consideráveis.

2.2 Quantificação de Benefícios

Ao se falar em quantificação ou estimativa de benefícios, deve-se fazer uma distinção entre realizar uma quantificação antes ou após – citado nos trabalhos de Craig e Henning (2000); Zanin e Moro (2004) e Bauer e Craig (2008) – da melhoria do sistema de controle. Neste trabalho procurou-se focar na quantificação dos benefícios que poderão advir da melhoria do sistema de controle, uma vez que esta tem papel essencial na aprovação de um novo projeto. Dentre as metodologias utilizadas para a quantificação de tais benefícios podem-se distinguir duas linhas: (a) as mais comumente empregadas são aquelas que utilizam a premissa de redução de variabilidade e posterior mudança do ponto de operação. (b) pode-se ainda fazer uso de funções de desempenho, as quais são funções da variável controlada.

Em um dos primeiros trabalhos que cita a melhoria e/ou implementação das técnicas de controle, Hall (1985) faz uso de análise gráfica de dados históricos para definir os benefícios advindos da melhoria do controle de uma unidade de destilação a vácuo, considerando uma redução de 55% na variabilidade do processo. Esses benefícios se materializam na forma de aumento da produção e diminuição do consumo de energia. Stanton (1990) também enfatiza o uso de uma análise gráfica dos dados históricos, tais como histogramas, para a justificativa de investimentos na área de controle.

Seguindo nesta linha, Bozenhardt e Dybeck (1986) utilizam dados históricos de processo, escolhidos de forma a representar a operação normal do processo sob uma mesma condição operacional, para sugerir uma redução típica de 35% na variabilidade obtida após a implementação de um sistema de controle assistido por computador em face ao controle manual existente.

Os trabalhos desenvolvidos até meados da década de 90 focavam prioritariamente na redução da variabilidade como principal fonte de benefícios. Foi a partir de Martin *et al.* (1991) que passou a se considerar também a posterior mudança do ponto de operação da variável para uma direção mais rentável como fonte inegável de benefícios.

A base para se estimar os benefícios por essa metodologia é a possibilidade de redução da variabilidade de uma variável do processo, estimada em um valor fixo, e posterior mudança do ponto de operação para mais próximo da restrição. Tem-se então, com uma estimativa de quanto a(s) variável (eis) pode(m) ser movida(s), a possibilidade de se converter esse movimento em benefício econômico. Dessa forma, as respostas dos histogramas e das curvas de distribuição dos dados em operação normal, em conjunto com os objetivos econômicos da unidade, são utilizadas para a estimativa dos benefícios econômicos. Em uma

pesquisa realizada por Bauer e Craig (2008), tem-se que a maioria dos projetos de controle avançado são justificados com o uso da metodologia desenvolvida por Martin *et al.* (1991).

Para isso considera-se que o lucro aumenta com a mudança do ponto de operação da variável x :

$$\Delta x = \bar{x}_c - \bar{x} \quad (2.1)$$

Onde \bar{x} é a média da variável x e \bar{x}_c é a média da variável x após o projeto de controle, sendo que Δx é ilustrado na Figura 2.1.

Os valores de Δx obtidos são então multiplicados pelo valor econômico da variável x em questão para que se obtenha o benefício econômico em termos de unidades monetárias. Caso não se tenha um valor monetário diretamente associado a esta variável, deve-se fazer uso de modelos de processo, nos quais é possível se obter uma correlação entre essa variável e alguma outra que tenha um valor monetário associado (Friedmann, 1995).

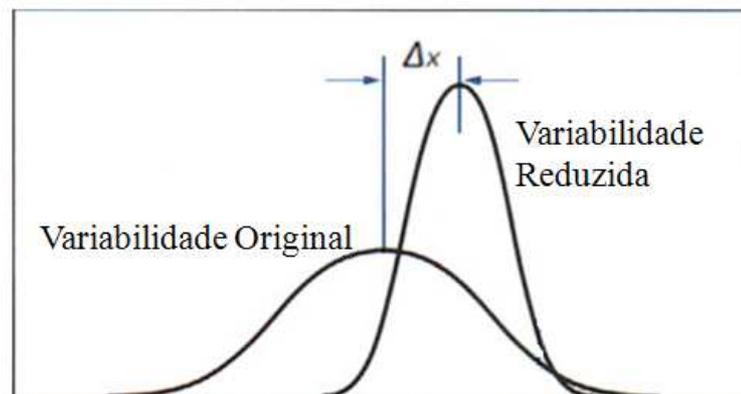


Figura 2.1: Representação de quanto uma variável pode ser movida para o seu ponto de maior rentabilidade, Δx (adaptado de Martin, 2004).

Para a aplicação da metodologia proposta por Martin *et al.* (1991, 2004), deve-se fazer uma análise criteriosa da percentagem dos dados de operação que excedem o limite especificado para cada variável, a qual determinará qual método deverá ser empregado. Assume-se também que, para os três primeiros métodos apresentados a seguir, os dados apresentam distribuição gaussiana ou normal (ou seja, os dados são independentes, não-correlacionados, e possuem a mesma média e mesmo desvio-padrão) e que o desvio-padrão apresentado pelo processo após o projeto de controle, σ_c , é 50% do desvio-padrão apresentado pelos dados históricos, σ , ou seja, $\sigma_c = \sigma/2$. Tem-se ainda que a probabilidade de que $m\%$ dos dados fiquem acima do limite especificado para a variável é dado por:

$$x_l = \bar{x} + P(m)\sigma \quad (2.2)$$

Onde:

x_l = limite especificado para a variável. Este limite, também chamado de restrição, pode ser, de acordo com Friedmann (1995), um limite físico (por exemplo, capacidade de uma bomba), econômico (como o preço de uma determinada matéria-prima) ou ainda pode ser um limite imposto por normas regulatórias (por exemplo, a emissão de um dado poluente) e

$P(m)$ = parâmetro estatístico da distribuição normal. Assume-se como sendo igual a 1,65, ou seja, considera-se como aceitável que 5% dos dados irão exceder o limite da variável. Isto pode ser melhor visualizado pela Figura 2.2.

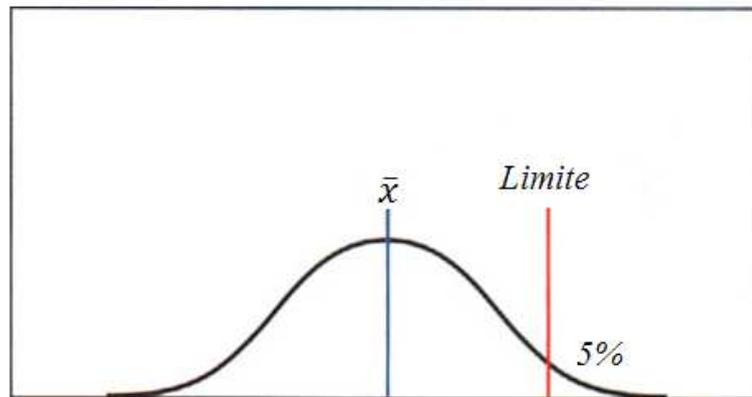


Figura 2.2: Distribuição gaussiana, com 5% dos dados excedendo o limite (adaptado de Martin, 2004).

Método 1 – Regra do igual limite: utilizado quando uma grande percentagem de dados excede o limite especificado para a variável, conforme pode ser visualizado na Figura 2.3a Neste caso, ignora-se tal limite e assume-se que este seja igual a 5% (Figura 2.3b). A regra é então aplicada para se calcular quanto a(s) variável (eis) pode ser movida:

$$x_l - \bar{x} = P(m)\sigma \quad \text{Antes do projeto} \quad (2.3)$$

$$x_l - \bar{x}_c = P(m)\sigma_c \quad \text{Após o projeto} \quad (2.4)$$

Diminuindo-se uma equação da outra e com $\sigma_c = \frac{s}{2}$, tem-se:

$$\Delta x = \frac{\sigma P(m)}{2} \quad (2.5)$$

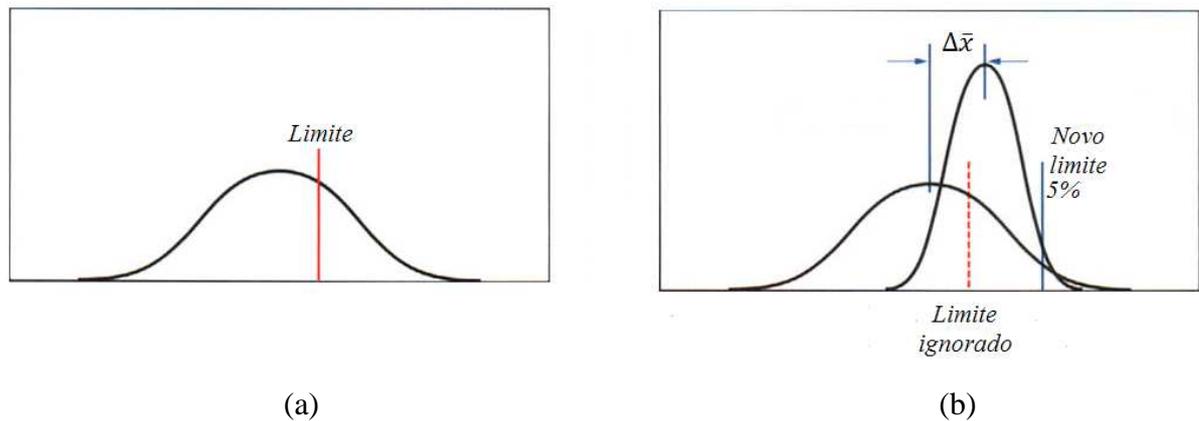


Figura 2.3: (a) Distribuição gaussiana, com uma grande percentagem de dados excedendo o limite. (b) Aplicação da Regra do igual limite (adaptado de Martin, 2004).

Método 2 – Regra da mesma percentagem: se uma percentagem razoável dos dados exceder o limite de especificação da variável (Figura 2.4a), então se assume que após o projeto a mesma percentagem dos dados irá exceder esse mesmo limite (Figura 2.4b). A regra é então aplicada para se calcular quanto a(s) variável (eis) pode(m) ser movida(s):

Sabendo que:

$$\Delta x = P(m)(\sigma - \sigma_c) \quad (2.6)$$

Aplicando-se essa relação na equação (2.2) e, após manipulação algébrica, obtêm-se:

$$\Delta x = \frac{x_l - \bar{x}}{2} \quad (2.7)$$

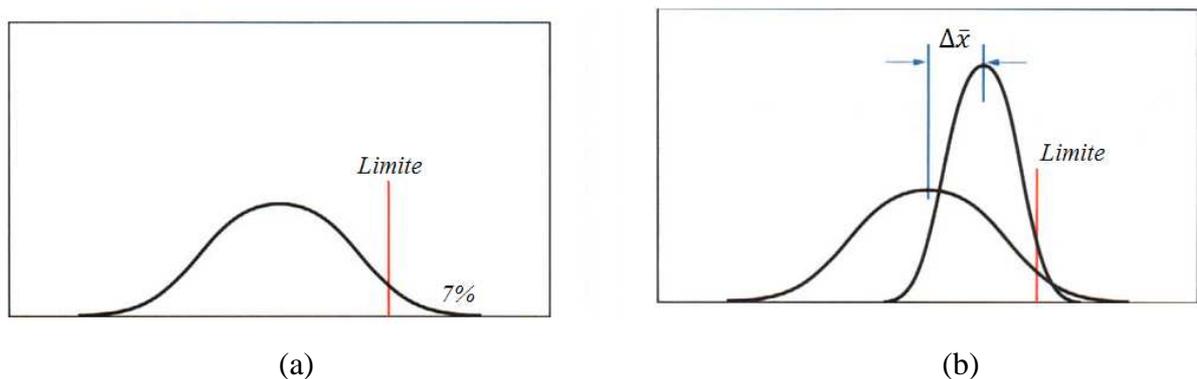


Figura 2.4: (a) Distribuição gaussiana, com uma percentagem razoável dos dados excedendo o limite. (b) Aplicação da Regra da mesma percentagem (adaptado de Martin, 2004).

Método 3 – Regra da percentagem final: utilizada quando não existem muitos dados violando o limite especificado (Figura 2.5). Neste caso, isolando \bar{x}_c da equação (2.1) e aplicando na equação (2.4), obtém-se:

$$\Delta x = \left(\bar{x} + \frac{1,65\sigma}{2} \right) \quad (2.8)$$

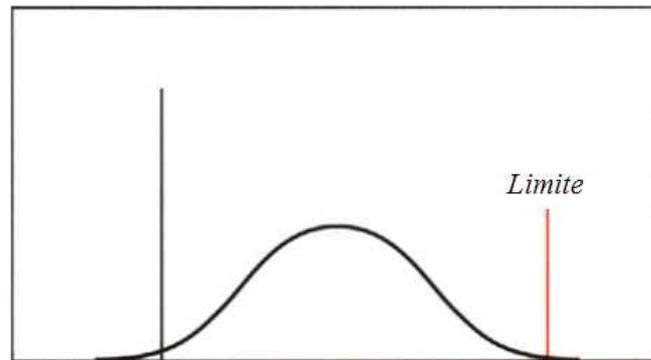


Figura 2.5: Distribuição gaussiana, com poucos dados violando o limite especificado (adaptado de Martin, 2004).

Método 4 – Regra da operação atingível: usada quando uma percentagem significativa dos dados está no limite, como pode ser mais bem visualizado pela Figura 2.6a. Convém ressaltar que esta regra ignora a distribuição estatística dos dados, mas aceita que, se a operação pode ser mantida em torno desse limite, esse passará a ser a nova restrição da variável, ou seja, a variável pode ser movida para este limite (Figura 2.6b). Dessa forma:

$$\Delta x = x_l - \bar{x} \quad (2.9)$$

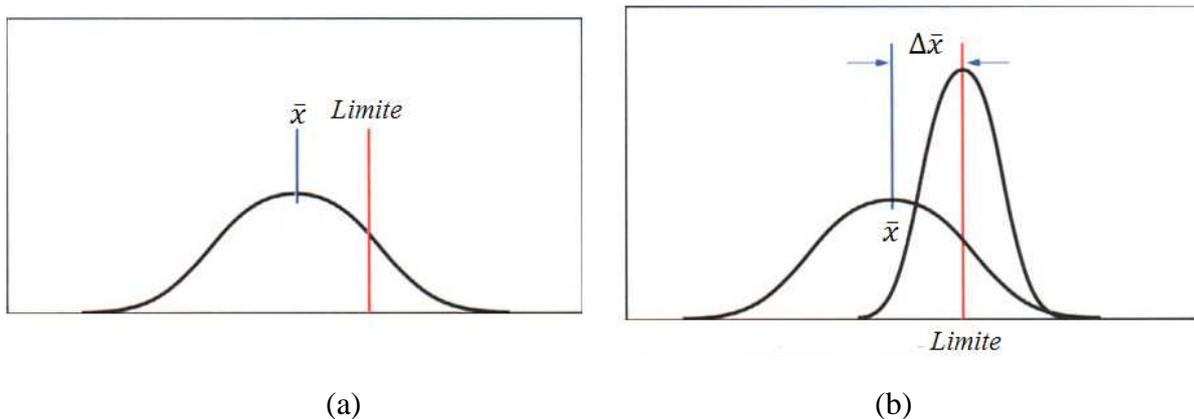


Figura 2.6: (a) Distribuição gaussiana, com uma percentagem significativa dos dados no limite (b) Aplicação da Regra da operação atingível (adaptado de Martin, 2004).

Esta regra difere da apresentada no Método 1, uma vez que nesta a operação pode ser mantida em torno do limite por períodos significantes de tempo, enquanto que naquela isto já não é possível, uma vez que pode comprometer a qualidade do processo. Deve-se então ter o cuidado de ser feita uma análise prévia para identificar a viabilidade de se manter a operação em torno de certo limite de especificação da variável.

Todas as metodologias descritas acima assumem uma redução na variância ou no desvio-padrão em valores fixos. A mais comum consideração é de uma redução no desvio-padrão da variável controlada de 50% (Martin *et al.*, 1991 e 2004; Latour, 1976 e 1996). Em outros trabalhos, assume-se uma redução na ordem de 35% (Bozenhardt e Dybeck, 1986), de 50-66% (Stout e Cline, 1976 e Hall, 1985), de 85% (Stout, 1960) ou até mesmo de 90% (Tolfo, 1983 e Latour *et al.*, 1986).

A consideração de uma redução na variabilidade por um fator fixo constitui-se em uma medida que deve ser aplicada com certo cuidado, uma vez que a redução estimada pode não ser representativa da melhoria efetivamente alcançável e, na pior hipótese, pode não ser fisicamente possível. Além disso, a redução da variabilidade irá depender do processo, do sistema de controle vigente e do sistema de controle a ser implementado. De acordo com Canney (2005), o grande perigo ao se estimar benefícios é extrapolá-los os mesmos de uma planta para outra a qual possui diretrizes de negócios e condições operacionais substancialmente diferentes, além é claro de equipes de operadores diferentes.

Visando atingir uma medida mais objetiva, diversos autores propuseram metodologias para se estimar a redução na variabilidade. Dentre esses trabalhos, pode-se citar o de Muske (2003). Esse autor propõe uma metodologia que tem como padrão a variância mínima, que, de acordo com Bauer *et al.* (2007), trata-se da variância que é causada por um distúrbio externo que não pode ser eliminado pelo controlador. Åström (1970) apresentou no seu livro *Introdução à Teoria de Controle Estocástico* as formulações para a predição ótima de processos estacionários lineares discretos, da qual a teoria de controle de variância mínima é derivada. Parte-se do princípio de que a variância do sistema é a soma da variância gerada pela ação de controle, a variância ocasionada pelo ruído de medição (pois o controlador é incapaz de eliminar esta perturbação aleatória) e pela não atuação do controlador devido ao tempo morto. A variância que tem como origem o ruído e a não atuação do controlador é considerada invariante e denominada como variância mínima.

No trabalho de Muske (2003) tem-se que este ruído de medição (ou perturbação aleatória) é modelado como sendo um ruído gaussiano, ou ruído branco, w_k , caracterizado por possuir média zero e variância σ_w^2 ajustado por meio de um modelo ARIMA G_w . Dessa

forma, a função de transferência em malha fechada com a variável de processo x como entrada e o ruído branco como saída pode ser representada por um modelo resposta ao impulso, tal como pode ser visualizado na equação (2.10) e cuja representação é ilustrada na Figura 2.7:

$$x = \frac{G_w(z^{-1})}{1 + G_p(z^{-1})G_c(z^{-1})} w_k = \sum_{i=0}^{\infty} \Psi_i w_{k-1} \quad (2.10)$$

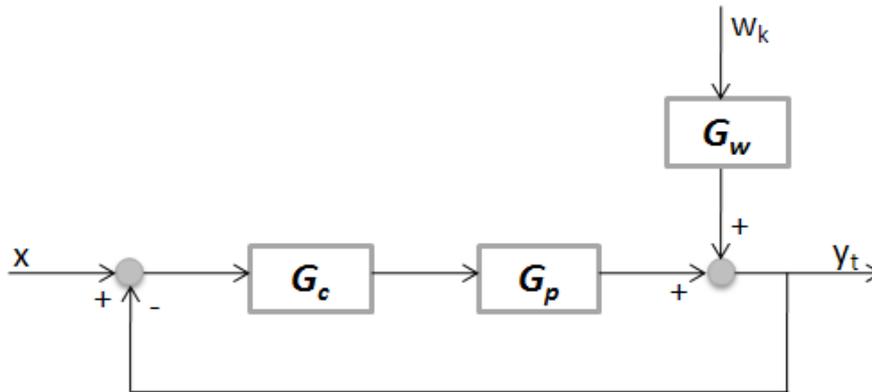


Figura 2.7: Representação esquemática da malha *feedback* padrão.

Onde G_p é o modelo do processo, G_c é a função de transferência referente ao controlador e G_w é a função de transferência referente ao ruído branco. Neste caso, Ψ_i são os coeficientes do modelo resposta ao impulso. Uma estimativa da redução da variabilidade do processo teoricamente possível pode ser obtida pela equação (2.11).

$$\begin{aligned} \Delta\sigma_{mv}^2 &= \sigma_{mv}^2 - \sigma_p^2 \\ \sigma_{mv}^2 &= \left(1 + \sum_{i=1}^{d-1} \Psi_i^2\right) \sigma_w^2 \end{aligned} \quad (2.11)$$

Onde σ_{mv}^2 é a variância mínima estimada e σ_p^2 a variância do processo, estimada a partir de dados históricos do processo, conforme métodos de cálculo apresentados no Apêndice A.

Para a estimativa da redução efetiva de variabilidade do processo devido a melhorias no controle, $\Delta\sigma_p^2$, tendo como base a variância mínima, Muske (2003) apresenta metodologias que são dependentes da forma do controlador escolhido para representar a melhora no controle da operação. Nesse sentido, apresentam-se metodologias para quando diferentes técnicas de controle são utilizadas, tais como controlador por modelo interno (IMC), controladores PID ou ainda controladores *feedforward*. Para o caso de controladores PID, por

exemplo, tem-se que o pólo diferente de zero da malha fechada irá determinar a resposta do sistema. Dessa forma, a estimativa da redução efetiva de variabilidade do processo devido a melhorias no controle, $\Delta\sigma_p^2$, tendo como base a variância mínima, dá-se pelo uso da equação (2.12).

$$\Delta\sigma_p^2 = \sigma_\mu^2 - \sigma_p^2 = \Delta\sigma_{mv}^2 + \Psi_{d-1}^2 \left(\frac{\mu^2}{1-\mu^2} \right) \sigma_w^2 \quad (2.12)$$

Onde μ é o pólo, diferente de zero, que determina a resposta do sistema em malha fechada. Esse valor pode ser escolhido com base na resposta desejada para o sistema, que é geralmente definida como uma fração da resposta do sistema em malha aberta.

Outros detalhes sobre essas metodologias podem ser vistos no próprio trabalho de Muske (2003).

Além da estimativa da redução da variabilidade que pode ser obtida com melhorias no sistema de controle, tem-se ainda a posterior alteração no ponto de operação. Muske (2003) parte da equação (2.1), proposta por Martin *et al.* (1991), porém com \bar{x}_c sendo definido pela equação (2.13):

$$\bar{x}_c = x_l - \alpha \sqrt{\sigma^2 + \Delta\sigma_p^2} \quad (2.13)$$

Nessa equação o fator α é estimado a partir de v , que representa a fração dos dados que violam o limite especificado. O valor de v pode ser calculado diretamente dos dados históricos.

Convém ressaltar que no trabalho de Muske (2003) encontra-se a primeira referência a métodos de estimativa da variância mínima quando se utilizam controladores multivariáveis. Para esses, Muske (2003) afirma que a estimativa de redução de variabilidade constitui-se de um desafio significativo como resultado da falta de uma estrutura de controle já existente, uma vez que esta é determinada em uma etapa posterior. Ou seja, as informações necessárias para se proceder a uma estimativa de benefícios requerem, para a metodologia abordada por Muske (2003), uma estrutura de controle definida, ou mais precisamente de um controlador operando em malha fechada de forma a permitir que os dados operacionais possam ser obtidos. Somente assim é possível que um modelo ARIMA possa ser identificado e a partir deste, se estimar os parâmetros requeridos pelo método. Para muitos casos, entretanto, a análise dos benefícios de controladores multivariáveis pode ser baseada em estimativas de redução da variabilidade para sistemas SISO, não sendo necessária, portanto, a determinação

da estrutura de controle multivariável como etapa determinante. Porém isso só é possível quando houver garantias de que o controle multivariável não será mal-condicionado ou altamente acoplado.

Jain (2006), baseado na metodologia proposta por Muske (2003), propõe o Indicador de Desempenho Econômico (*EPI*, do inglês *Economic Performance Indicator*), baseado no controlador de variância mínima. Esse índice pode ser estimado a partir do uso da equação (2.14), que representa a diferença entre a média da variável $x(\bar{x})$ e a média ótima (\bar{x}_{OPT}), obtida do controlador de variância mínima.

$$EPI = D(\bar{x} - \bar{x}_{OPT}) \quad (2.14)$$

Onde D traduz a mudança de estratégia de controle em \$ por unidade de tempo, podendo ser quantificado como uma função do aumento de produção da planta, da redução no consumo de utilidades, etc.

Outra forma de quantificar os benefícios advindos através da melhoria do controle do processo é por meio da chamada função de desempenho $\vartheta(x)$, que é função da variável controlada x . Essa metodologia foi introduzida por Stout e Cline (1976) e por Latour (1976). A partir desses trabalhos, a função de desempenho foi aprimorada por Martin *et al.* (1991), Latour (1992 e 1996) e Bauer *et al.* (2007). Nesses trabalhos apresentam-se três importantes funções de desempenho comumente utilizadas que serão brevemente discutidas a seguir.

- 1) Função de desempenho quadrática: também referida por Martin *et al.* (1991) como a Regra da Curvatura. Essa regra baseia-se na consideração de que uma medida significativa do lucro do processo, ϑ_{quad} , pode ser descrita como uma função polinomial de segunda ou terceira ordem da variável x . No caso da função de desempenho quadrática descrita pela equação (2.15), x_m é o ponto de operação ótimo, no qual a função de desempenho atinge seu valor máximo ϑ_m , conforme ilustrado na Figura 2.7a.

$$\vartheta_{quad}(x) = \begin{cases} \vartheta_m \left[1 - \left(\frac{x - x_m}{x_1} \right)^2 \right] & x_m - x_1 \leq x \leq x_m + x_1 \\ 0 & x > x_m + x_1, x < x_m - x_1 \end{cases} \quad (2.15)$$

Onde ϑ_m é o lucro máximo que pode ser obtido e $x_m \pm x_1$ representa o limite abaixo do qual o lucro é igual a zero, sendo x_1 o limite abaixo do qual a função de desempenho torna-se igual a zero.

- 2) Função de desempenho linear, com restrições: introduzida por Latour (1976), tem-se que o lucro pode comumente se comportar como uma relação linear, conforme ilustrado na Figura 2.7b. O desempenho aumenta linearmente de um ponto x_1 até um limite x_2 o qual, se excedido, torna o produto fora de especificação e o lucro zero. A função de desempenho linear com restrições pode ser descrita pela equação (2.16).

$$\vartheta_{lin}(x) = \begin{cases} \vartheta_m \left(\frac{x_2 - x}{x_2 - x_1} \right) & x_1 \leq x \leq x_2 \\ 0 & x > x_2, x < x_1 \end{cases} \quad (2.16)$$

Onde x_2 é a restrição e x_1 é o limite abaixo do qual a função de desempenho torna-se igual a zero.

- 3) Função de desempenho Clifftent: introduzida por Latour (1996), essa função de desempenho pode ser expressa como a soma de duas variáveis de restrição lineares, $\vartheta_{cliff}(x) = \vartheta_1(x) + \vartheta_2(x)$ sendo essas variáveis descritas da seguinte forma:

$$\begin{aligned} \vartheta_1(x) &= \begin{cases} \vartheta_m \left(\frac{x - x_1}{x_2 - x_1} \right) & x_1 \leq x \leq x_2 \\ 0 & x > x_2, x < x_1 \end{cases} \\ \vartheta_2(x) &= \begin{cases} c \vartheta_m \left(\frac{x_3 - x}{x_3 - x_2} \right) & x_2 \leq x \leq x_3 \\ 0 & x > x_3, x < x_2 \end{cases} \end{aligned} \quad (2.17)$$

Onde x_1 e x_3 são os limites nos quais o lucro é igual a zero e x_2 é o ponto no qual o lucro máximo, ϑ_m , é atingido. Na Figura 2.7c, $\vartheta_c = c \vartheta_m$, onde c é uma constante ($0 \leq c \leq 1$).

Tendo desenvolvido a função de desempenho para o processo a ser estudado, é possível estimar o benefício esperado, Ψ . Isso se dá por meio da integração da função de desempenho da seguinte forma:

$$\Psi(s, \bar{x}) = \int_{-\infty}^{+\infty} \vartheta(x) f(x, \sigma, \bar{x}) dx \quad (2.18)$$

Onde $\vartheta(x)$ é a função de desempenho e $f(x, \sigma, \bar{x})$ é a distribuição de frequência (normalmente assume-se como sendo Gaussiana e é estimada por dados do processo). O benefício estimado é, portanto função do desvio-padrão σ , e da média da variável controlada x, \bar{x} .

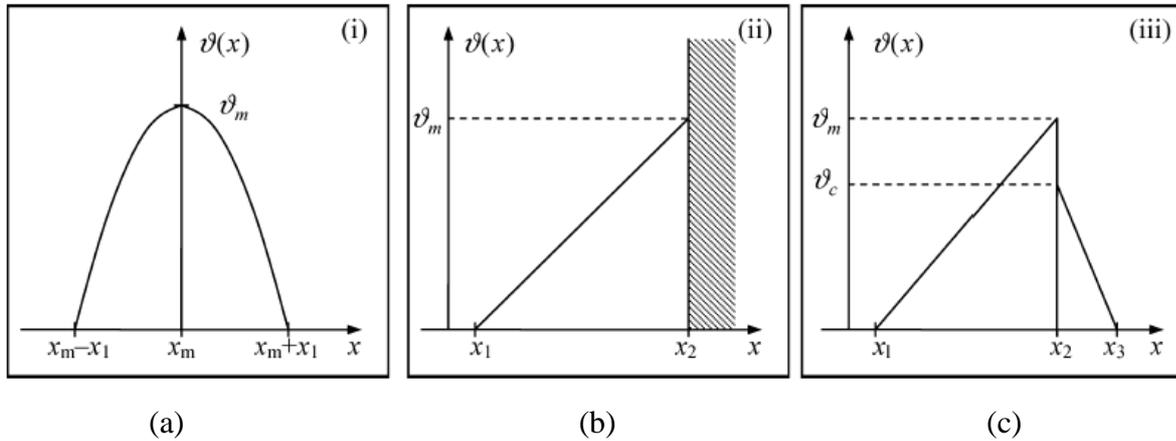


Figura 2.8: (a) Função de desempenho quadrática. (b) Função de desempenho linear, com restrições. (c) Função de desempenho *Cliffrent* (retirado de Bauer *et al.*, 2007).

É possível também estimar o benefício esperado como função somente do desvio-padrão, σ . Para isso, Bauer *et al.* (2007) sugerem que o ponto ótimo operacional (x_m) seja determinado para um dado desvio-padrão tal que $x_m = g(\sigma)$, onde g é uma função inversa. A média da variável controlada é então movida para o ponto ótimo operacional. O benefício esperado (Ψ), também chamado de índice de lucratividade, decresce monotonicamente com σ para a maioria das funções de desempenho, e o índice de lucratividade máximo ocorre para um valor nulo de desvio-padrão. Assumindo-se que os dados seguem uma distribuição gaussiana, e que para essa ser completamente determinada o desvio-padrão e a média devem ser conhecidos, tem-se que a distribuição de frequência f é dada pela equação (2.19), fazendo-se $\bar{x} = x_o$.

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{(x-x_o)^2}{2\sigma^2}\right] \quad (2.19)$$

Dessa forma, por exemplo, para a função de desempenho quadrática, o índice de lucratividade pode ser calculado diretamente pela equação (2.20):

$$\Psi_{quad}(\sigma) = \vartheta_m \left[(1-2z^2) \operatorname{erf}\{z\} + \frac{1}{z\sqrt{\pi}} e^{-z^2} \right] \quad (2.20)$$

Onde $erf\{z\}$ é a função de erro da Gaussiana e $z = \frac{x_1}{\sigma\sqrt{2}}$. O cálculo para as demais funções de desempenho encontra-se mais bem detalhado em Bauer *et al.* (2007).

Apesar de ser bem estudada por esses autores, a função de desempenho é, em muitos casos, difícil de ser obtida, uma vez que requer um extensivo conhecimento do processo em questão e do cenário econômico vigente.

Capítulo 3

Auditoria de Desempenho e Robustez

Assumindo-se diretrizes de negócios tais que busquem o máximo em lucratividade, a auditoria de desempenho e robustez de malhas de controle torna-se ferramenta valiosa para identificar focos de melhoria que contribuam para a redução da variabilidade das variáveis chaves do processo. Essa auditoria baseia-se fundamentalmente na comparação de critérios que são chamados de índices de desempenho e robustez e que consistem em uma série de parâmetros mensuráveis que indicam o quão bom (ou ruim) é o sistema de controle avaliado.

Nesse capítulo é realizada uma revisão dos índices mais comumente utilizados para a avaliação do desempenho e robustez de malhas de controle, suas vantagens e desvantagens. De modo a facilitar o entendimento, os índices de desempenho serão abordados em duas categorias: índices determinísticos e índices não intrusivos.

Complementando este capítulo, é apresentada a metodologia proposta por Farenzena e Trierweiler (2006a), a qual faz uso de um Modelo de Inferência para Desempenho e Robustez, uma formulação alternativa para avaliar o desempenho e robustez de malhas de controle.

3.1 Índices Determinísticos

As técnicas para avaliação de desempenho e robustez quanto as suas características determinísticas baseiam-se na comparação de indicadores tais como tempo de subida, tempo de assentamento, sobre-sinal (*overshoot*) e máxima sensibilidade, entre outros.

A observação dessas características possibilita uma análise simples a respeito da ação do controlador, permitindo a obtenção de um cenário que define claramente o desempenho e a robustez de uma malha de controle.

Entretanto, essas técnicas são intrusivas devido à necessidade de testes em malha aberta, o que resulta em introdução de perturbações no processo, além de necessitarem um grande investimento de engenharia em termos de tempo para o ajuste de uma única malha. Dessa forma, sua implementação *on-line* para monitoramento das malhas de controle em operação torna-se de difícil aplicação.

Para um melhor entendimento, os conceitos relativos a esses indicadores serão explicitados a seguir. Para tanto, os mesmos foram separados em duas categorias: índices de desempenho e índices de robustez.

3.1.1 Índices de desempenho

Diversos critérios baseados na resposta temporal podem ser utilizados para o comissionamento de malhas de controle, como especificações de projeto de controladores, ou para documentar mudanças no desempenho devidas ao ajuste dos parâmetros do controlador ou do processo. Alguns dos critérios mais importantes são ilustrados na Figura 3.1.

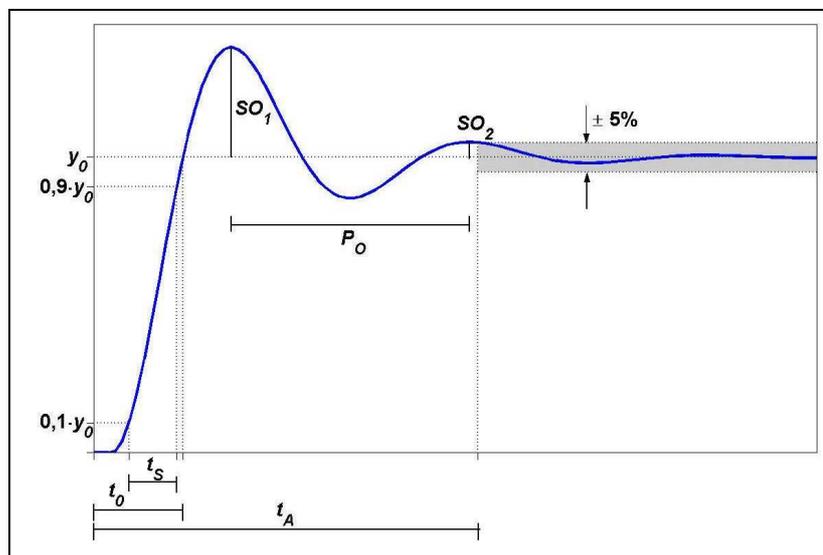


Figura 3.1: Critérios de desempenho baseados na resposta de um sistema subamortecido típico para uma mudança do tipo degrau no valor da variável de referência (Retirado de Faccin, 2004).

Tais índices apresentam as seguintes definições:

- Tempo de assentamento (t_A ou do inglês *settling time* – St): tempo necessário para se ter a resposta no interior de uma faixa percentual de 2 a 5% do valor estacionário. Este tempo está relacionado com a maior constante de tempo do sistema de controle (Mejía *et al.*, 2008). Em outras palavras, é o tempo que o sistema leva, em malha aberta, para atingir um novo estado estacionário a partir de uma perturbação na variável manipulada.
- Tempo de duplicação (t_0): tempo necessário para se ter, pela primeira vez, erro nulo, em resposta à mudança no valor da variável manipulada (D'azzo e Houpis, 1978).
- Tempo de subida (t_s ou do inglês *rise time* - Rt): indicativo de quão rápido reage o sistema. É o tempo em que o sistema leva para passar de 10% até 90% do valor estacionário para respostas frente a uma mudança no valor da variável manipulada (Åström e Hägglund, 1995). Convém ressaltar que esses valores variam de autor para autor.
- Período de oscilação (PO): Período de tempo que depende da característica da resposta de malha fechada. Não é especificado como meta de desempenho do controlador (Mejía *et al.*, 2008).
- *Overshoot* ou Sobrelevação (SO): razão entre o maior pico atingido pela resposta do sistema para mudança no valor da variável de referência e o valor estacionário. Trata-se de uma medida de quanto a resposta de um sistema excede o seu valor final. Não há um valor limite absoluto, dependendo este do objetivo da malha de controle (característica servo ou regulatória); em alguns sistemas nenhuma sobrelevação é desejada, mas uma recomendação comumente empregada é $SO < 20\%$ (Bazanella e Silva Jr., 1999).

$$SO = \frac{SO_1}{y_o} \cdot 100\% \quad (3.1)$$

Baseado nesses parâmetros, os seguintes índices podem ser utilizados com o intuito de se avaliar o desempenho de uma malha de controle:

- Razão entre o tempo de subida do sistema em malha aberta e fechada (RtR) e

- Razão entre o tempo de assentamento do sistema em malha aberta e fechada (StR).

Ambos os índices são de fácil compreensão e fornecem uma medida conclusiva acerca do potencial de ganho de uma malha de controle. Esses índices também apresentam a vantagem de serem indicadores de desempenho globais, permitindo a avaliação do comportamento de um controlador em diferentes condições operacionais, além de comparar o desempenho entre diferentes controladores (Farenzena e Trierweiler, 2006a).

A velocidade de uma malha de controle pode ser facilmente avaliada utilizando o RtR:

- valores maiores que 6 indicam desempenho muito rápido;
- valores entre 4 e 6 indicam um desempenho muito bom;
- valores entre 2 e 4 indicam um bom desempenho;
- valores entre 1 e 2 são indicativos de um desempenho razoável e
- valores inferiores a unidade indicam um pobre desempenho.

3.1.2 Índices de robustez

Por robustez de um sistema de controle entende-se a habilidade de uma malha de controle de manter a estabilidade, mesmo quando os parâmetros do processo (ponto de operação) diferem de seus valores nominais. Para se avaliar essa habilidade, os principais índices utilizados são:

- **Máxima sensibilidade (MS)**: é equivalente ao inverso da menor distância da curva de resposta do sistema no diagrama de Nyquist ao ponto crítico -1, conforme pode ser visualizado na Figura 3.2. Quanto menor a distância mínima do ponto -1 que um sistema apresentar, mais suscetível à instabilidade está o sistema. Com isso, tem-se que o valor limite recomendado desse indicativo de robustez é $MS < 2$; sendo que quanto maior esse valor, menos robusto e mais próximo da instabilidade está o sistema (Åström e Hägglund, 1995).

$$MS = \max_{0 \leq \omega < \infty} |S(j.\omega)| \quad (3.2)$$

- **Margem de Ganho (MG):** medida de quanto o sistema suportaria a uma variação no ganho estático, antes de instabilizar. O valor limite recomendado é $MG > 1,7$ (Trierweiler e Posser, 2002).

$$MG = \frac{1}{|G(j.\omega_u)|} \quad (3.3)$$

Sendo o parâmetro ω_u correspondente à frequência ultimativa (equivalente a uma amplitude unitária).

- **Reserva de Fase (RF):** reserva existente para a fase cair abaixo de -180° para um ganho estático unitário. A reserva de fase consiste no maior valor de tempo morto que uma malha de controle pode suportar antes de instabilizar. Em termos práticos, um bom controlador deverá ter no mínimo $RF \geq 30^\circ$ (Bolton, 1995).

$$RF = \pi + \arg(G(j.\omega_c)) \quad (3.4)$$

Sendo o parâmetro ω_c correspondente a frequência de corte (equivalente a uma fase de -180°).

Os índices MG, MS e RF também podem ser facilmente visualizados através do diagrama de Nyquist, conforme mostrado na Figura 3.2.

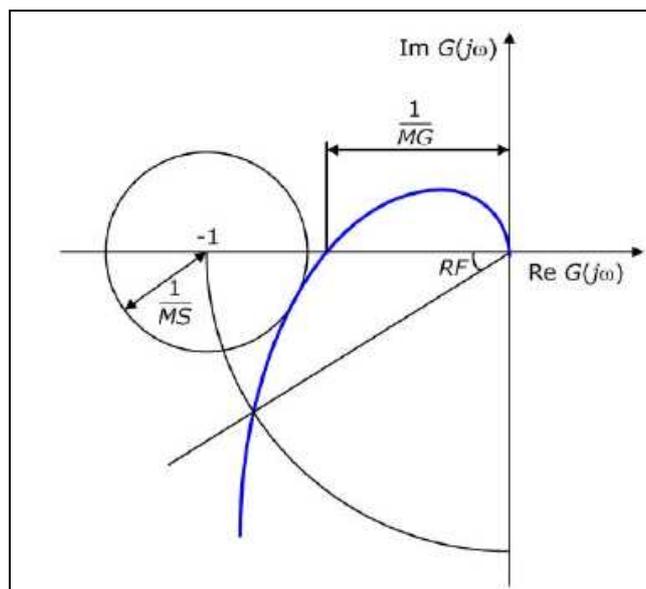


Figura 3.2: Diagrama de Nyquist ilustrando alguns critérios de robustez (Retirado de Faccin, 2004).

3.2 Índices Não Intrusivos

A segunda classe de índices utilizados para a avaliação de desempenho e robustez de malhas de controle faz uso de dados de operação normal do processo e requerem mínimo conhecimento do processo. Estes índices são denominados de não intrusivos e podem ser divididos em duas categorias: índices baseados no controlador de variância mínima e índices baseados na integral do erro.

3.2.1 Índices baseados no controlador de variância mínima

Com a necessidade de se obter índices de forma não invasiva e em tempo real, Harris (1989) propôs um índice que utiliza como padrão referencial o controlador de variância mínima proposto por Åström (1970) para avaliação de desempenho de controladores. Esse índice, conhecido como Índice de Harris tornou-se amplamente difundido, uma vez que como entradas para seu cálculo são necessários apenas dados de operação normal do processo e a estimativa do tempo morto do processo.

O índice de Harris ($\eta(d)$) é definido como o complementar da razão entre a variância mínima do controlador e sua variância atual, conforme pode ser visualizado pela Equação 3.5.

$$\eta(d) = 1 - \frac{\sigma_{mv}^2}{\sigma^2} \quad (3.5)$$

Cabe salientar que também é utilizado o índice complementar $\kappa(d)$:

$$\kappa(d) = \frac{\sigma_{mv}^2}{\sigma^2} \quad (3.6)$$

Onde σ_{mv}^2 é a estimativa da variância mínima teórica e σ^2 é a variância atual do sistema. A variância atual da malha é facilmente estimada utilizando-se dados da variável controlada em sua operação normal. Já para a estimativa da variância mínima deve-se fazer uso de algoritmos, sendo um dos mais difundidos o baseado em filtragem e correlação denominado FCOR (*Filtering and Correlation*), proposto por Huang e Shah (1999).

O algoritmo FCOR necessita de uma janela de dados de operação normal e da estimativa do tempo morto do processo. Além dessas entradas, o algoritmo FCOR, por utilizar um modelo auto-regressivo de média móvel (ARMA) para a modelagem da perturbação, necessita que se determine a ordem do modelo ARMA. Deve-se atentar que não existe um valor padrão para a ordem desse modelo, normalmente para sistemas com um tempo de

amostragem corretamente dimensionado para a dinâmica do sistema, ordens entre 15 e 30 são adequadas para capturar o comportamento do sistema (Kempf, 2003). Um ponto crítico para a aplicação industrial do algoritmo FCOR é a necessidade da estimativa do tempo morto do processo. De uma maneira geral, a estimativa do tempo morto é feita a partir de dados históricos correspondentes a períodos onde o sistema é operado em malha aberta com modificações de posição na abertura da válvula; sendo assim, evitados testes que perturbem o sistema. Também se pode estimar o tempo morto em períodos em que a malha estava fechada durante alterações de *setpoint*, pois o tempo morto da planta em malha aberta e fechada é o mesmo (Lynch e Dumont, 1996 citado em Kayser, 2007). Diversas outras metodologias que se propõem a estimar o tempo morto em malha fechada, tanto no domínio contínuo como no discreto, são propostas na literatura (Huang *et al.*, 1997 e Kamrunnahar *et al.*, 2000), sendo que uma revisão dessas pode ser encontrada em Jelali (2006).

Outros algoritmos para a estimativa da variância mínima podem ser utilizados, tais como o proposto por Desborough e Harris (1992) que propõem o uso de regressão linear simples. É possível encontrar referências substanciais a respeito dos mesmos nos trabalhos de Kempf (2003) e Jelali (2006).

O índice de Harris é limitado no intervalo de valores entre $0 < \eta(d) < 1$. Ao se utilizar a Equação (3.5), quanto mais próximo o índice for da unidade, mais distante está a variância atual da variância mínima e pior é o desempenho do controlador. Ao contrário, ou seja, valores mais próximos de zero indicam que a variância real do processo está próxima da variância mínima, o que caracteriza um controle eficiente (Harris, 1989). Já ao se utilizar a Equação (3.6), o processo é dito sem controle quando o índice complementar for igual a zero.

Os índices que utilizam o controlador de variância mínima como referencial para o desempenho, tal como o índice de Harris, 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 e 2006b) e Kayser (2007) em:

- deterioração quando ocorrem variações de *setpoint*, restringindo a avaliação de desempenho ao controle regulatório;
- não ter um 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, ou seja, na prática o controlador de variância mínima é raramente utilizado devido às suas excessivas ações de controle.

Essas limitações foram discutidas e elucidadas por meio de exemplos industriais em Farenzena e Trierweiler (2006a) e Kayser (2007).

3.2.2 Índices baseados na integral do erro

O desempenho de controladores pode ser quantificado também pela utilização da integral do erro da variável controlada, que pode ser estimada utilizando-se apenas dados de operação normal, sem a necessidade de informação adicional do processo. As desvantagens destas métricas são a dependência com a perturbação aplicada ao sistema e a relação com a ordem de grandeza da variável de processo, o que resulta em um índice não conclusivo e não global, uma vez que a análise só é válida quando se compara uma mesma malha de controle sujeita ao mesmo padrão e intensidade de perturbações e, mesmo nessas situações, seria preciso ter uma referência para poder comparar diferentes desempenhos.

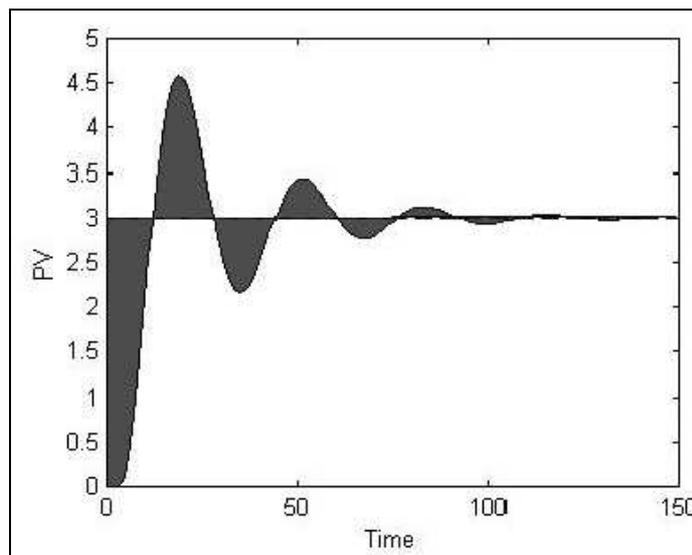


Figura 3.3: Representação da integral do erro.

Os índices mais comumente utilizados baseados na integral do erro (Figura 3.3) são:

- **Integral do Erro Quadrático (ISE):** corresponde à integral do quadrado do valor do erro, conforme Equação 3.7. Segundo Mejía (2008), este índice é adequado para avaliar respostas onde grandes desvios causam uma maior degradação do desempenho quando comparada com pequenos desvios, isto devido ao fato que o indicador proporciona uma maior penalização do sinal do erro.

$$ISE = \int_0^{\infty} e^2(t)dt \quad (3.7)$$

- **Integral do Erro Absoluto (IAE):** corresponde à integral do valor absoluto do sinal do erro no tempo, conforme Equação 3.8. É equivalente à soma das áreas formadas entre a curva da variável de processo e a curva do *setpoint* (Marlin, 1995). Segundo Mejía (2008), este índice é adequado para avaliar respostas não-monotônicas, devido à penalização dos erros persistentes.

$$IAE = \int_0^{\infty} |e(t)|dt \quad (3.8)$$

No caso, $e(t)$ refere-se ao erro entre o valor do *setpoint* (SP) e o valor da variável de processo (PV), ou seja:

$$e(t) = SP - PV \quad (3.9)$$

3.3 Modelo de Inferência para Desempenho e Robustez

Visando sanar algumas das deficiências apresentadas pelas metodologias de auditoria de desempenho e robustez anteriormente descritas, Farenzena e Trierweiler (2006a) propuseram a construção de um modelo de inferência (IM) capaz de gerar índices determinísticos de controladores em malha fechada, de forma não intrusiva e que utilizam como referência o desempenho em malha aberta, onde as entradas são parâmetros facilmente quantificados em tempo real (índices não intrusivos e parâmetros do processo), usando-se somente dados de operação normal.

Os índices gerados pelo IM apresentam as características desejáveis para um índice de desempenho e robustez de malhas de controle, ou seja, os índices gerados pelo IM são:

- globais: a análise dos índices permite a verificação da melhora ou da piora de um dado controlador ao longo da operação, bem como permite a comparação

do desempenho e robustez de diferentes controladores. Isso se deve ao fato de que os índices obtidos por meio do IM não são dependentes do tipo e intensidade das perturbações;

- não intrusivos: para a obtenção dos referidos índices não se fazem necessários testes em planta, o que implica introdução de perturbações no processo, além de ser uma prática que demanda um grande período de tempo.
- fáceis de serem calculados: uma vez que exigem um conhecimento mínimo do processo para a obtenção dos índices.
- conclusivos no que tange à sua interpretação.

3.3.1 Modelo de Inferência

Para a construção do modelo de inferência, um conjunto de plantas foi determinado considerando-se diferentes características, tais como dinâmica, ordem do modelo, pólos e zeros. Um conjunto de controladores Proporcional-Integral (PI) com diferentes desempenhos foi então sintonizado para cada planta, utilizando-se a abordagem multi-modelos proposta por Faccin (2004). Nas plantas, a obtenção dos índices propostos ocorreu a partir de testes invasivos.

Após essa etapa, utilizando os índices medidos em tempo real para variável controlada e manipulada, uma curva que apresenta como resposta os índices propostos pelo IM foi ajustada por diferentes métodos, devendo-se à rede neural de duas camadas (contendo neurônios tipo tangente sigmoidal na camada oculta e neurônios lineares na camada externa) os melhores resultados.

3.3.2 Entradas do IM

O Modelo de Inferência para Desempenho e Robustez tem como entradas, índices comumente utilizados e fáceis de serem obtidos em tempo real, a partir de dados de operação do processo. Convém ressaltar que se podem ter duas situações distintas em que esses dados são apresentados, sendo que para cada uma delas, diferentes índices podem ser quantificados.

- Situação 1: operação na qual se tem variações de *setpoint*.

Para a situação 1, é recomendável utilizar os seguintes índices, computados a partir da área da curva da variável controlada e da variável manipulada, antes e após a alteração no valor do *setpoint*:

$$CV_{AR} = \int_0^{St} (CV - CV_{\infty}) dt \quad (3.10)$$

$$MV_{AR} = \int_0^{St} (MV - MV_{\infty}) dt \quad (3.11)$$

Onde CV_{∞} e MV_{∞} referem-se respectivamente aos valores das variáveis controlada e manipulada após o processo estar operando no novo ponto de operação (dado pela mudança no valor do *setpoint*).

- Situação 2: operação na qual não ocorrem variações de *setpoint*.

Para a Situação 2, os índices não intrusivos previamente definidos (Seção 3.2), ou seja, índice de Harris e índices baseados na integral do erro podem ser quantificados. Pode-se ainda quantificar outros índices, propostos por Farenzena e Trierweiler (2006b e 2007a), que permitem uma avaliação mais clara do desempenho da malha, permitindo ainda a quantificação da influência de componentes tais como tempo morto e ruído branco sobre a variância total do sistema (Figura 3.4). Tais índices partem do princípio de que é possível decompor o sinal de saída de um controlador em três diferentes componentes, a saber:

$$\sigma^2(y) = \sigma_{w_t}^2 + \sigma_{f_t}^2 + \sigma_{g_t}^2 \quad (3.12)$$

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.

A partir dessa decomposição, os seguintes índices podem ser definidos:

- i. Índice de Ruído (*Noise portion of the signal, nosi*): mostra a importância da variabilidade da componente aleatória do sinal, que não pode ser removida pelo controlador. É definido como sendo a relação entre a variância da componente aleatória e a variância total em malha fechada, conforme mostra a equação 3.13.

$$nosi = \frac{\sigma_{w_f}^2}{\sigma_y^2} \quad (3.13)$$

- ii. Índice de Tempo Morto (*Delay time index, deli*): mostra a influência do tempo morto na variabilidade do processo. É definido como sendo a relação entre a variância causada pelo tempo morto e a variância total em malha fechada, conforme mostra a equação 3.14.

$$deli = \frac{\sigma_{f_t}^2}{\sigma_y^2} \quad (3.14)$$

- iii. Índice de Ajuste (*Tuning index, tuni*): mostra a influência da componente que o controlador *feedback* pode atenuar, ou seja, a influência do ajuste do controlador. É definido como sendo a relação entre a variância acessível ao controle *feedback* e a variância total em malha fechada, conforme mostra a equação 3.15.

$$tuni = \frac{\sigma_{g_t}^2}{\sigma_y^2} \quad (3.15)$$

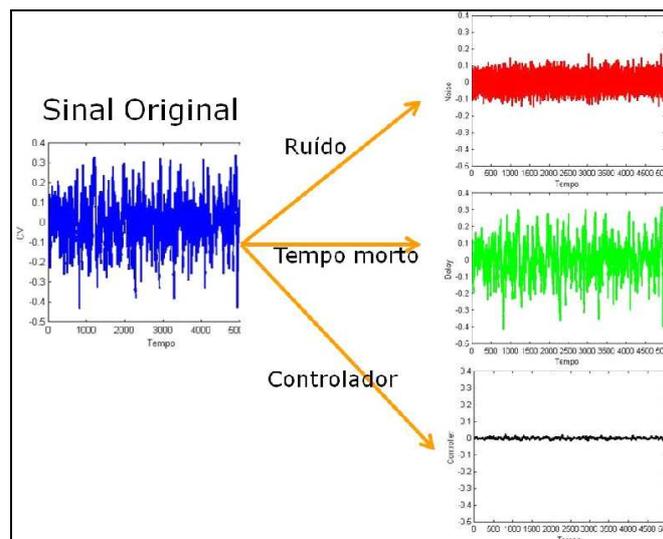


Figura 3.4: Representação esquemática da decomposição do sinal de saída de um controlador (Retirado de Farenzena,2008).

Exemplos de forma de cálculo e aplicação desses índices podem ser encontrados em Farenzena e Trierweiler (2007a) e em Farenzena (2008).

Ainda para a Situação 2, outros conjuntos de índices podem ser definidos tendo como base a função de autocorrelação (R_{xx}). Esses podem ser melhor visualizados na Figura 3.5, que ilustra o índice baseado na inclinação da curva da autocorrelação (índice AcorSI) e o índice baseado na soma das áreas das curvas que excedem o intervalo de confiança da função de autocorrelação (índice AcorAR).

A função de autocorrelação mostra a correlação do erro da saída do controlador ao longo do tempo, permitindo se ter uma medida aproximada do quão perto da variância mínima encontra-se o sistema, ou seja, permite uma análise da influência entre os dados históricos e os dados atuais. Com isso, um cenário acerca da velocidade do controlador e da presença de perturbações no sistema pode ser claramente analisado. A função de autocorrelação varia entre -1 e 1, sendo que para um controlador bem ajustado, a função de autocorrelação deve tender a zero tão logo o período referente ao tempo morto tenha se esgotado.

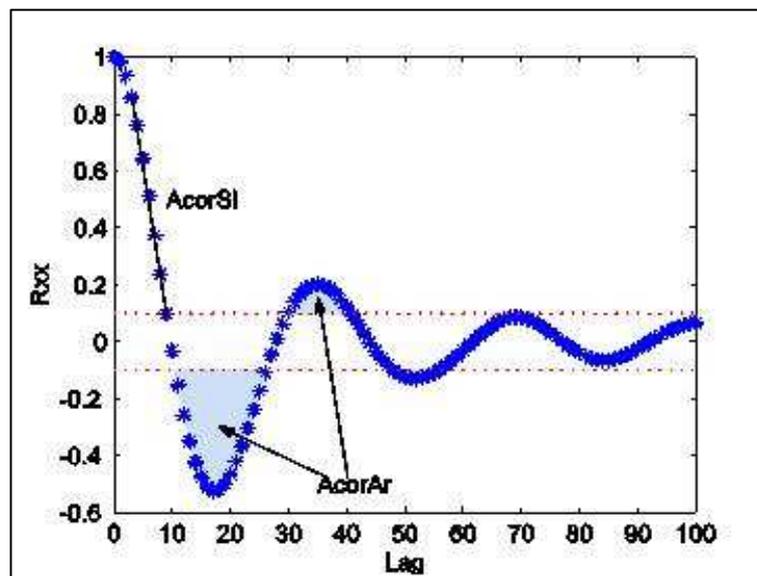


Figura 3.5: Definição dos índices baseados na função de autocorrelação (Retirado de Farenzena, 2006b).

Além dos índices descritos acima, o modelo de inferência ainda tem como entradas a estimativa do tempo morto (θ) e a constante de tempo (τ) do processo.

3.3.3 Índices gerados pelo IM

O Modelo de Inferência para Desempenho e Robustez fornece indicadores tais como a razão entre o tempo de subida em malha aberta e em malha fechada (Rt_R), a razão entre o tempo de assentamento em malha aberta e em malha fechada (St_R), além da máxima sensibilidade (MS), da reserva de fase (RF) e da margem de ganho (MG), índices que abrangem tanto desempenho quanto robustez.

Um esquema representativo do modelo de inferência proposto é apresentado na Figura 3.6.

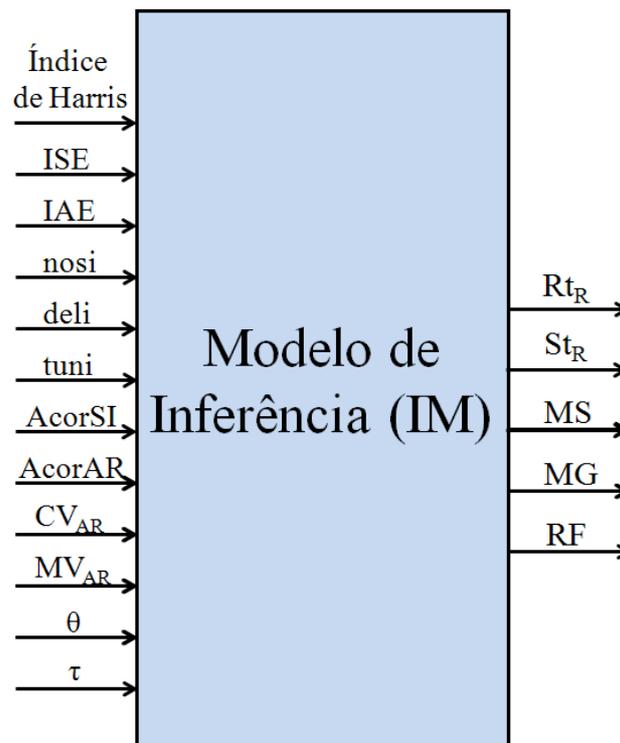


Figura 3.6: Representação esquemática do Modelo de Inferência para Desempenho e Robustez proposto.

Maiores detalhes sobre a construção do modelo de inferência, as plantas e a sintonia dos controladores utilizados, considerações assumidas, os métodos utilizados para ajuste das curvas e os resultados obtidos podem ser encontrados em Farenzena e Trierweiler (2006a) e em Farenzena (2008).

Capítulo 4

Desenvolvimento Teórico

A maioria das metodologias explanadas no capítulo 2 da presente dissertação assume uma redução na variância ou no desvio-padrão em valores fixos. Porém a consideração de uma redução na variabilidade de uma dada malha por um fator fixo constitui-se uma medida que deve ser aplicada com certo cuidado, uma vez que a redução estimada pode não ser representativa da verdadeira melhoria alcançada e, na pior das hipóteses, pode não ser fisicamente possível. Por outro lado, os trabalhos que se propõem a quantificar a redução de variabilidade a qual uma malha está sujeita são escassos e complicados de se implementar de forma prática.

Diante desse cenário e com o intuito de traduzir a relação entre variação no desempenho e potencial de alteração de variabilidade de uma dada malha, o presente capítulo apresenta o Modelo de Inferência de Variabilidade (MIV), um modelo de regressão multivariada (modelo de inferência) que faz uso de parâmetros que quantificam o desempenho de uma dada malha de controle e de características da planta. Tal ferramenta desenvolvida neste trabalho tem por objetivo conciliar a confiabilidade suficiente que permita a sua utilização prática com a simplicidade de utilização para permitir a sua fácil aplicação industrial.

4.1 Definição do Modelo de Inferência de Variabilidade

O modelo de inferência proposto nesse trabalho visa, a partir de entradas facilmente quantificáveis, prever o potencial de alteração de variabilidade de uma dada malha de controle. É desejado que, para atingir tal objetivo, as entradas sejam indicativas do

desempenho atual da malha de controle e possam ser obtidas de forma não intrusiva a partir de dados em operação normal do sistema. Além disso, deseja-se estabelecer uma conexão entre o desempenho desejado para a malha de controle e o quanto ela terá sua variabilidade alterada quando da obtenção de tal desempenho.

Visando este propósito, tais entradas serão provenientes do Modelo de Inferência para Desempenho e Robustez exposto no capítulo 3 dessa dissertação. Além de tais indicadores de desempenho, serão exploradas como entradas características da planta tais como o tempo morto e a constante de tempo. Partindo dessa afirmação, a seguinte definição é proposta:

O Modelo de Inferência de Variabilidade (MIV) é uma função não-linear (N) capaz de prever a alteração de variabilidade (V_A) a partir da variação do desempenho do controlador, sendo essa expressa por índices facilmente quantificáveis obtidos a partir do Modelo de Inferência para Desempenho e Robustez (IM) e características da planta, tais como o tempo morto e a constante de tempo (P_c).

$$V_A = N(IM, P_c) \quad (4.1)$$

A Figura 4.1 apresenta uma representação esquemática do modelo de inferência proposto nesse trabalho, com as entradas as quais se propõe a sua utilização e os diferentes métodos que serão testados. A saída de tal modelo será, conforme definição acima, a alteração da variabilidade, sendo essa expressa pela Equação 4.2.

$$V_A = \frac{\sigma_2^2}{\sigma_1^2} - 1 \quad (4.2)$$

Sendo σ_1^2 e σ_2^2 a variância da malha de controle antes e depois das melhorias realizadas na mesma.

A escolha de tal saída vem ao encontro do que se deseja com o modelo de inferência: obter facilmente o quanto uma malha pode ter sua variabilidade alterada a partir de uma variação no seu desempenho, sendo essa expressa como uma razão relativa entre o estado desejado e o estado atual de uma dada malha de controle. Com isso é esperado que se tenha uma forma mais apurada de, antes de se realizar uma melhoria no sistema de controle, estimar a alteração de variabilidade que a malha pode apresentar.

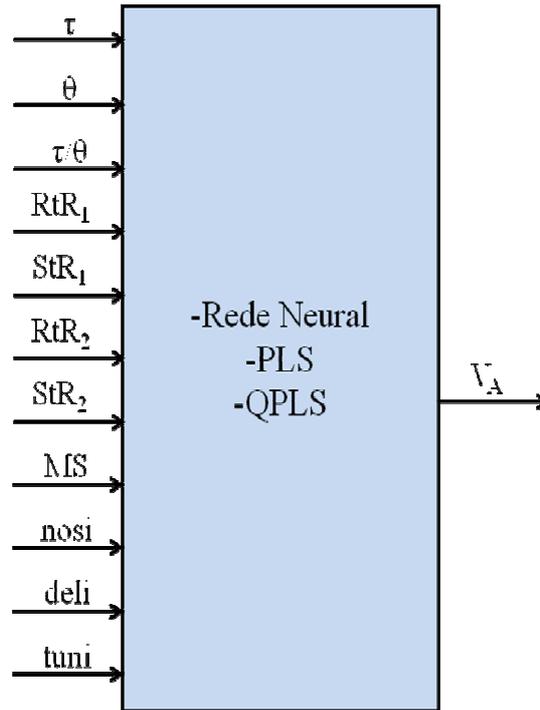


Figura 4.1: Representação esquemática do modelo de inferência proposto. V_A é a alteração de variabilidade dada pela Equação 4.2 e as denominações das entradas estão listadas na Tabela 4.2.

Para uma situação na qual se dispõe de dados em operação normal, sem variação no valor do *setpoint*, o cálculo dos indicadores de desempenho necessários para quantificar a situação atual da malha de controle será realizado a partir do Modelo de Inferência para Desempenho e Robustez. Estes indicadores, juntamente com características da planta, deverão constar como entradas do modelo de inferência proposto. Uma vez que o objetivo do modelo de inferência é de prever a alteração de variabilidade a partir de variações no desempenho do controlador, deve-se também informar ao modelo o desempenho desejado para a malha de controle. Tal desempenho desejado poderá ser fornecido tanto em relação à razão entre tempo de subida em malha aberta e fechada quanto em relação à razão entre tempo de assentamento em malha aberta e fechada desejáveis, $RtR2$ e $StR2$.

4.2 Obtenção do Modelo de Inferência de Variabilidade

Para o desenvolvimento do modelo de inferência proposto, três diferentes métodos foram testados, a saber:

- Rede Neural (RN);

- Mínimos Quadrados Parciais (PLS);
- Mínimos Quadrados Parciais Quadráticos (QPLS).

Para a obtenção de um modelo de inferência com uma capacidade de predição adequada seguiu-se o procedimento sumarizado pela Figura 4.2. Os passos de tal procedimento são semelhantes aos utilizados nos trabalhos de Rawlings (1988) e Facchin (2005).

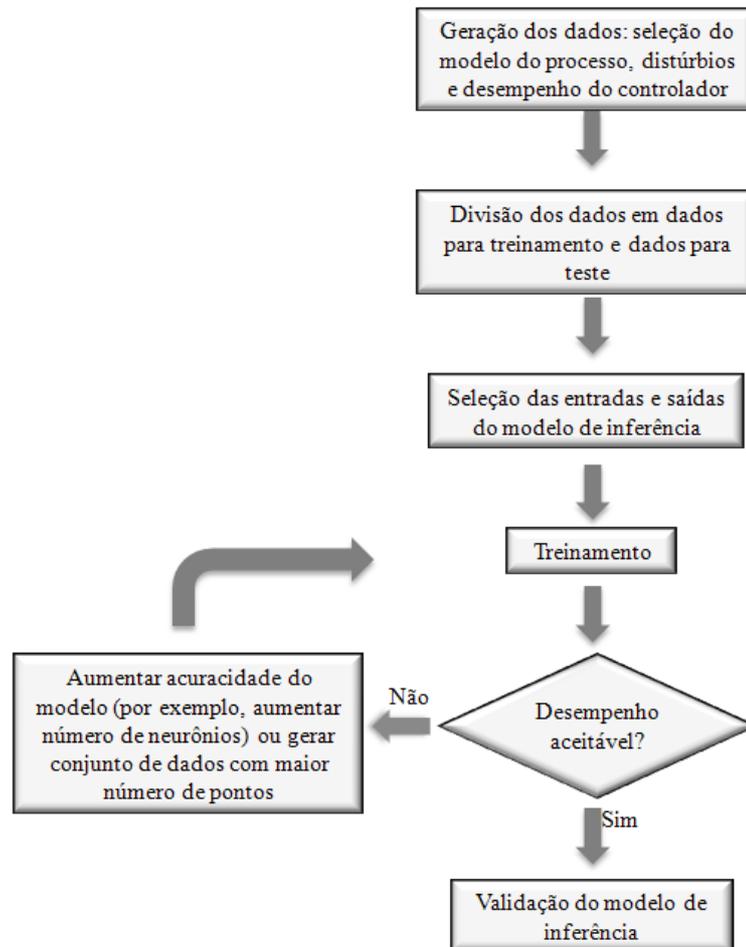


Figura 4.2: Procedimento para a construção do modelo de inferência.

O primeiro passo desse procedimento consiste na geração dos dados, o que envolve a seleção do modelo do processo, das perturbações e dos modelos dos controladores que serão utilizados. Essa etapa constitui de um procedimento de “tentativa-e-erro”; gera-se um determinado conjunto de dados e avalia-se o seu desempenho quando utilizado para o treinamento do modelo de inferência. Caso seja necessário se proceder ao aumento do número de neurônios para melhorar a capacidade de ajuste do modelo de inferência, este aumento normalmente deve vir acompanhado de um aumento do número de dados gerados, evitando assim a ocorrência de sobreajuste.

Cada método teve sua acuracidade determinada pelo cálculo do coeficiente de correlação (R^2), sendo esse definido como a covariância entre y_p (valor predito) e y (valor de referência). Considera-se o desempenho do método aceitável quando R^2 da etapa de treinamento apresenta valores superiores a 0,96. Caso R^2 seja inferior a 0,96 então a acuracidade do modelo é aumentada. Para avaliar a capacidade de predição do modelo, os dados da etapa de teste foram utilizados para o cálculo de R^2 . Caso R^2 da etapa de teste for significativamente menor que R^2 da etapa de treinamento, então pode-se dizer que o modelo foi devidamente treinado.

Considerando-se então uma malha *feedback* padrão tal qual a apresentada na Figura 4.3, uma das mais simples e a mais utilizada em processos químicos industriais, onde G é modelo do processo, C é o controlador, N é o modelo da perturbação, y_t é a variável controlada, r a variável de referência e a_t e b_t sinais randômicos; um conjunto de plantas, controladores e perturbações foram escolhidos para a geração dos dados que foram utilizados para a construção do modelo de inferência.

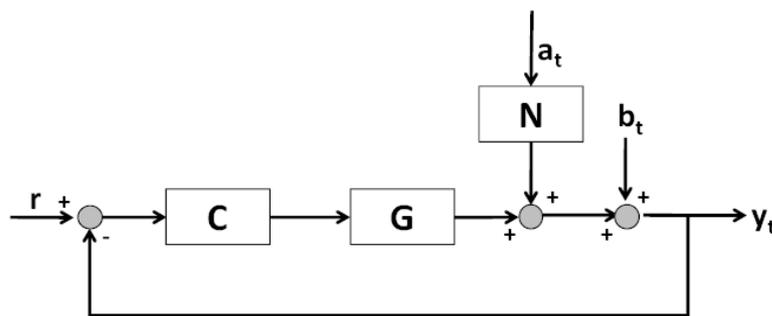


Figura 4.3: Malha de Controle por *feedback* padrão.

Para tanto, as plantas G utilizadas na simulação foram representadas por funções de primeira ordem com tempo morto enquanto os controladores C foram representados por controladores PID, sendo que seus parâmetros de sintonia foram alterados visando diferentes desempenhos. O sistema é ainda afetado por uma perturbação periódica com frequência e amplitude variáveis, representado por N e um ruído branco, representado por b_t .

Para a geração do conjunto de dados que foi utilizado para a obtenção dos modelos de inferência, os parâmetros de simulação da malha *feedback* padrão constantes na Tabela 4.1 foram variados, onde τ é a constante de tempo, θ o tempo morto, K_c o ganho do controlador, b_t a intensidade do ruído branco e τ/τ_d a razão entre a constante de tempo da planta e a constante de tempo da perturbação. Importante salientar que os valores dos parâmetros integrais dos controladores utilizados são ajustados frente à constante de tempo e ao tempo morto da planta.

Dessa forma foi possível obter um conjunto de plantas e controladores com características distintas, abrangendo assim uma maior gama de comportamentos que poderão ser detectados pelo Modelo de Inferência de Variabilidade.

Tabela 4.1: Parâmetros do conjunto de dados utilizados para a construção do modelo de inferência.

Parâmetro	Valor
τ	[5 10 15 25:25:100]
θ	[1:10]
K_c	[0,05 0,1 0,5 0,75 1 2 3]
τ_d/τ	[1:0,5:4]
b_t	[0,1:0,05:0,25 0,5 1 2 5]

OBS.: Os intervalos são definidos segundo a notação do Matlab[®] (início: passo: fim).

Partindo-se da variação desses parâmetros, um total de 27440 dados foram então gerados. A determinação do modelo é realizada em duas etapas: (a) treinamento e (b) testes. O treinamento do modelo é realizado para que o modelo de inferência tenha capacidade de reproduzir o comportamento do sistema, enquanto que na etapa de testes é realizada a validação do modelo, que deve prever a saída do sistema para os dados de entrada utilizados no treinamento e ter a capacidade de generalizar para qualquer conjunto de valores reais de entrada do processo.

Utilizando-se a seleção *y-Rank*, o conjunto de dados foi então dividido de modo a ser utilizado nessas duas etapas: cerca de 80% dos pontos foram utilizados para treinar cada método e 20% dos pontos foram utilizados para a etapa de teste. O procedimento de seleção *y-Rank* baseia-se na ordenação, ou “ranqueamento”, dos dados em ordem crescente. O processo de seleção move os três primeiros dados ordenados para o conjunto de treinamento enquanto o próximo dado é movido para o conjunto de teste. Esse procedimento se repete até que todos os dados tenham sido transferidos para um dos conjuntos, garantindo assim que o modelo seja treinado e testado em todas as regiões com diferentes conjuntos de dados (Facchin, 2005).

Como o objetivo do modelo proposto é estimar a alteração de variabilidade, a razão dada pela Equação 4.2 foi escolhida para ser a saída do modelo de inferência. Entre as possíveis entradas estão as variáveis propostas na Tabela 4.2. Importante observar que, para se fazer uma conexão entre a variação de desempenho e a alteração de variabilidade, foram escolhidas para fazer parte do conjunto de entradas indicadores de desempenho que possam ser quantificados para a situação atual e que possam ainda ser estimados de acordo com o desempenho que se deseja para a malha de controle.

Tabela 4.2: Variáveis de entrada possíveis para o modelo de inferência.

Número da Variável	Variável	Descrição
1	τ/θ	Razão entre a constante de tempo e o tempo morto da planta
2	τ	Constante de tempo
3	θ	Tempo morto
4	RtR1	Razão entre o tempo de subida do sistema em malha aberta e fechada <i>antes</i> das melhorias na malha de controle
5	RtR2	Razão entre o tempo de subida do sistema em malha aberta e fechada <i>depois</i> das melhorias na malha de controle
6	StR1	Razão entre o tempo de assentamento do sistema em malha aberta e fechada <i>antes</i> das melhorias na malha de controle
7	StR2	Razão entre o tempo de assentamento do sistema em malha aberta e fechada <i>depois</i> das melhorias na malha de controle
8	M_S	Máxima sensibilidade
9	<i>tuni</i>	Índice de ajuste
10	<i>nosi</i>	Índice de ruído
11	<i>deli</i>	Índice de tempo morto

Apesar de o conjunto de variáveis que compõem o grupo de entrada não ser considerado elevado, optou-se por utilizar a classe de métodos seqüenciais de busca para a seleção das variáveis que mais influenciam para o cálculo da alteração de variabilidade, pois quanto menos variáveis de entrada forem necessárias mais fácil será a implementação e manutenção do modelo. Esse método caracteriza-se pela possibilidade de avaliação dos efeitos das variáveis através da adição ou remoção de apenas uma variável em cada etapa, sendo que existem três principais variações desse: seleção por adição (*Forward Selection*), seleção por eliminação (*Backward Elimination*) e seleção por adição e eliminação (*Stepwise Regression*) (Facchin, 2005). Uma vez que, com a utilização dessa última variante é possível a verificação da redundância de variáveis, optou-se por se fazer a seleção das variáveis de entrada por esse método.

O método seqüencial de busca *Stepwise Regression* inicia com a adição seqüencial das variáveis candidatas ao modelo, sendo que a variável que apresentar melhor desempenho é adicionada ao conjunto de variáveis que irão compor o modelo. Posteriormente são criados modelos contendo combinações da variável previamente incluída e cada uma das variáveis não selecionadas anteriormente. A variável que gerar o melhor modelo em combinação com aquela introduzida na etapa anterior é pré-selecionada para compor o modelo. A cada inclusão de variável é realizada uma comparação eliminatória para verificar se a variável adicionada não é redundante a uma outra previamente adicionada. A variável pré-selecionada é então submetida a um teste de hipótese F para verificar se a sua adição acarreta melhora significativa ao modelo. Caso não acarrete nenhuma melhora, a variável é removida. O método é finalizado quando não há mais variáveis a serem excluídas do conjunto (Facchin, 2005).

Fazendo uso então do *Statistics Toolbox* do MATLAB[®], o qual contém a função *stepwise*, foi possível selecionar as variáveis de entrada para o conjunto de dados que apresentaram melhor desempenho na composição do modelo. A janela de tal *toolbox* pode ser visualizada na Figura 4.4, na qual se pode observar que a escolha de tais variáveis seguiu a observância do menor valor do RMSE (raiz do erro quadrático médio do conjunto de variáveis em análise):

$$RMSE = \sqrt{\left(\frac{1}{n}\right) \sum_{i=1}^n (y_i - y_{p_i})^2} \quad (4.3)$$

Na Equação 4.3 y é a saída real, y_p é a saída do modelo e n corresponde ao número de dados utilizados.

Convém ressaltar que o menor valor de RMSE ocorreu ao se utilizar todo o conjunto de variáveis possíveis para entrada. Porém, para a modelagem de um sistema o número de variáveis é fator considerável para complexidade do modelo. Com isso em mente e tendo em vista que até o subconjunto de seis variáveis houve uma diminuição significativa do erro e do subconjunto com seis variáveis até a inserção de todas as variáveis não houve uma melhora considerável da qualidade do modelo, foi escolhido então o subconjunto com seis variáveis, as quais estão listadas na Tabela 4.3.

Tabela 4.3: Variáveis de entradas escolhidas para o conjunto de dados.

Variável	Descrição
τ	Constante de tempo
θ	Tempo morto
RtR1	Razão entre o tempo de subida do sistema em malha aberta e fechada <i>antes</i> das melhorias na malha de controle
RtR2	Razão entre o tempo de subida do sistema em malha aberta e fechada <i>depois</i> das melhorias na malha de controle
<i>nosi</i>	Índice de ruído
<i>deli</i>	Índice de tempo morto

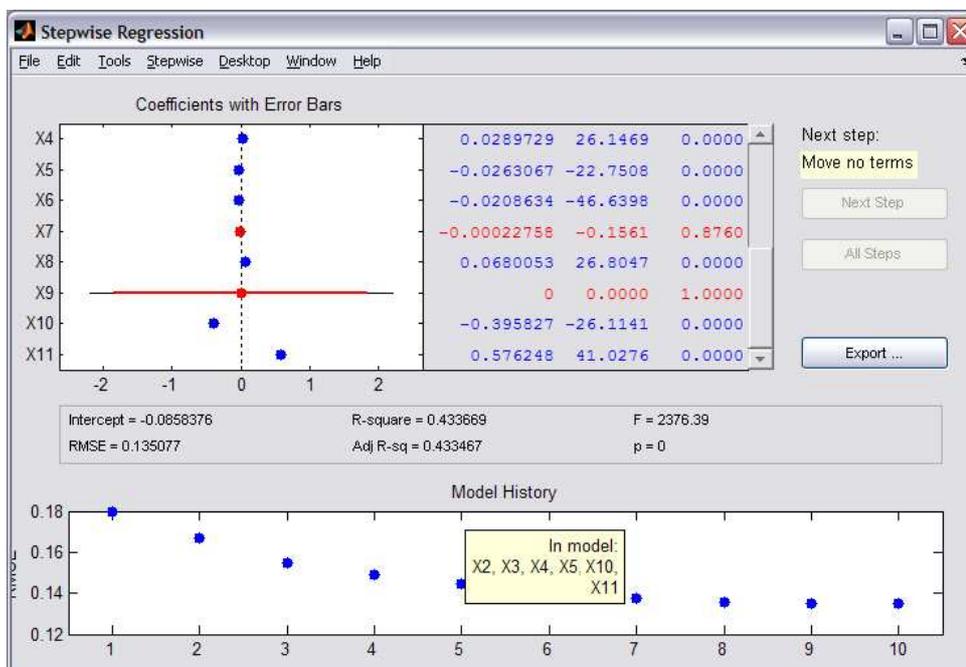


Figura 4.4: Interface gráfica utilizada para seleção das entradas do modelo de inferência através do conjunto de dados gerado. As variáveis estão numeradas de acordo o “Número da Variável”, constante na 1ª coluna da Tabela 4.2.

A seguir, são abordados separadamente cada um dos métodos utilizados para gerar os diferentes tipos de modelos.

4.2.1 Rede Neural

Redes Neurais são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neuronal.

Neste trabalho optou-se pela utilização da denominada Rede Neural Multicamada (*Multilayer Feedforward Neural Network* - MNN). Nessa arquitetura, os neurônios estão dispostos em camadas que se justapõem umas às outras, formando uma configuração em cascata, podendo existir mais de uma camada intermediária. A primeira camada (pseudocamada) é a camada de entrada (*input layer*), as camadas intermediárias são as camadas ocultas (*hidden layers*) e a última camada é a camada de saída (*output layer*). A rede funciona no sentido direto da entrada para a saída (*feedforward*) e a camada de entrada não possui processamento. Segundo Haykin (1999), as MNNs são boas para “aprender” relações matemáticas a partir de um conjunto de dados de entrada-saída, sendo, por isso, consideradas aproximadores universais de funções matemáticas.

A MNN utilizada para a construção do Modelo de Inferência de Variabilidade apresenta duas camadas, sendo a primeira (camada oculta) com função de ativação (função responsável pela ativação da saída ou resposta do neurônio artificial, ou elemento processador) do tipo tangente sigmoidal com número variável de neurônios e a segunda com um neurônio do tipo linear.

A construção e o treinamento das redes neurais deu-se com o uso do *toolbox Neural Networks* do MATLAB[®], sendo que para o treinamento utilizou-se o algoritmo de *backpropagation*, ou retropropagação. Esse nome é devido ao movimento de propagação do erro, de trás para frente, da camada de saída para a camada de entrada (Haykin, 1999). Uma abordagem mais detalhada dos principais conceitos relativos às redes neurais é dada no Apêndice B da presente dissertação.

Utilizando-se então como entradas as variáveis constantes na Tabela 4.3 e como saída a alteração de variabilidade dada pela Equação 4.2, treinaram-se para o conjunto de dados gerados diferentes arquiteturas de redes, sendo que para isso o número de neurônios na camada oculta foi sendo modificado. Cada rede foi treinada quatro vezes durante 100 épocas, e após esse treinamento escolheu-se aquela que apresentou melhor desempenho e treinou-se a mesma novamente durante 1000 épocas, visando a sua melhora. Portanto, o desempenho das diferentes redes neurais testadas com diferentes números de neurônios na camada oculta, o qual pode ser visualizado na Tabela 4.4, refere-se ao desempenho obtido pelo melhoramento da melhor rede treinada para cada arquitetura escolhida.

Importante salientar que, além da observância aos valores de R^2 , para as redes neurais treinadas foram observados também os valores do erro quadrático médio - MSE (do inglês *mean squared error*), dado pela equação 4.4, tendo-se como objetivo obter o menor valor deste.

$$MSE = \left(\frac{1}{n} \right) \sum_{i=1}^n (y_i - y_{p_i})^2 \quad (4.4)$$

Tabela 4.4: Relação entre o desempenho da rede neural e número de neurônios para o conjunto de dados.

Neurônios	R^2 Treinamento	R^2 Teste	MSE
5	0,8585	0,8404	0,00830
10	0,9735	0,9730	0,00169
20	0,9892	0,9850	0,00091
30	0,9893	0,9862	0,00087
50	0,9897	0,9809	0,00078

Conforme se pode visualizar na Tabela 4.4, o desempenho do modelo de inferência baseado em redes neurais para o conjunto de dados utilizado mostrou-se muito bom, sendo que a melhor relação entre capacidade de predição do modelo se deu com baixo número de neurônios, isto é, com apenas 20 neurônios foi possível obter-se um modelo de inferência capaz de predizer de forma eficaz a relação entre as variáveis de entrada e as variáveis de saída, sendo que acima de 20 neurônios não houve um aumento significativo na capacidade de predição do modelo. Uma vez que com o conjunto de dados utilizados, o qual conteve 27440 pontos, obteve-se uma boa capacidade de predição para o modelo de inferência, não se fez necessário gerar outros conjuntos de dados. Caso isso não se confirmasse, dever-se-ia proceder à geração de um novo conjunto de dados que abrangesse uma maior região de interesse e posteriormente ao treinamento e validação de uma nova Rede Neural Multicamada.

A escolha das variáveis de entrada condiz com o que se deseja observar em uma malha de controle. Enquanto é possível a utilização de características da planta facilmente obtíveis, utilizaram-se ainda parâmetros que podem ser quantificados de forma conclusiva pelo Modelo de Inferência para Desempenho e Robustez. O uso da razão entre o tempo de subida do sistema em malha aberta e fechada antes e depois das melhorias na malha de controle permite que se faça uma conexão precisa entre o desempenho atual e o desempenho

desejável de forma simples. Além disso, uma vez que a variabilidade da malha de controle pode estar relacionada com componentes tais como tempo morto e ruído branco, os índices de tempo morto (*nosi*) e de ruído (*deli*) permitem capturar tais padrões de comportamento e assim possibilitam uma melhor capacidade de predição para o modelo de inferência proposto.

Visando verificar como essa capacidade de predição do modelo de inferência se alteraria em virtude da inclusão ou não de tais índices, obteve-se, para o mesmo conjunto de dados gerados, uma nova rede neural (denominada de modelo de inferência “teste”), a qual teve somente como entradas as variáveis listadas na Tabela 4.5, abaixo.

Tabela 4.5: Variáveis de entradas utilizadas para a geração do modelo de inferência “teste”.

Variável	Descrição
τ	Constante de tempo
θ	Tempo morto
RtR1	Razão entre o tempo de subida do sistema em malha aberta e fechada antes das melhorias na malha de controle
RtR2	Razão entre o tempo de subida do sistema em malha aberta e fechada depois das melhorias na malha de controle

Analogamente ao realizado para a rede neural que continha as entradas mencionadas na Tabela 4.3, treinaram-se para o conjunto de dados gerados diferentes arquiteturas de redes, sendo que para isso o número de neurônios na camada oculta foi sendo modificado. Cada rede foi treinada quatro vezes, e após esse treinamento escolheu-se aquela que apresentou melhor desempenho e treinou-se a mesma novamente, visando a sua melhoria. Portanto, o desempenho das diferentes redes neurais testadas com diferentes números de neurônios na camada oculta, o qual pode ser visualizado na Tabela 4.6, refere-se ao desempenho obtido pelo melhoramento da melhor rede treinada para cada arquitetura escolhida.

Tabela 4.6: Relação entre o desempenho da rede neural e número de neurônios para geração do modelo de inferência “teste”.

Neurônios	R^2 Treinamento	R^2 Teste	MSE
5	0,8271	0,8331	0,00997
10	0,8327	0,8324	0,00967
20	0,8572	0,8546	0,00833
30	0,9129	0,9110	0,00525
50	0,9187	0,9121	0,00499

Conforme pode se observar pelos valores da Tabela 4.6, a não inclusão dos índices de tempo morto e de ruído implicou piora do desempenho do modelo de inferência, uma vez que os valores do coeficiente de correlação ficaram abaixo do aceitável, para qualquer número de neurônios utilizado. Pode-se com isso afirmar que a inclusão de tais índices se faz necessária, pois somente com esses é possível capturar o padrão de comportamento da perturbação, fator esse que pode influenciar de forma considerável na variabilidade de uma malha de controle.

4.2.2 Mínimos Quadrados Parciais – PLS e Mínimos Quadrados Parciais Quadráticos – QPLS

O método de regressão multivariada por mínimos quadrados parciais (*Partial Least Squares*, PLS) apresenta-se como uma poderosa ferramenta para o desenvolvimento de modelos quando os dados apresentam um elevado índice de correlação (Facchin, 2005). Esse método é muito mais concentrado na variável dependente e, portanto, mais eficiente para descrever a variável de interesse.

Em complemento ao método PLS, apresenta-se o método QPLS (do inglês *Quadratic Partial Least Squares*) como uma alternativa para se trabalhar com sistemas onde o grau de não-linearidade é relativamente elevado, isso devido à substituição do mapeamento linear utilizado pelo PLS por uma relação quadrática (Facchin, 2005).

Ambos os métodos foram também utilizados para a determinação do modelo de inferência, utilizando-se o conjunto de dados gerados via simulação, o qual conteve 27440 pontos, e as variáveis de entrada que apresentaram melhor desempenho na composição do modelo: τ , θ , RtR1, RtR2, *nosi* e *deli*.

Porém, conforme pode ser visualizado na tabela 4.7, observa-se que a capacidade de predição dos modelos de inferência obtidos via PLS e QPLS é menos efetiva quando comparado à obtida via redes neurais, mesmo com a inclusão dos índices *nosi* e *deli*.

Tabela 4.7: Desempenho dos métodos PLS e QPLS.

Método	R^2 Treinamento	R^2 Teste
PLS	0,8856	0,8011
QPLS	0,8543	0,8188

Conclui-se com isso que o modelo de inferência desenvolvido via PLS ou QPLS não pode ser considerado efetivo em seu propósito e por isso não será utilizado para fins de prever a alteração de variabilidade a qual uma malha possa estar sujeita.

4.3 O Modelo de Inferência de Variabilidade na Prática

A partir dos resultados obtidos, verificou-se que com a utilização do conjunto de dados, modelados via rede neural utilizando-se 20 neurônios na camada oculta e as entradas constantes na Tabela 4.3 foi possível obter uma melhor capacidade de predição, característica essencial para a determinação de propriedades a partir de determinadas variáveis de entrada. Partindo-se então da simulação da rede neural escolhida, uma função para Matlab[®] que automatiza o processo de obtenção da alteração de variabilidade foi implementada. É necessário fornecer apenas os índices obtidos através do Modelo de Inferência para Desempenho e Robustez, ou seja, a razão entre o tempo de subida do sistema em malha aberta e fechada (RtR), o índice de ruído (*nosi*), o índice de tempo morto (*deli*), além da constante de tempo da planta (τ) e seu tempo morto (θ) que esta função devolve a alteração de variabilidade, sendo este valor o determinado a partir da Equação 4.2.

Convém salientar que os valores de RtR devem ser fornecidos para duas situações distintas. A primeira situação descreve o desempenho da malha de controle na configuração praticada atualmente, ou seja, antes de qualquer variação no desempenho do controlador. Para a obtenção de tal índice através do Modelo de Inferência para Desempenho e Robustez, uma função em Matlab[®] desenvolvida em Farenzena (2008) deve ser utilizada, sendo necessário fornecer apenas uma janela de dados, a constante de tempo da planta e seu tempo morto.

Assim, de posse do valor de RtR anterior às variações no desempenho do controlador, é possível obter a variância da malha de controle para tal situação. Essa razão será aqui denominada de σ_1^2 .

Já na segunda situação, o valor de RtR é determinado levando-se em consideração o desempenho desejado para a malha de controle. De posse do valor de RtR posterior às variações no desempenho do controlador, a variância da malha de controle encontrada para tal situação pode ser calculada, sendo a mesma denominada de σ_2^2 .

A alteração de variabilidade (V_A) será dada, portanto pela razão entre os valores de σ_2 e σ_1 , subtraído de 1, conforme definido na Equação 4.2. Valores de V_A 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 V_A . Ao contrário, ou seja, valores de V_A negativos indicam que a malha de controle pode ter sua variabilidade reduzida, sendo esse potencial de redução tão maior quanto mais negativo for V_A .

Visando confirmar a aplicabilidade do Modelo de Inferência de Variabilidade, o qual visa traduzir a relação entre variação no desempenho e potencial de alteração de variabilidade de uma dada malha de controle, diferentes casos de estudo foram desenvolvidos. Em um primeiro momento procurou-se focar na análise da influência de determinados parâmetros de entrada sobre o modelo de inferência proposto. Para tanto, na seção seguinte será apresentado os casos de estudo acompanhados de uma minuciosa análise de sensibilidade. Em um segundo momento procurou-se focar na viabilidade da aplicação industrial do Modelo de Inferência de Variabilidade e, para isso, um caso de estudo foi desenvolvido em uma planta industrial, o qual é apresentado no capítulo seguinte.

4.4 Casos de Estudo

Com o intuito de elucidar a influência da variação de determinados parâmetros de entrada sobre o modelo de inferência proposto, pretende-se na próxima seção realizar uma análise de sensibilidade em casos de estudo os quais utilizarão modelos de 1ª e de 2ª ordem, em diferentes cenários. Com tal análise será ainda possível verificar as potencialidades do Modelo de Inferência de Variabilidade, avaliando de forma efetiva a sua capacidade de predição.

4.4.1 Casos de Estudo Aplicando-se Modelos de 1ª Ordem

Partindo-se do sistema representado na Figura 4.3, o mesmo utilizado para etapa de geração dos dados, e variando-se os parâmetros de simulação tanto do modelo da planta, G , quanto do controlador, C , foram obtidas diferentes configurações de malhas de controle de 1ª ordem com tempo morto e perturbação periódica. Parâmetros tais como a intensidade do ruído branco ao qual o sistema está submetido (b_t) e a relação entre a constante de tempo da planta e a constante de tempo da perturbação (τ/τ_d) também foram variados e os valores utilizados para tais constam na Tabela 4.8.

Tabela 4.8: Valores dos parâmetros b_t e τ/τ_d utilizados para a obtenção das diferentes malhas de controle.

Planta	b_t	τ/τ_d
G1	0,25	1
G2	0,5	1
G3	0,5	1,5
G4	0,5	2,5

Quatro malhas no total foram analisadas, sendo que os modelos das plantas utilizadas são apresentados na Tabela 4.9.

Tabela 4.9: Conjunto de plantas de 1ª ordem utilizadas para os casos de estudo desenvolvidos nesta seção.

Planta	Modelo
G1	$\frac{1}{10s+1}e^{-5s}$
G2	$\frac{1}{50s+1}e^{-5s}$
G3	$\frac{1}{50s+1}e^{-2s}$
G4	$\frac{1}{25s+1}e^{-3s}$

Pela simulação com tais parâmetros, um conjunto de dados foi gerado para cada malha de controle a ser analisada. Ao se fornecer esta janela de dados gerada, a constante de tempo e o tempo morto da planta, é possível, através do Modelo de Inferência para Desempenho e Robustez, obter para cada malha de controle os valores da razão entre o tempo de subida do sistema em malha aberta e fechada para o desempenho atual, $RtR1$. Para a obtenção dos índices de ruído ($nosi$) e de tempo morto ($deli$), além da janela de dados e do tempo morto é necessário fornecer a ordem do modelo auto-regressivo (AR). Para tal considerou-se que o sistema apresenta tempo de amostragem corretamente dimensionado e assim assumiu-se um valor de 20 para a ordem do AR, visando capturar de forma adequada o comportamento do mesmo. Os índices assim calculados, que constituem-se das entradas do Modelo de Inferência de Variabilidade podem ser visualizados na Tabela 4.11.

Para o cálculo de RtR2 nominais, das quatro malhas analisadas, em duas, G1 e G3, se procurou melhorar o seu desempenho, pelo aumento do ganho proporcional do controlador e em duas, G2 e G4, se procurou piorar o seu desempenho, pela diminuição do ganho proporcional do controlador. Com isso foram obtidos diferentes valores da razão entre o tempo de subida do sistema em malha aberta e fechada depois de realizados tais ajustes, RtR2. Com o aumento do ganho a resposta do sistema em malha fechada é mais rápida, ocasionando assim um aumento de RtR ao passo que com a diminuição do ganho a resposta em malha aberta torna-se mais rápida, fazendo com que RtR diminua. Os valores obtidos, portanto de RtR2 constam na última coluna da Tabela 4.11 enquanto que as alterações realizadas nos valores dos ganhos proporcionais dos controladores constam da Tabela 4.10.

Tabela 4.10: Valores da constante de tempo integral (τ_i) e dos ganhos proporcionais para antes (K_p1) e depois (K_p2) do ajuste nas malhas de controle.

Planta	K_p1	K_p2	τ_i
G1	0,1	0,5	12,5
G2	0,75	0,5	52,5
G3	0,5	0,75	51
G4	0,5	0,1	26,5

Tabela 4.11: Valores calculados pelo Modelo de Inferência para Desempenho e Robustez.

Planta	<i>nosi</i>	<i>deli</i>	RtR1	RtR2
G1	0,7876	0,1977	0,0809	0,4699
G2	0,9594	0,0406	0,7522	0,4879
G3	0,9571	0,0429	0,4914	0,7450
G4	0,9567	0,0433	0,4863	0,1023

Fornecendo as entradas constantes da Tabela 4.11 e ainda a constante de tempo e o tempo morto da planta ao Modelo de Inferência de Variabilidade foi possível calcular o valor de alteração de variabilidade predito para cada malha de controle analisada. Tais valores constam da Tabela 4.12 e os mesmos foram comparados com os valores de alteração de variabilidade teóricos, aqueles obtidos quando realizada as melhorias na malha de controle. Para a obtenção desses valores teóricos, foi calculado, a partir da simulação, o valor da variância da variável de saída com o valor do ganho proporcional original e o valor da

variância com o valor do ganho proporcional alterado. Deste modo, a partir da Equação 4.2, foi possível obter os valores de alteração de variabilidade apresentados pelas malhas de controle.

Tabela 4.12: Valores de V_A preditos em comparação com os valores de V_A teóricos.

Planta	Valor Predito	Valor Teórico	Erro Absoluto	Erro Percentual
G1	-0,0281	-0,0357	0,0076	27,04%
G2	0,0045	0,0034	0,0011	24,44%
G3	-0,0060	-0,0073	0,0013	21,67%
G4	0,0067	0,0081	0,0014	20,89%

Observa-se que os valores do erro entre V_A predito e V_A teórico são pequenos, dentro do que se espera desse trabalho.

Assim sendo, após ter verificado quantitativamente a capacidade de predição do Modelo de Inferência de Variabilidade, procede-se a análise de sensibilidade para verificar como uma alteração nos parâmetros de entrada influenciam na saída do modelo. Para esta análise de sensibilidade procurou-se, em um primeiro momento, focar no comportamento da função alteração de variabilidade quando da variação dos parâmetros indicativos do desempenho do controlador, $RtR1$ e $RtR2$. A razão entre o tempo de subida do sistema em malha aberta e fechada após as melhorias na malha de controle, $RtR2$, deve ser especificado com base no desempenho que se deseja para o sistema e por muitas vezes este desempenho desejável pode não ser factível de se alcançar na prática. A análise de sensibilidade efetuada a seguir pretende inferir o quanto um erro na estimativa de $RtR2$ pode produzir resultados equivocados nos valores de alteração de variabilidade.

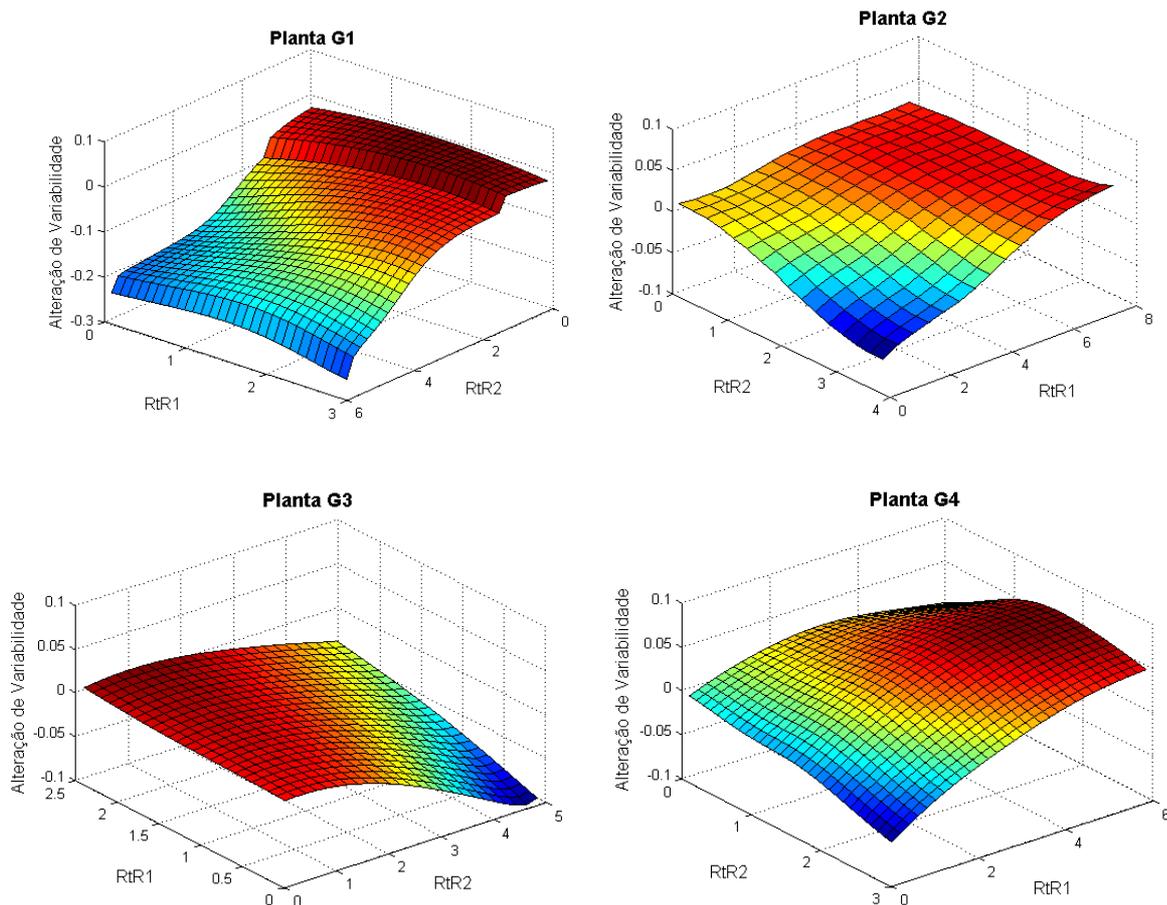
Tendo-se então mantido constantes os valores da constante de tempo, do tempo morto e dos índices de ruído e de tempo morto, os valores de $RtR1$ e $RtR2$ foram variados dentro de intervalos pré-definidos, de acordo com a Tabela 4.13.

Tabela 4.13: Intervalo dos parâmetros RtR1 e RtR2 utilizados para a análise de sensibilidade.

Planta	RtR1	RtR2
G1	0,05:0,1:3	0,1:0,2:6
G2	0,1:0,5:8	0,05:0,25:4
G3	0,05:0,1:2,5	0,1:0,2:5
G4	0,1:0,2:3	0,05:0,1:1,5

OBS.: Os intervalos são definidos segundo a notação do Matlab[®] (início: passo: fim).

A Figura 4.5 mostra o impacto da alteração de RtR1 e RtR2 para cada uma das quatro malhas analisadas

**Figura 4.5:** Comportamento da alteração de variabilidade em função da variação dos parâmetros RtR1 e RtR2.

É observado que o aumento no valor de $RtR2$ implicou em uma diminuição dos valores de V_A , ou seja, a variância após realizados os ajustes no controlador diminuiu em relação à sua variância original, o que corrobora o que é observado ao se melhorar o desempenho de uma dada malha de controle. Ao se observar o comportamento da função alteração de variabilidade verifica-se que o modelo de inferência proposto apresenta a capacidade de prever de forma coerente o comportamento dessa função ao ser aumentado o valor de $RtR2$.

Observa-se ainda que os valores de $RtR2$ tendem a se estabilizar a partir de um certo valor, indicando assim que a malha não apresenta mais um potencial significativo de alteração de sua variabilidade. Ou seja, uma malha pode ter seu desempenho melhorado até certo ponto, sendo que a partir desse ponto a melhora no desempenho acaba por não provocar mais uma redução na variabilidade da malha.

Pela Figura 4.5 pode-se ainda observar um comportamento suave das funções de alteração de variabilidade, o que evidencia a qualidade de predição do modelo de inferência proposto.

Para a análise realizada a seguir, os valores do tempo morto e da constante de tempo foram variados dentro de intervalos pré-definidos, de acordo com a Tabela 4.14.

Tabela 4.14: Intervalo dos parâmetros τ e θ utilizados para a análise de sensibilidade.

Planta	τ	θ
G1	5:0,5:15	4:0,1:6
G2	45:0,5:55	4:0,1:6
G3	45:0,5:55	1:0,1:3
G4	20:0,5:30	2:0,1:4

OBS.: Os intervalos são definidos segundo a notação do Matlab[®] (início: passo: fim).

Conforme elucidado em Farenzena (2008), o tempo morto apresenta um forte impacto sobre a quantificação dos indicadores *nosi* e *deli*, pois é um dos parâmetros utilizados para o cálculo destes. A estimativa errônea do tempo morto leva a resultados distorcidos para estes índices.

Devido a isso, ao se realizar uma análise de sensibilidade que busque intuir sobre a influência da variação do tempo morto e da constante de tempo sobre a função alteração de variabilidade, deve ser considerada também a variação nos valores dos índices *nosi* e *deli* com

o tempo morto, pois esses atuam como entradas do Modelo de Inferência de Variabilidade e podem afetar os valores da função alteração de variabilidade.

Para fins comparativos, essa análise de sensibilidade foi realizada para duas situações distintas. Na primeira situação somente os valores do tempo morto e da constante de tempo foram variados, de acordo com os valores pré-definidos da Tabela 4.14. As demais entradas, ou seja, $RtR1$, $RtR2$, $nosi$ e $deli$ foram mantidas constantes em seus valores nominais apresentados na Tabela 4.11.

A Figura 4.6 ilustra o obtido para a análise de sensibilidade nessa primeira situação. É verificada uma alta dependência entre as características da planta e a alteração de variabilidade, sendo que para as plantas com igual constante de tempo e tempo morto distintos, o erro ao se estimar um valor de tempo morto equivocado é maior.

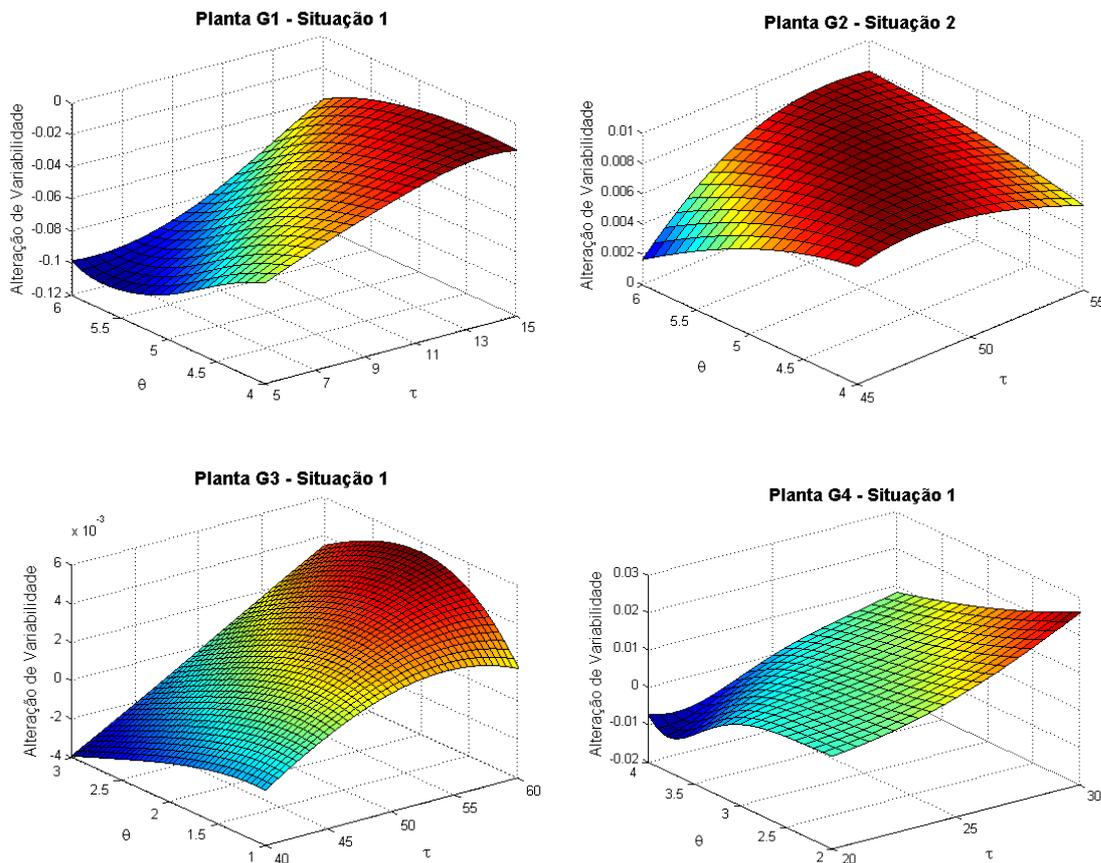


Figura 4.6: Comportamento da alteração de variabilidade em função da variação do tempo morto e da constante de tempo da planta para a análise de sensibilidade realizada para a primeira situação.

Já para a segunda situação, os valores da função alteração de variabilidade foram computados mediante variação de $nosi$ e $deli$ com o tempo morto, ou seja, além de se ter uma

variação nos valores do tempo morto e da constante de tempo, a função alteração de variabilidade foi calculada também com os índices *nosi* e *deli* obtidos para cada valor de tempo morto constante no intervalo da Tabela 4.14.

Pela Figura 4.7 é possível constatar que o modelo de inferência proposto mantém sua capacidade de predição, uma vez que a função alteração de variabilidade continua a apresentar um comportamento suave, característica visualizada também na análise de sensibilidade realizada para a primeira situação. No entanto os valores preditos para a função alteração de variabilidade são totalmente distintos daqueles obtidos na primeira situação, evidenciando deste modo que um erro na estimativa do valor de tempo morto acaba por influenciar significativamente no valor obtido para a alteração de variabilidade a qual uma malha pode estar sujeita, uma vez que afeta diretamente os valores dos índices *nosi* e *deli*, que são também entradas do Modelo de Inferência de Variabilidade.

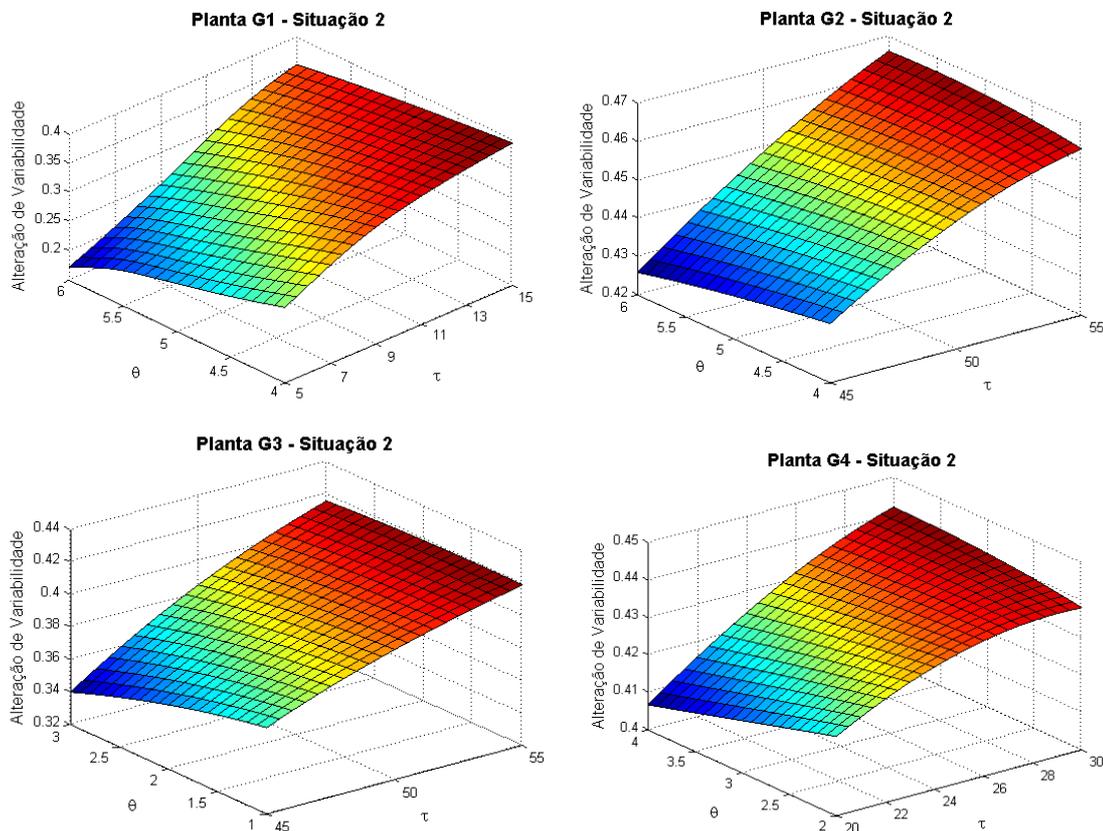


Figura 4.7: Comportamento da alteração de variabilidade em função da variação do tempo morto e da constante de tempo da planta para a análise de sensibilidade realizada para a segunda situação.

Sendo os valores de *nosi* e *deli* influenciados pela correta estimativa do tempo morto, uma análise de sensibilidade que leva em consideração a variação desses parâmetros sobre a

função alteração de variabilidade acaba se tornando redundante à análise de sensibilidade anterior e assim não será realizada nesse estudo.

4.4.2 Casos de Estudo Aplicando-se Modelos de 2ª Ordem

Tendo sido o Modelo de Inferência de Variabilidade treinado e testado com dados gerados a partir de um sistema de 1ª ordem, se faz necessário verificar a sua eficácia quando utilizado para malhas de controle nas quais o modelo de planta é distinto.

Deste modo, na presente seção é apresentada a análise realizada para oito casos de estudo, sendo esses divididos em três tópicos, relativos aos casos em que o sistema apresenta respostas do tipo subamortecida, superamortecida e resposta inversa.

Para cada um desses casos, partiu-se do sistema representado na Figura 4.3, o mesmo utilizado para etapa de geração dos dados, e, variando-se os parâmetros do modelo da planta cuja estrutura é mostrada na Equação 4.5, e do controlador, C, obtiveram-se diferentes configurações de malhas de controle de 2ª ordem com tempo morto e perturbação periódica. Parâmetros tais como a intensidade do ruído branco ao qual o sistema está submetido (b_i) e a relação entre a constante de tempo da planta e a constante de tempo da perturbação (τ/τ_d) também foram variados na simulação realizada e os valores pertinentes são identificados para cada caso.

$$G(s) = \frac{K(\beta s + 1)}{\tau^2 + 2\tau\zeta s + 1} e^{-\theta s} \quad (4.5)$$

Na equação 4.5, K refere-se ao ganho estático, β está relacionado com a posição do zero do sistema, ζ é o fator de amortecimento, τ a constante de tempo e θ o tempo morto.

No entanto, tendo em vista que a metodologia proposta para traduzir o desempenho em alteração de variabilidade baseou-se em um modelo de processo representado por uma função de transferência de 1ª ordem com tempo morto, faz-se necessário, para viabilizar a aplicação do Modelo de Inferência de Variabilidade a sistemas com ordem superiores, que se aproxime a dinâmica do sistema por uma função de 1ª ordem com tempo morto.

Para realizar essa aproximação, foi utilizado o Método de Sundaresan e Krishnaswamy (método SK, citado em Trierweiler e Posser, 2002), que permite que se obtenha facilmente o tempo morto e a constante de tempo do processo através da determinação dos tempos em que a resposta do sistema atinge 35,3% ($t_{35,3\%}$) e 85,3% ($t_{85,3\%}$) de sua variação final. Tendo tais valores de tempos, é possível, pela aplicação das equações

seguintes, obter os parâmetros que descrevem a função de 1ª ordem e que fazem parte das entradas do Modelo de Inferência de Variabilidade.

$$\begin{aligned}\theta &= 1,3(t_{35,3\%}) - 0,29(t_{85,3\%}) \\ \tau &= 0,67(t_{85,3\%} - t_{35,3\%})\end{aligned}\quad (4.6)$$

Caso 1: Modelo de 2ª Ordem com Resposta Subamortecida

Sistemas de 2ª ordem com resposta subamortecida são caracterizados por possuírem valores do fator de amortecimento entre 0 e 1, sendo que quanto menor o valor de ξ , maior será o efeito oscilatório da resposta. Este tipo de sistema é bastante comum quando é analisado um processo real que está submetido a uma ação de controle.

Visando, então, ao estudo de sistemas que podem ser descritos por funções de 2ª ordem com resposta subamortecida, foram consideradas neste estudo duas malhas de controle, sendo que os modelos de planta utilizados na simulação constam na Tabela 4.15. Para a geração dos dados das malhas de controle via simulação, os valores da intensidade do ruído e da razão entre a constante de tempo da planta e a constante de tempo da perturbação foram mantidos constantes em 0,25 e 1,5, respectivamente.

Tabela 4.15: Conjunto de plantas de 2ª ordem com resposta subamortecida utilizadas para o caso de estudo 1.

Planta	Modelo
G1	$\frac{20s+1}{5625s^2+15s+1} e^{-5s}$
G2	$\frac{15s+1}{2500s^2+20s+1} e^{-2s}$

A resposta a uma perturbação do tipo degrau na entrada de tais sistemas é mostrada na Figura 4.8.

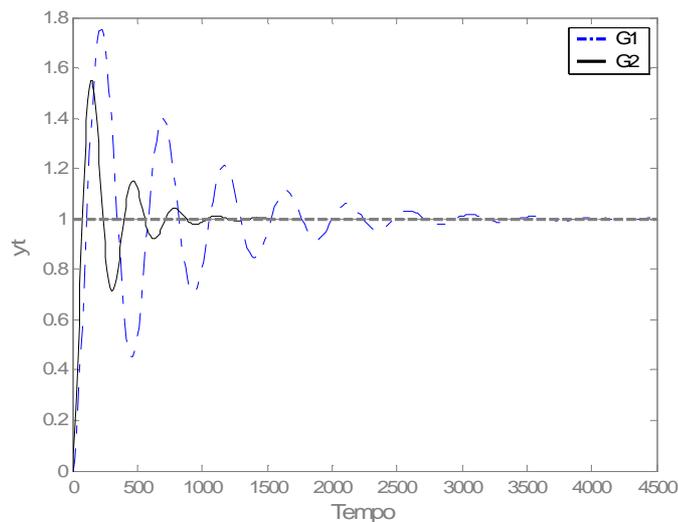


Figura 4.8: Respostas para os sistemas de 2ª ordem considerados no caso estudo de 1, quando submetidos a uma perturbação do tipo degrau na sua entrada.

Para a malha de controle 1, o valor do ganho proporcional foi incrementado em 0,25 visando um aumento na rapidez da resposta. Já para a malha de controle 2, o valor do ganho proporcional foi reduzido de 0,5 para 0,1. Dessa forma é esperado que para a malha de controle 1 a variância após esse ajuste tenha seu valor reduzido em comparação com a variância original, ou seja, a alteração de variabilidade predita deve possuir valores negativos. Ao contrário, é esperado que o valor de alteração de variabilidade para a malha de controle 2 seja positivo, indicando portanto que a variância após o ajuste no ganho proporcional do controlador tenha aumentado em relação a sua variância original.

Pela aplicação do Modelo de Inferência para Desempenho e Robustez torna-se possível, a partir da janela de dados gerada na simulação, da constante de tempo e do tempo morto, obter os valores da razão entre tempos de subida em malha aberta e fechada para antes e depois de realizada a alteração no ganho proporcional do controlador. Para o cálculo dos índices *nosi* e *deli*, além de tais informações, a ordem do modelo AR deve ser fornecida e para tal considerou-se um valor igual a 20. Os valores calculados de tais indicadores são apresentados na Tabela 4.16 e, juntamente com a constante de tempo e tempo morto do sistema obtidos após a aplicação da aproximação de 1ª ordem com tempo morto, constituem-se das entradas do Modelo de Inferência de Variabilidade.

Tabela 4.16: Valores calculados pelo Modelo de Inferência para Desempenho e Robustez para o caso de estudo 1.

Planta	<i>nosi</i>	<i>deli</i>	RtR1	RtR2
G1	0,9313	0,0511	0,5838	0,8068
G2	0,9264	0,0417	2,5499	1,6073

Fornecendo então tais entradas ao Modelo de Inferência de Variabilidade foi possível obter os valores preditos de alteração de variabilidade a qual as malhas de controle estão sujeitas. Estes valores foram comparados com o obtido para o sistema via simulação, sendo que a Tabela 4.17 mostra os resultados de tal comparação.

Tabela 4.17: Valores de V_A preditos em comparação com os valores de V_A teóricos para o caso de estudo 1.

Planta	Valor Predito	Valor Teórico	Erro Absoluto	Erro Percentual
G1	-0,0279	-0,0249	0,0031	10,96%
G2	0,0343	0,0275	0,0068	19,73%

É observado a partir dos resultados da Tabela 4.17 que o erro entre o valor predito e o valor teórico apresentou valores similares aos obtidos no estudo das malhas de controle cujo modelo de planta pode ser representado por uma função de 1ª ordem (Tabela 4.12), significando deste modo que a capacidade de predição do modelo de inferência se manteve para sistemas com ordem mais elevada.

Visando confirmar essa capacidade de predição, é apresentada a seguir a análise de sensibilidade realizada para esse caso de estudo. Tal análise foi, igualmente à realizada para sistemas de 1ª ordem, realizada para duas situações distintas.

Na primeira situação, mantendo-se constantes em seus valores nominais os parâmetros de entrada, ou seja, a constante de tempo, o tempo morto e os índices *nosi* e *deli*, os valores de RtR1 e RtR2 foram variados dentro dos intervalos pré-definidos constantes da Tabela 4.18.

Tabela 4.18: Intervalo dos parâmetros RtR1 e RtR2 utilizados para a análise de sensibilidade para o caso de estudo 1.

Planta	RtR1	RtR2
G1	0.1:0.1:2	0.2:0.2:4
G2	0:0.05:3	0:0.05:3

OBS.: Os intervalos são definidos segundo a notação do Matlab® (início: passo: fim).

Na Figura 4.9 é apresentado o resultado da análise de sensibilidade para a primeira situação. Pelo estudo da mesma, verifica-se que a função alteração de variabilidade se apresenta com valores coerentes para cada malha de controle analisada. Nas circunstâncias em que ocorre um aumento no valor de RtR2, pode-se observar que a função alteração de variabilidade tende a apresentar valores cada vez mais negativos. O contrário também se observa, ou seja, ao se assumir que o desempenho em malha aberta seja mais rápido do que em malha fechada os valores da função alteração de variabilidade tendem a aumentar, indicando dessa forma que a variância foi aumentada.

Atentando para a escala de valores da função alteração de variabilidade, é verificado que um pequeno erro na estimativa do desempenho desejado, RtR2, pode ocasionar a predição equivocada da alteração de variabilidade. Tal fato torna-se mais evidente para valores de RtR2 próximos a zero. Nessa região observa-se que uma pequena variação no valor de RtR2 acaba ocasionando uma inversão de sinal no valor da alteração de variabilidade. Isso pode erroneamente indicar que uma malha pode ter variância reduzida quando na verdade ela pode ter sua variância aumentada, por exemplo.

Pode-se ainda observar que a função alteração de variabilidade apresenta um comportamento suave quando da alteração dos parâmetros indicativos do desempenho da malha de controle, evidenciando assim a boa capacidade de predição do modelo de inferência utilizado para prever os valores de tal função.

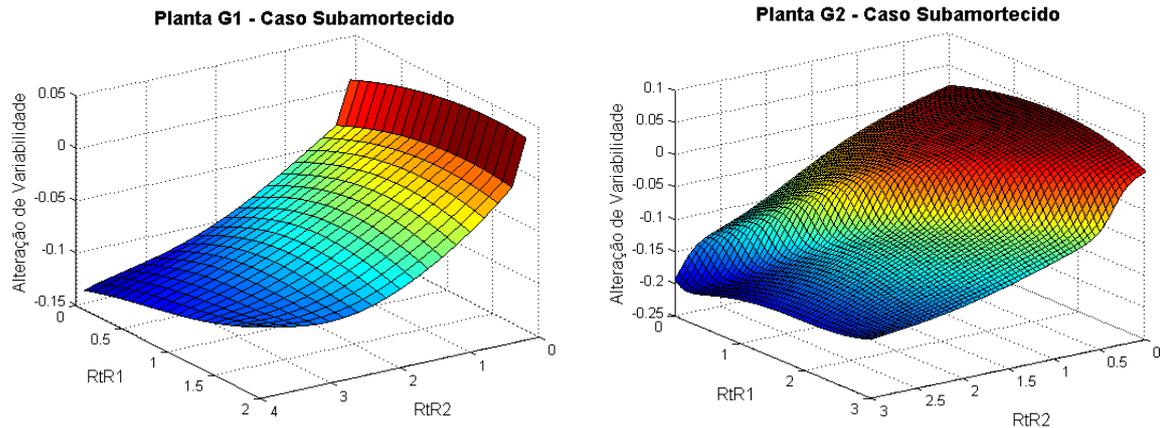


Figura 4.9: Comportamento da alteração de variabilidade em função da variação dos parâmetros $RtR1$ e $RtR2$ para sistemas com resposta subamortecida.

Para a segunda situação, a análise de sensibilidade foi realizada mediante alteração dos valores da constante de tempo e do tempo morto em intervalos pré-definidos de acordo com a Tabela 4.19. Uma vez que os valores de *nosi* e *deli* são calculados a partir do tempo morto, esses valores também foram variados de acordo com o valor do tempo morto. Dessa forma, os únicos parâmetros de entrada constantes para essa análise de sensibilidade foram as razões entre tempo de subida em malha aberta e fechada, $RtR1$ e $RtR2$.

Tabela 4.19: Intervalo dos parâmetros τ e θ utilizados para a análise de sensibilidade para o caso de estudo 1.

Planta	τ	θ
G1	70:0,5:80	4:0,1:6
G2	45:0,5:55	1:0,1:3

OBS.: Os intervalos são definidos segundo a notação do Matlab[®] (início: passo: fim).

A Figura 4.10 ilustra o resultado da análise de sensibilidade resultante para a segunda situação. Nela é possível observar uma semelhança entre os comportamentos das curvas, indicando que apesar da função alteração de variabilidade sofrer forte influência do tempo morto, o erro na estimativa deste apresenta as mesmas características tanto para malhas de controle que tiveram sua variabilidade reduzida quanto para aquelas que tiveram sua variabilidade aumentada. Evidencia-se ainda o comportamento suave das curvas, o que indica a boa qualidade de interpolação do modelo de inferência proposto.

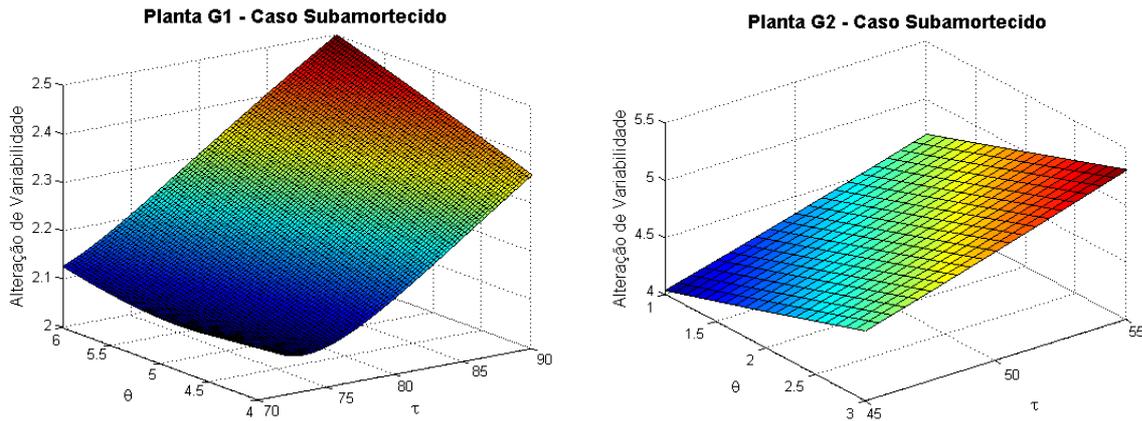


Figura 4.10: Comportamento da alteração de variabilidade em função da variação do tempo morto e da constante de tempo da planta para sistemas com resposta subamortecida.

Caso 2: Modelo de 2ª Ordem com Resposta Superamortecida

Sistemas com resposta superamortecida a uma perturbação degrau apresentam comportamento semelhante à resposta de um sistema de 1ª ordem. Nestes casos, o valor do fator de amortecimento, ξ , irá determinar a rapidez da resposta do sistema a uma perturbação, sendo que à medida que o fator de amortecimento aumenta, o sistema torna-se mais lento.

Para o estudo de malhas de controle as quais apresentam um modelo de planta que pode ser descrito por uma função de transferência de 2ª ordem com fator de amortecimento maior que a unidade, considerou-se para a simulação os modelos constantes na Tabela 4.20. Ainda, para a geração dos dados das malhas de controle via simulação, os valores da intensidade do ruído e da razão entre a constante de tempo da planta e a constante de tempo da perturbação foram considerados como sendo iguais aos valores dados na Tabela 4.21.

Tabela 4.20: Conjunto de plantas de 2ª ordem com resposta superamortecida utilizadas para o caso de estudo 2.

Planta	Modelo
G1	$\frac{10s+1}{625s^2+100s+1} e^{-5s}$
G2	$\frac{10s+1}{25s^2+11s+1} e^{-3s}$

Tabela 4.21: Valores dos parâmetros b_t e τ/τ_d utilizados para a obtenção das duas malhas de controle do caso de estudo 2.

Planta	b_t	τ/τ_d
G1	1	1
G2	0,25	1,5

A resposta a uma perturbação do tipo degrau na entrada de tais sistemas é mostrada na Figura 4.11.

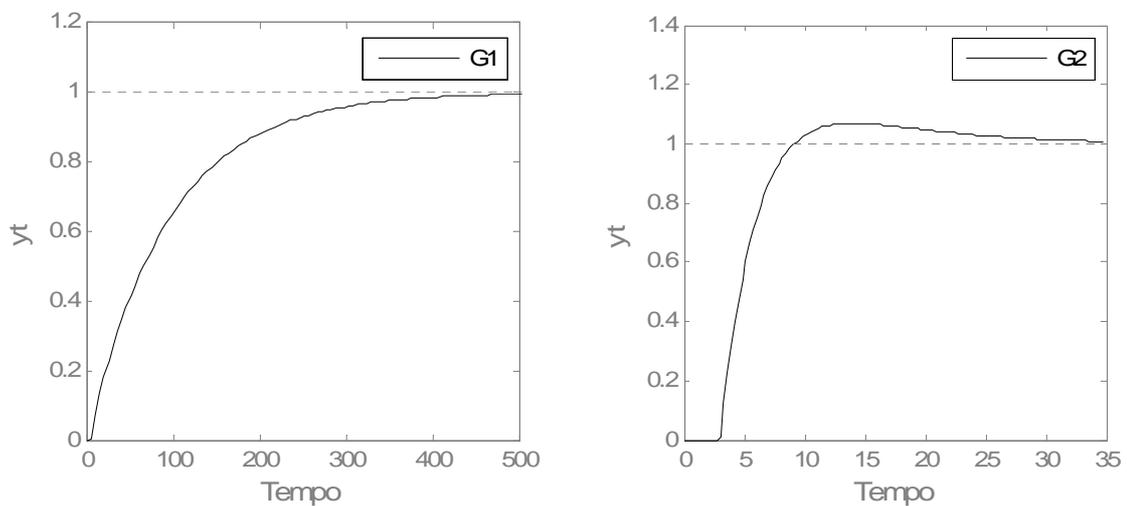


Figura 4.11: Respostas para os sistemas de 2ª ordem considerados no caso de estudo 2, quando submetidos a uma perturbação do tipo degrau na sua entrada.

A malha de controle 1 teve um aumento na rapidez de sua resposta, pelo aumento do valor do ganho proporcional de 0,5 para 0,75. Já a malha de controle 2 teve o ganho proporcional alterado de 0,75 para 0,5, visando a obtenção de respostas mais lentas.

Tendo sido então, pela simulação, gerados os dados pertinentes a cada malha de controle para antes e depois de tais ajustes, foram calculados a partir do Modelo de Inferência para Desempenho e Robustez os indicadores de desempenho que são as entradas do modelo de inferência proposto neste trabalho. Os mesmos podem ser visualizados na Tabela 4.22.

Tabela 4.22: Valores calculados pelo Modelo de Inferência para Desempenho e Robustez para o caso de estudo 2.

Planta	<i>nosi</i>	<i>deli</i>	RtR1	RtR2
G1	0,8190	0,1810	0,1463	1,0033
G2	0,9135	0,0815	2,5499	1,6073

Fornecendo esses indicadores, mais o tempo morto e a constante de tempo da planta ao Modelo de Inferência de Variabilidade é possível obter os valores de V_A preditos. Tais valores são comparados na Tabela 4.23 com os valores de V_A calculados a partir da variância observada para os dados obtidos via simulação, antes e depois dos ajustes realizados.

Tabela 4.23: Valores de V_A preditos em comparação com os valores de V_A teóricos.

Planta	Valor Predito	Valor Teórico	Erro Absoluto	Erro Percentual
G1	-0,0754	-0,0579	0,0175	23,17%
G2	0,0548	0,0329	0,0219	39,94%

Conforme é percebido pelos valores tanto do erro absoluto quanto do erro teórico, a capacidade de predição do modelo de inferência para casos em que o sistema apresenta resposta superamortecida se apresenta dentro do observado nos casos anteriores de estudo.

De maneira análoga à análise de sensibilidade realizada para o caso de estudo 1, a análise de sensibilidade para esse caso de estudo foi realizada para duas situações distintas. Nesta primeira situação os valores da constante de tempo, do tempo morto e dos índices *nosi* e *deli* foram mantidos constantes e as razões entre tempo de subida em malha aberta e fechada foram variados dentro dos intervalos da Tabela 4.24.

Tabela 4.24: Intervalo dos parâmetros RtR1 e RtR2 utilizados para a análise de sensibilidade para o caso de estudo 2.

Planta	RtR1	RtR2
G1	0.8:0.02:2.5	0.8:0.02:2.5
G2	1:0.1:3.5	1:0.1:3.5

OBS.: Os intervalos são definidos segundo a notação do Matlab® (início: passo: fim).

Na Figura 4.12 é possível observar o comportamento da função alteração de variabilidade quando da variação dos parâmetros $RtR1$ e $RtR2$. Além do comportamento suave, indicativo da boa capacidade de predição do modelo de inferência, pode-se observar que para a malha de controle 1, a qual antes das melhorias apresentava uma resposta considerada mais lenta (valor de $RtR1$ de 0,1463), pequenas melhorias no desempenho dessa implicam em um potencial de redução de variabilidade cada vez maior. Logo, é possível evidenciar que um erro na estimativa do desempenho desejado, $RtR2$, acaba por afetar mais fortemente o resultado predito para a alteração de variabilidade em malhas consideradas mais lentas.

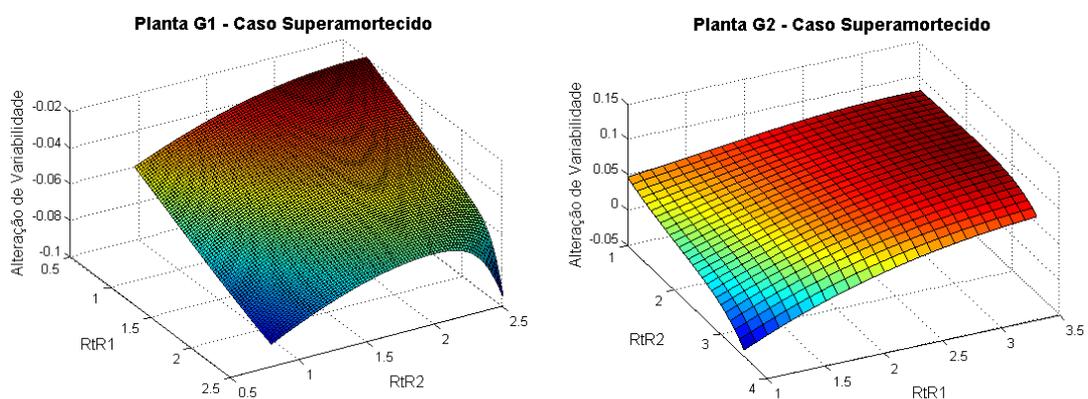


Figura 4.12: Comportamento da alteração de variabilidade em função da variação dos parâmetros $RtR1$ e $RtR2$ para sistemas com resposta superamortecida.

Considerando uma segunda situação na qual os valores do tempo morto e da constante de tempo e conseqüentemente dos índices *nosi* e *deli* foram variados dentro dos intervalos pré-definidos na Tabela 4.25, foram obtidos os gráficos ilustrados na Figura 4.13, demonstrativos do comportamento da função alteração de variabilidade em relação à variação dos parâmetros de entrada acima citados.

Tabela 4.25: Intervalo dos parâmetros τ e θ utilizados para a análise de sensibilidade para o caso de estudo 2.

Planta	τ	θ
G1	20:0,5:30	4:0,1:6
G2	4,5:0,5:5,5	2:0,1:4

OBS.: Os intervalos são definidos segundo a notação do Matlab® (início: passo: fim).

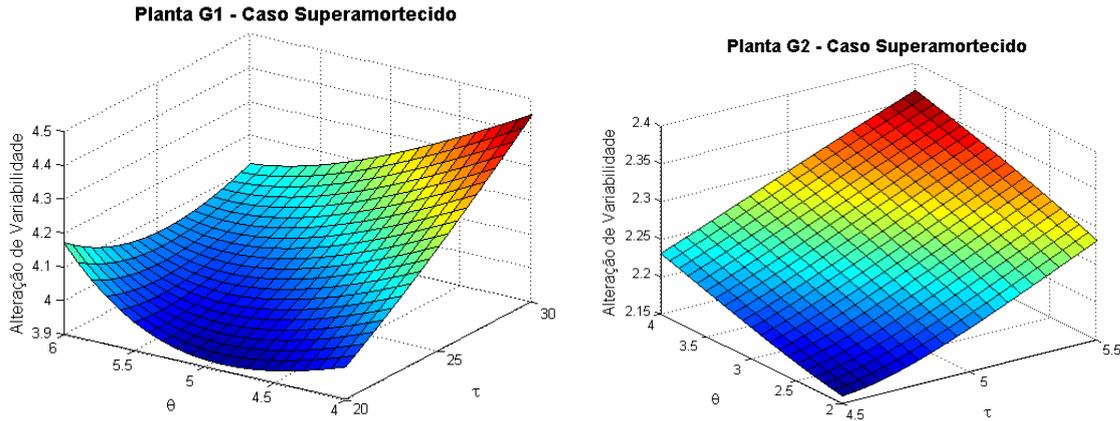


Figura 4.13: Comportamento da alteração de variabilidade em função da variação do tempo morto e da constante de tempo da planta para sistemas com resposta superamortecida.

Apesar de predizerem valores de alteração de variabilidade distintos do esperado, pois a variação do tempo morto afeta também os índices *nosi* e *deli* e, por conseguinte os valores preditos é observado que a função alteração de variabilidade apresenta um comportamento suave. Além disso, é demonstrado o quanto um erro na estimativa do tempo morto pode alterar a predição do modelo de inferência.

Caso 3: Modelo de 2ª Ordem com Resposta Inversa

Respostas inversas decorrem da combinação de duas dinâmicas opostas. Nesse caso, o sistema inicialmente responde para o lado que possui dinâmica mais rápida, mas no final o ganho maior (inverso) se sobrepõe. A velocidade do controlador será limitada pela resposta inversa e por isso deve se assumir uma configuração mais lenta para que a informação referente à resposta inversa não determine a ação de controle, o que pode causar até a desestabilização do processo.

Visando, portanto ao estudo de tais sistemas foram utilizadas as plantas representadas pelas funções de transferência da Tabela 4.26. Considerando ainda a razão entre a constante de tempo da planta e a constante de tempo da perturbação com valor unitário e a intensidade do ruído de 0,25, obtiveram-se, a partir da simulação do sistema representado na Figura 4.3, duas configurações de malha de controle.

Para a malha de controle 1, assumiu-se que o seu desempenho poderia ser melhorado pelo incremento em 0,25 no valor do ganho proporcional. Já para a malha de controle 2, com a alteração do ganho proporcional de 0,75 para 0,5, o seu desempenho em malha fechada tende a assumir características mais lentas.

Tabela 4.26: Conjunto de plantas de 2ª ordem com resposta inversa utilizadas para o caso de estudo 3.

Planta	Modelo
G1	$\frac{-20s+1}{5625s^2+150s+1}e^{-10s}$
G2	$\frac{-5s+1}{25s^2+10s+1}e^{-s}$

A resposta a uma perturbação do tipo degrau na entrada de tais sistemas é mostrada na Figura 4.14.

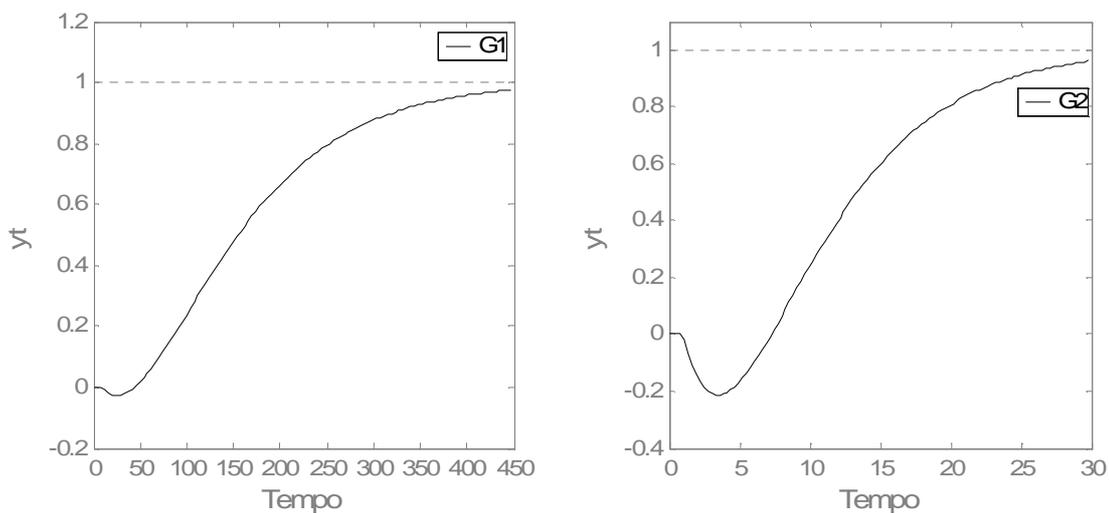


Figura 4.14: Respostas para os sistemas de 2ª ordem considerados no caso de estudo 3, quando submetidos a uma perturbação do tipo degrau na sua entrada.

Ao se aplicar o Modelo de Inferência para Desempenho e Robustez aos dados gerados via simulação foi possível obter os índices constantes na Tabela 4.27. De posse de tais valores obtêm-se, pelo Modelo de Inferência de Variabilidade os valores preditos de alteração de variabilidade, sendo esses comparados com os valores obtidos por meio da simulação realizada que constam na Tabela 4.28.

Tabela 4.27: Valores calculados pelo Modelo de Inferência para Desempenho e Robustez para o caso de estudo 3.

Planta	<i>nosi</i>	<i>deli</i>	RtR1	RtR2
G1	0,8942	0,0661	1,2602	1,8755
G2	0,2737	0,0110	3,0949	1,8422

Tabela 4.28: Valores de V_A preditos em comparação com os valores de V_A teóricos para o caso de estudo 3.

Planta	Valor Predito	Valor Teórico	Erro Absoluto	Erro Percentual
G1	-0,0119	-0,0200	0,0081	68,44%
G2	0,8736	0,5595	0,3141	35,95%

Para sistemas que apresentam resposta inversa a uma perturbação na entrada observa-se que o erro entre V_A predito e V_A teórico difere do erro apresentado pelos demais sistemas, sendo tal erro mais pronunciado ao se considerar a malha de controle em que o modelo da planta apresenta maior resposta inversa.

Tal observação se confirma pela observância à análise de sensibilidade realizada mantendo-se o tempo morto, a constante de tempo e os índices *nosi* e *deli* constantes em seus valores nominais e variando-se as razões entre os tempos de subida em malha aberta e fechada dentro dos intervalos definidos na Tabela 4.29. Tal análise é mostrada na Figura 4.15.

Tabela 4.29: Intervalo dos parâmetros RtR1 e RtR2 utilizados para a análise de sensibilidade para o caso de estudo 3.

Planta	RtR1	RtR2
G1	0.1:0.1:2	0.2:0.2:4
G2	1.5:0.05:3	0:0.1:3

OBS.: Os intervalos são definidos segundo a notação do Matlab® (início: passo: fim).

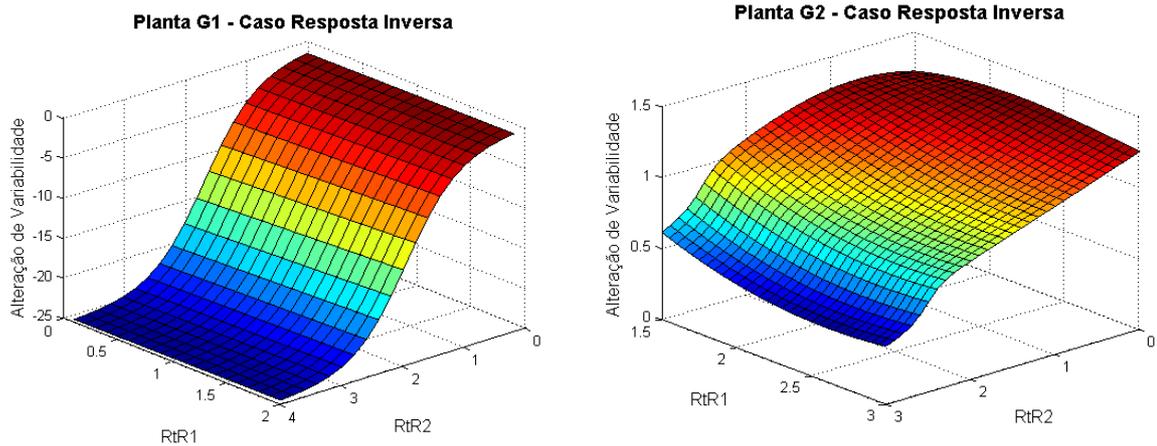


Figura 4.15: Comportamento da alteração de variabilidade em função da variação dos parâmetros $RtR1$ e $RtR2$ para sistemas com resposta inversa.

Ao se alterar, dentro dos intervalos da Tabela 4.30, os valores do tempo morto e da constante de tempo, é observado que, para o sistema com maior resposta inversa, a influência do tempo morto sobre a função alteração de variabilidade é mais pronunciada.

Tabela 4.30: Intervalo dos parâmetros τ e θ utilizados para a análise de sensibilidade para o caso de estudo 3.

Planta	τ	θ
G1	70:0,5:80	9:0,1:11
G2	3,5:0,2:6	1:0,25:4

OBS.: Os intervalos são definidos segundo a notação do Matlab[®](início: passo: fim).

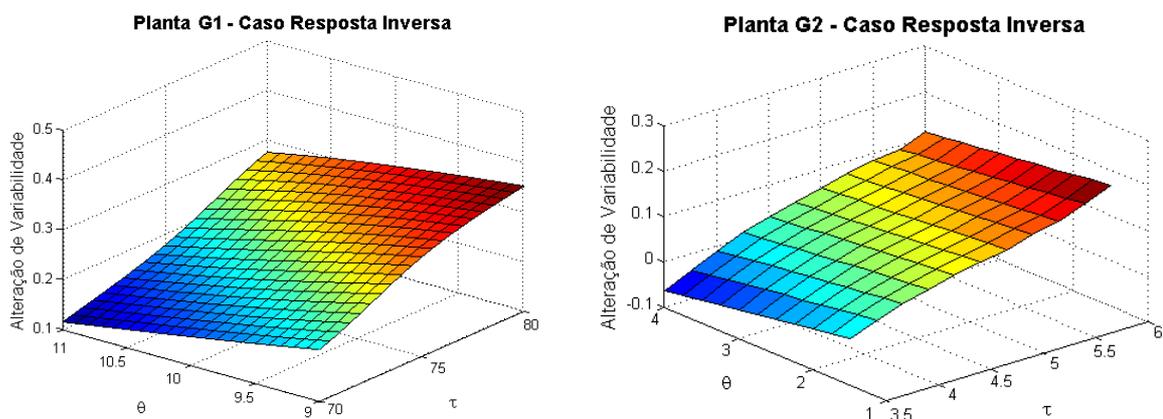


Figura 4.16: Comportamento da alteração de variabilidade em função da variação do tempo morto e da constante de tempo da planta para sistemas com resposta inversa.

Tais observações sugerem uma deficiência no modelo de inferência quando utilizado para sistemas cujo modelo de planta pode ser representado por uma função de transferência de 2ª ordem com resposta inversa.

4.5 Discussões Finais

Para o cálculo da alteração de variabilidade devem ser informados ao modelo de inferência os parâmetros indicativos do desempenho do controlador, $RtR1$ e $RtR2$, o tempo morto e a constante de tempo da planta, além dos parâmetros indicativos dos componentes que apresentam maior influência sobre a variância total do sistema. Visando demonstrar as potencialidades do modelo de inferência proposto, foi analisada nesse capítulo a influência dos parâmetros acima citados sobre a função alteração de variabilidade.

Foi observado que o Modelo de Inferência de Variabilidade apresenta boa capacidade de predição. Além disso, a escolha de um modelo de 1ª ordem mostrou-se bastante satisfatória quando aplicada para os casos de estudo que envolviam modelos de 2ª ordem, sendo assim desnecessária a obtenção de um modelo de inferência específico para esses casos.

Capítulo 5

Caso de Estudo – Modelo de Inferência de Variabilidade

Com o objetivo de exemplificar a metodologia desenvolvida para a estimativa do potencial de alteração de variabilidade de uma dada malha de controle, proveniente da melhoria de técnicas de controle, um estudo foi realizado em uma indústria petroquímica, produtora de resina termoplástica.

Visando a uma melhor compreensão, são apresentadas neste capítulo as principais características das unidades nas quais será aplicada a metodologia proposta.

Apresentar-se-ão, ainda, aspectos pertinentes à aplicação da metodologia, seus resultados e comparações com o obtido no processo industrial. Além disso, as melhorias no desempenho das malhas de controle serão abordadas mediante comparação dos índices mais comumente utilizados, apresentados no Capítulo 3.

5.1 Estruturas de Controle

As unidades as quais a metodologia proposta será aplicada fazem parte do processo *Spheripol*, um dos mais utilizados na produção industrial de polipropileno e seus copolímeros (Reginato, 2001). Tais unidades em estudo fazem parte da seção de recuperação de monômeros e da seção de produção de copolímeros de alto impacto (copolímero heterofásico, ou, mais comumente chamados de HECO).

Nesta seção pretende-se, de forma detalhada, apresentar as estruturas de controle originalmente utilizadas na torre de *stripping*, T01, e no reator a leito fluidizado, RFG, com o intuito de se buscar um melhor entendimento das unidades em estudo com o posterior objetivo de se avaliar de forma quantitativa o potencial de alteração de variabilidade que as principais malhas de controle dessas possam vir a apresentar.

Esta etapa de entendimento das estruturas de controle permite que se obtenha uma visão do que vem sendo praticado em termos de operação da unidade e constitui-se em uma ferramenta importante na análise dos dados que serão posteriormente utilizados na metodologia proposta pela presente dissertação.

Convém ainda ressaltar que outro ponto importante em um estudo que busca a melhoria de uma unidade, em qualquer nível, está vinculado ao entendimento dos processos físicos e químicos envolvidos, pois a partir desse entendimento novas propostas podem surgir, revelando alternativas que não haviam sido avaliadas anteriormente.

5.1.1 Torre de Stripping

O objetivo da torre de *stripping* é a eliminação no *flare* ou o reprocessamento em torre semelhante, denominada torre de *stripping* B2, de componentes leves (hidrogênio, metano, etano, eteno, CO, CO₂, etc.), permitindo que a corrente de fundo, com composição predominante de propeno, seja reutilizada na planta. Junto com os componentes leves, uma quantidade razoável de propeno é também perdida para o *flare*.

A carga e a composição da torre são bastante variáveis, dependendo principalmente do tipo de polímero em produção e da taxa de produção dos reatores, o que leva a uma série de dificuldades operacionais.

No caso de produção de homopolímero, a corrente de topo é encaminhada para a torre de *stripping* B2, ou nos casos em que as colunas não estão alinhadas, a corrente segue para *flare*. A corrente de fundo da torre de *stripping* é parcialmente enviada para a Central de Matérias Primas, que purifica a corrente e revende para a companhia a um valor inferior ao dos monômeros virgens; e o restante é encaminhado para a primeira torre de lavagem de propeno e dessa segue para ser reutilizada no processo. A carga da coluna neste tipo de campanha é constituída basicamente por propano e propeno, sendo encontradas ainda pequenas frações de etano.

A Figura 5.1 apresenta um fluxograma simplificado da torre de *stripping* (denominada nesse estudo de T01). Nesse fluxograma, é possível a visualização das correntes de

alimentação e descarga da torre, assim como os respectivos instrumentos de medição para controle.

Camada de Controle Regulatório

Um sistema de controle de colunas de destilação tem os seguintes objetivos:

- manter a estabilidade operacional, ou seja, o inventário de massa e energia na coluna;
- garantir a separação desejada.

Tais objetivos são alcançados por dois níveis de controle, a saber: controle do inventário e controle da separação.

Tendo como objetivo estabilizar a operação, o controle regulatório de inventários é composto pelos controles de nível (inventários de líquido) e de pressão (inventário de vapor) do equipamento.

Para o controle de nível do fundo da coluna, a estratégia de controle adotada é o controle em cascata. Nessa estrutura de controle são utilizados dois controladores. Um deles, chamado de controlador primário (*master*), fornece o *setpoint* para o controlador secundário (*slave*), que por sua vez gera o sinal para o elemento final de controle. No caso da referida malha, o LIC01 (controlador primário) opera enviando o *setpoint* para o FIC02 (controlador secundário) que atua na vazão de fundo que segue para o processo.

O líquido no condensador tem seu nível medido pelo LIC02, e volta por gravidade para a torre, passando pela válvula V01 e sendo a vazão de retorno medida pelo FIC04 e a temperatura pelo TI02. A pressão da coluna (PIC01) atua na vazão de água gelada para o condensador (PIC01.OUT), sendo que a válvula de manipulação dessa variável apresenta um batente eletrônico de máximo, impedindo que a mesma abra acima de um dado valor, evitando-se assim o uso excessivo de água gelada, o que pode ocasionar falta em outros pontos da planta.

Parte dos vapores não condensados segue para queima no *flare*, sendo a vazão medida pelo FIC07 após passar pela válvula V07.

Além do controle regulatório de inventários, é necessário buscar o ajuste das correntes de produto. Para atingir tal objetivo utiliza-se o controle da separação, que possibilita o ajuste do fracionamento da coluna.

Para isso, parte do líquido de fundo da coluna é aquecido no refeedor E02 e retorna à torre. O aquecimento é realizado com vapor, que passa pela válvula V04 e tem a vazão determinada pelo FIC03. Esse controle é utilizado para alterar a razão de refluxo da coluna, ou seja, alterar a eficiência de separação do equipamento.

Além disso, a corrente de fundo é analisada pelo cromatógrafo AI01, que determina a concentração dos principais componentes, sendo então dividida em duas correntes, uma que retorna ao processo, sendo medida pelo FIC02, após a válvula V02, e outra que segue para a Central de Matérias Primas. A corrente que volta ao processo é misturada com uma corrente de monômeros puros provindos da Central de Matérias Primas, no tanque pulmão TQ01, retornando ao sistema de reação. Nesse ponto, tem-se um sistema de controle automático de composição de inertes pesados no sistema (AIC02), que atua diretamente na corrente que segue do fundo da T01 para a Central de Matérias Primas. Tal controle tem por objetivo manter a composição de propano de saída do tanque TQ01 em um dado valor (em % molar), mantendo-se assim a uniformidade na concentração de inertes pesados no sistema, a uniformidade na concentração da corrente que retorna ao processo e também garantindo uma vazão mínima de retorno à Central de Matérias-Primas.

A redução das vazões de inertes do processo deve respeitar certos limites operacionais. A corrente de retorno para a Central de Matérias-Primas deve garantir que o vaso TQ01 tenha uma concentração de inertes aceitável. Já a corrente de topo que segue para a queima no *flare*, deve garantir uma concentração abaixo de um limite (na faixa de ppms) de componentes leves no fundo.

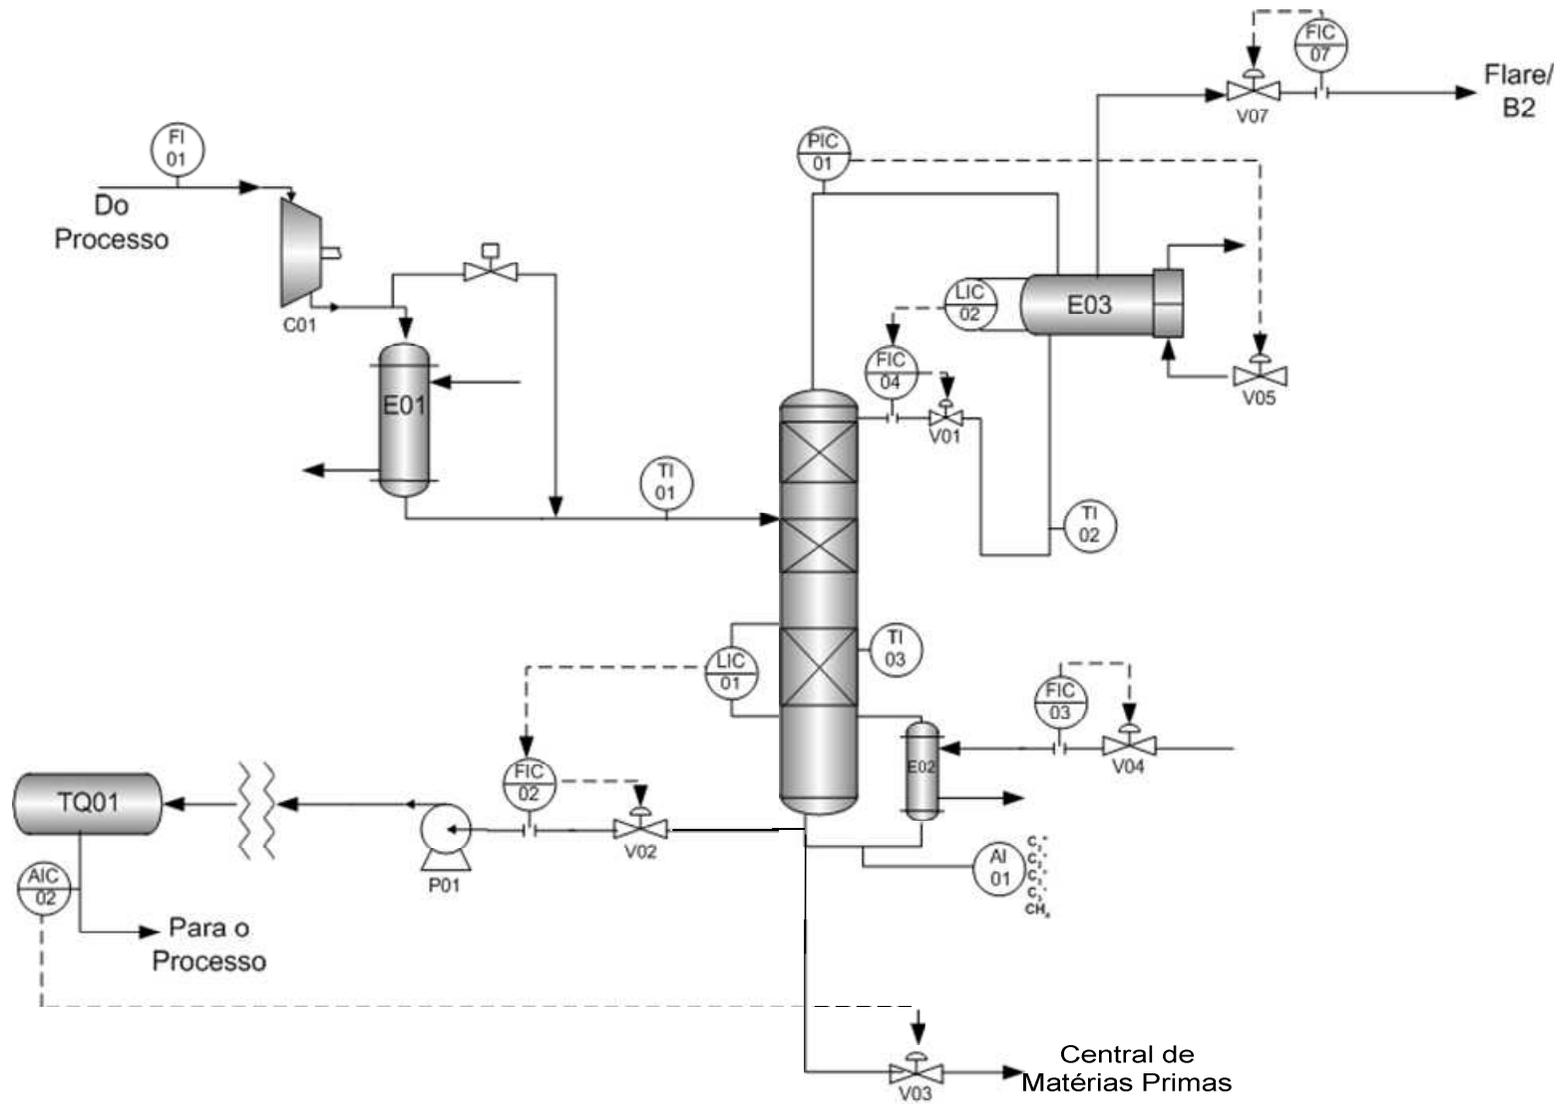


Figura 5.1: Fluxograma simplificado da torre de stripping (Adaptado de Farina et al., 2007).

5.1.2 Reator a Leito Fluidizado

No processo *Spheripol*, concebido pela *Basell* em 1982, tem-se a possibilidade de produção de materiais poliméricos com quantidades elevadas de comonômero (mais comumente eteno), como é o caso de materiais altamente resistentes ao impacto (Reginato, 2001). Esses são denominados de copolímeros de alto impacto (copolímero heterofásico, ou, mais comumente chamados de HECO) e são produzidos por meio de um reator a leito fluidizado (também chamado de reator fase gás, RFG) que opera em série com os reatores *loop*. Pela fluidização, as partículas de polímero são mantidas em suspensão no reator num nível tal que existe uma constante colisão entre as partículas de polímero, bem como entre as partículas de polímero e as paredes do reator. Nesse reator forma-se uma segunda camada de copolímero eteno-propeno amorfa e de característica borrachosa, também conhecida como EPR (*ethylene/propylene rubber*) na parte interna da matriz polimérica produzida no primeiro estágio de reação.

Para a produção de HECO, o homopolímero, após a separação de monômeros ocorrida no vaso de *flash*, flui por diferença de pressão à zona superior do leito fluidizado e percorre o mesmo na descendente, em contracorrente com a mistura gasosa eteno/propeno/hidrogênio, saindo por um coletor cônico no fundo. Os monômeros então reagem formando bipolímero sobre a matriz homopolimérica formada nos loops. Os monômeros não-reagidos são reciclados ao reator através de um compressor centrífugo. É este compressor, portanto que mantém a fluidização do leito. Nesta corrente circulante são feitas as alimentações de eteno, hidrogênio e propeno.

Para o presente estudo, somente a malha de controle de temperatura do reator será analisada e, portanto somente tal controle será melhor detalhado.

Camada de Controle Regulatório

O controle de temperatura de um reator de polimerização é um elemento crítico na operação de uma planta petroquímica, uma vez que está atrelado às questões de especificação dos produtos, de manutenção da taxa de produção da planta e de segurança.

A temperatura de operação do reator a leito fluidizado é definida pela receita do produto, podendo-se ajustar este valor conforme as condições de operação do reator no que diz respeito à atividade do catalisador nos reatores *loop* e ao valor do eteno ligado pretendido (Neumann *et al.*,2008).

Para tal, o controle da temperatura é realizado por um sistema em cascata de dois controladores PID. Neste sistema, a temperatura do reator (TIC03) é controlada pela

manipulação da temperatura do fluido de resfriamento dos gases de recirculação do reator (TIC04) atuando sobre as válvulas TV-04A/B em split-range.

A Figura 5.2 detalha a configuração do sistema de troca térmica do reator a leito fluidizado, sendo ilustrados os equipamentos, as correntes envolvidas e os medidores de temperatura e vazão existentes no circuito térmico.

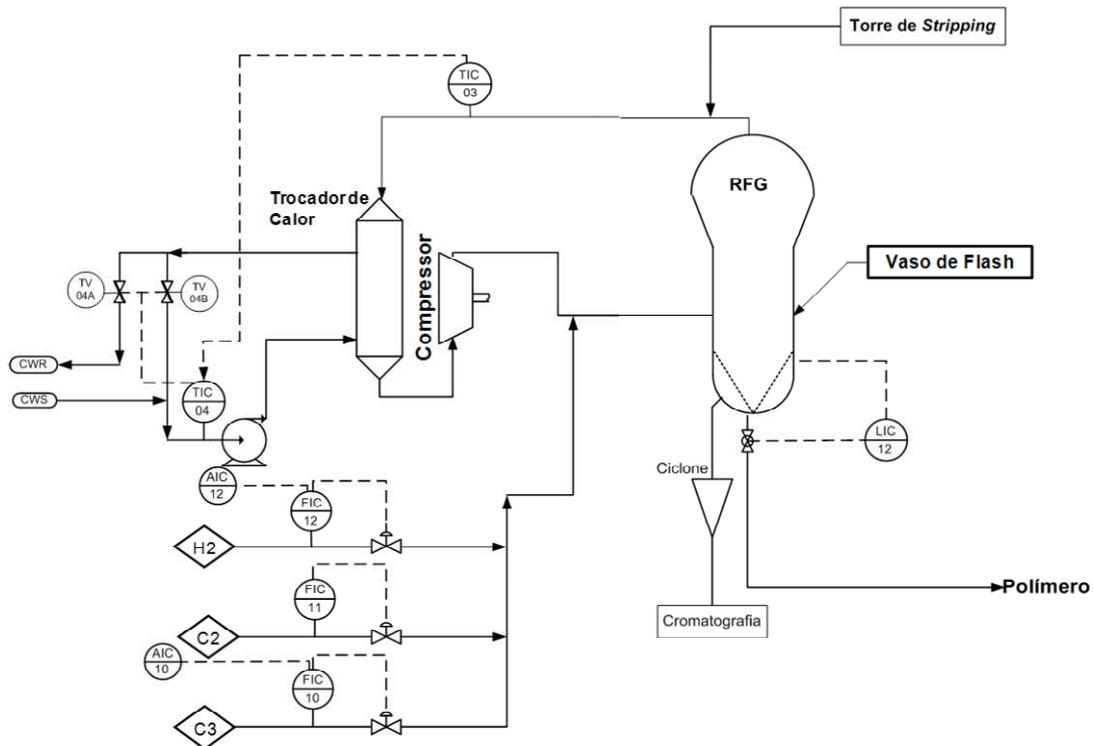


Figura 5.2: Fluxograma simplificado do sistema de controle do reator a leito fluidizado (Adaptado de Neumann *et al.*, 2008).

5.2 Melhoria do Controle Regulatório

Em um projeto de controle deve-se ter em mente que o controle regulatório é a base de uma operação industrial. Sendo a base, é de extrema necessidade que a mesma seja bem projetada e esteja sempre bem sintonizada, a fim de se evitar o mau funcionamento das ferramentas que dela dependem.

Sendo assim, em todo o projeto de controle que visa à otimização e implantação de técnicas de controle avançado, deve-se ter uma etapa que contemple uma análise da camada de controle regulatório. Tal análise é, portanto de suma importância, uma vez que com ela é possível identificar importantes pontos de melhoria que poderão contribuir para o sucesso econômico do projeto.

Na presente dissertação, tal análise foi realizada para as principais malhas de controle da torre de *stripping* T01 e para a malha de controle de temperatura do reator a leito fluidizado. Nessa análise insere-se o Modelo de Inferência de Variabilidade, proposta deste trabalho.

Tendo vislumbrado possíveis pontos de melhoria com a análise anterior, procede-se ao melhoramento das malhas de controle, por meio de alterações em seus parâmetros de sintonias.

Dessa forma, é possível comparar os resultados de antes e depois das melhorias nas malhas de controle e assim avaliar a capacidade de predição do Modelo de Inferência de Variabilidade. Ainda foi possível comparar as diferentes métricas de desempenho, e para isso contou-se com o auxílio de uma ferramenta de avaliação de desempenho de malhas de controle, através do software TriCLPM[®] desenvolvido pela empresa de engenharia TriSolutions em parceria com a Petrobrás, UFRGS e FINEP. Além do uso de tal ferramenta, utilizou-se o Modelo de Inferência para Desempenho e Robustez, visando a obtenção das entradas necessárias para o cálculo da alteração de variabilidade através do Modelo de Inferência de Variabilidade.

É importante ressaltar que, para todas as malhas, foram analisados dados em operação normal sem alteração nos valores de *setpoint* em períodos anteriores e posteriores as melhorias. Analisou-se em torno de 1500 pontos para cada malha, com período de amostragem igual a 1 minuto.

5.2.1 Torre de Stripping

As malhas avaliadas foram as diretamente vinculadas ao controle de inventário de líquido e de vapor, além das relacionadas ao controle de fracionamento da coluna. Para a sintonia das malhas de nível pulmão utilizou-se o método proposto por Friedman (1994), que dispensa testes na planta. Para as demais malhas de controle, foi realizado o planejamento de perturbações (*step test*), aplicação de tais e sintonia dos controladores PID pelos métodos do modelo interno (IMC) e da integral do erro (Campos e Teixeira, 2006).

Malha de Controle da Pressão

A malha de controle da pressão (PIC01) busca manter a torre de *stripping* em um valor de pressão constante, uma vez que oscilações bruscas nessa variável influenciam nas condições de equilíbrio líquido-vapor e, por conseguinte, na operação da coluna. Por exemplo, a diminuição da pressão pode provocar a vaporização do líquido no interior da torre,

e tirar de especificação os produtos de topo, ao passo que seu aumento repentino pode provocar condensação do vapor, e tirar de especificação os produtos de fundo da torre.

Pela observância da Figura 5.3 (a), percebe-se que tal controle não está sendo efetivo em sua função, uma vez que os valores de pressão apresentam-se por repetidas vezes abaixo do valor desejado.

Buscando então uma melhora no desempenho dessa malha, pela aproximação da pressão para valores dentro da especificação de projeto, procedeu-se à alteração dos parâmetros de sintonia do controlador, buscando uma sintonia mais rápida, a qual garante maiores ganhos pela redução da variabilidade da variável controlada e pela ação mais rápida na compensação das perturbações.

Realizados os ajustes convenientes, é possível, através dos indicadores de desempenho definidos no Capítulo 3, confirmar que os mesmos mostraram-se efetivos. Tais indicadores apresentam seus valores na Tabela 5.1.

Sendo RtR definido como a razão entre o tempo de subida do sistema em malha aberta e fechada, o seu aumento confirma que foi possível aumentar a velocidade de resposta do sistema, sendo a mesma, após as melhorias realizadas, 3,4 vezes mais rápida em malha fechada quando comparada com a sua resposta em malha aberta.

Por outro lado, durante controle adequado o valor do IAE torna-se pequeno, pois a soma das áreas acima e abaixo do valor de referência é relativamente menor. Portanto, a diminuição do valor do índice IAE, nesse caso, indica uma diminuição na variabilidade da malha de controle de pressão da torre de *stripping*. Essa diminuição na variabilidade também é confirmada pela diminuição na variância da PV na ordem de 41,5%. Entretanto tal diminuição não se refletiu de forma significativa no índice de Harris, evidenciando assim as limitações de baixa resolução de escala desse índice, discutidas e elucidadas em Farenzena e Trierweiler (2006a) e Kayser (2007).

Os índices *nosi*, *deli* e *tuni* indicam a influência de componentes tais como tempo morto, ruído branco e ajuste do controlador sobre a variância total do sistema. Para o cálculo de tais, é necessário fornecer a janela de dados, a constante de tempo e a ordem do modelo auto-regressivo. Para esse caso de estudo, iniciou-se o cálculo desses índices com uma ordem para AR de 5 e foi se aumentando gradativamente a mesma. Com uma ordem de 30, observou-se que os índices não apresentaram mais mudanças consideráveis em seus resultados e, portanto esse foi o valor considerado no cálculo.

Tabela 5.1: Principais índices de desempenho para a malha de controle de pressão PIC01, antes e depois da alteração dos parâmetros de sintonia.

Índices de Desempenho	Antes	Depois
Índice de Harris	0,982	0,929
IAE	446,29	233,76
Variância da PV	0,1231	0,0721
RtR	0,6540	1,7427
<i>nosi</i>	0,1971	0,3521
<i>deli</i>	0,0080	0,0185
<i>tuni</i>	0.9348	0,8973

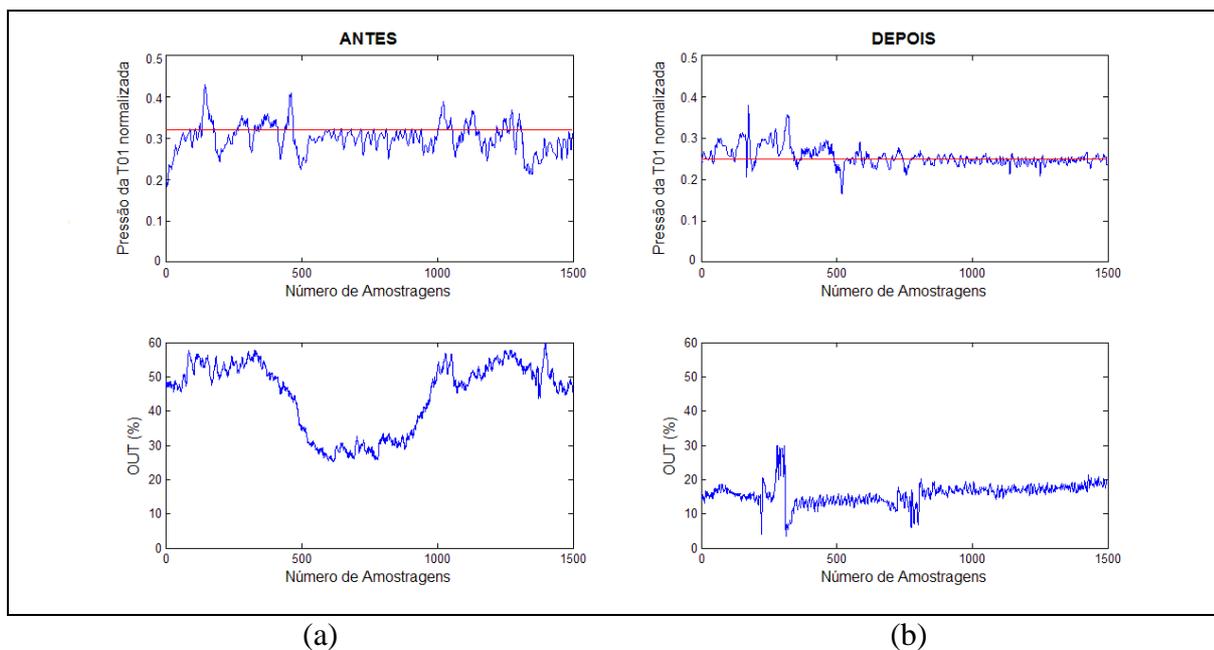


Figura 5.3: Gráficos de tendência representativos do comportamento da pressão da torre de *stripping*. (a) Antes das alterações nos parâmetros de sintonia e (b) Depois das alterações nos parâmetros de sintonia. Nos gráficos acima, em azul observa-se a variável de processo (PV) e em vermelho o valor de referência (SP). Nos gráficos abaixo se tem o valor de abertura da válvula V05.

Analisando então os resultados obtidos para *nosi*, *deli* e *tuni* observa-se que a influência da velocidade do controlador é bastante pronunciada frente aos demais índices.

Observa-se ainda que tal influência diminuiu significativamente após os ajustes realizados na malha de controle, indicando assim que tais ajustes foram efetivos em seu propósito.

Ao se fornecer os valores já conhecidos de RtR de antes e depois dos ajustes, *nosi, deli* e ainda a constante de tempo e o tempo morto da planta (aproximados por uma função de 1ª ordem com tempo morto via Método SK) ao Modelo de Inferência de Variabilidade chega-se a um valor de alteração de variabilidade de -0.6979, ou seja, pelo modelo de inferência proposto foi possível prever que a variância da PV sofreria uma diminuição em seu valor em 69,79%. Comparando esse valor com o obtido na prática (-0.4146) verifica-se um erro absoluto de 0,2833 entre o valor predito e o valor real, mostrando que o modelo de inferência proposto é capaz de prever a alteração de variabilidade de forma coerente, com erro considerado aceitável para os objetivos desse trabalho.

Tal afirmação é confirmada pela observância do gráfico bidimensional da Figura 5.4 que mostra, além da diminuição da alteração de variabilidade em função do aumento de $RtR2$, os pontos referentes à alteração de variabilidade conseguida na prática (ponto marcado com ‘*’) e à alteração de variabilidade predita pelo Modelo de Inferência de Variabilidade (ponto marcado com ‘+’). Observa-se ainda que ao se aumentar a razão entre o tempo de subida do sistema em malha aberta e fechada para depois das melhorias realizadas, $RtR2$, os valores de alteração de variabilidade tendem a patamares cada vez mais negativos, indicando assim que quanto mais bem ajustada for a malha de controle, mais possível será de alcançar uma variância menor da PV.

Pode-se ainda notar que a alteração de variabilidade apresenta um ponto máximo a partir do qual começa a se ter uma redução nesse valor até a sua estabilização em um patamar constante. Isto sugere que o aumento da velocidade de resposta da malha de controle é capaz de ocasionar uma redução na variância da PV, porém esse aumento atinge um dado valor no qual qualquer alteração além acaba por não provocar mais uma redução efetiva na variância da malha de controle.

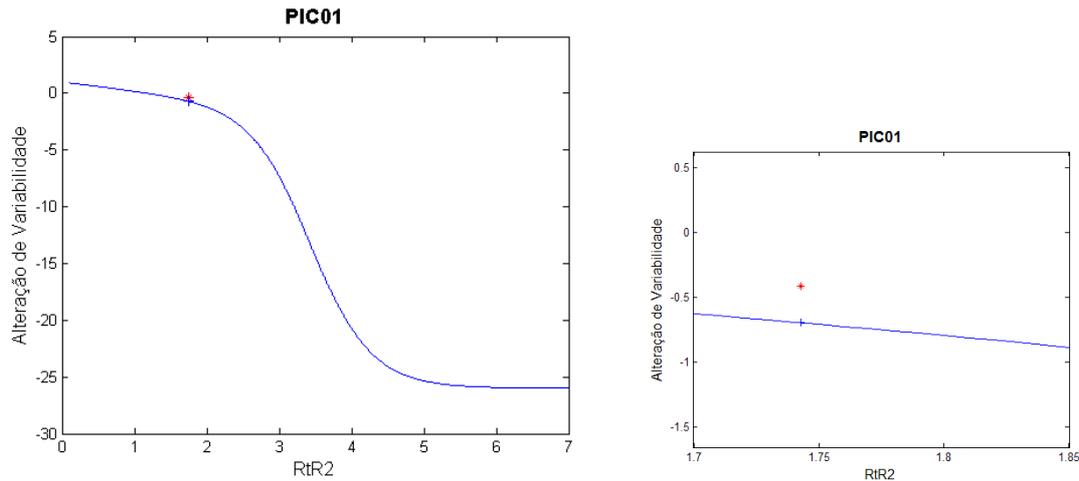


Figura 5.4: Potencial de alteração de variabilidade da malha de controle da pressão da torre de *stripping* em função do aumento de velocidade da mesma. O ponto marcado com “*” refere-se à alteração de variabilidade conseguida na prática enquanto que o ponto marcado com “+” refere-se à alteração de variabilidade predita pelo Modelo de Inferência de Variabilidade. O gráfico a direita mostra em escala maior estes dois pontos.

Malha de Nível da Torre de Stripping

Para esta malha o objetivo é aproveitar o fundo da torre de *stripping* como um vaso pulmão. Dessa forma é possível amortecer as perturbações que poderiam afetar outras partes da unidade, conseguindo-se assim uma maior estabilidade operacional. Além disso, trabalhando-se com o fundo da torre de *stripping* como um vaso pulmão, existe a possibilidade de se atenuar possíveis variações na qualidade dos produtos.

Sendo assim, ao se realizar a resintonia de uma malha de nível pulmão deve-se procurar um controle pouco agressivo (mais lento) que possibilite que o nível trabalhe amortecendo as perturbações do sistema. Com a resintonia observa-se que a variabilidade da variável de processo (PV) aumenta. Com o aumento, portanto, do valor da soma das áreas formadas entre a curva da variável de processo e a curva do *setpoint* o valor do índice de desempenho IAE tende a aumentar também. Importante ressaltar que tal comportamento não seria desejável para outros tipos de malhas, pois assim o desempenho está sendo deteriorado.

Configura-se dessa forma como necessária, ao se realizar uma análise do desempenho de uma dada malha de controle, a distinção entre malhas com configuração de nível pulmão e malhas com configuração de nível *setpoint*, sendo que a correta informação sobre esse aspecto é importante para a tomada de ações corretivas envolvendo a sintonia de malhas de nível.

Tendo-se definido que a malha a ser resintonizada tem a característica de nível pulmão, uma análise importante a ser realizada é a observância dos valores do fator de ampliação de distúrbios, que mede o quanto um sinal oscilatório é atenuado (ou ampliado) por uma malha de controle. O valor desse índice deve ser menor que a unidade, indicando assim que a malha de controle está atuando efetivamente no amortecimento das perturbações (Kempf, 2003).

Ratificando o propósito de se ter um controle mais lento, o valor da razão entre o tempo de subida do sistema em malha aberta e fechada deve diminuir, indicando dessa forma que o propósito da malha atuar como atenuadora de oscilações foi conseguido.

Tais análises podem ser melhor visualizadas na Tabela 5.2, abaixo. Observa-se ainda, pela Figura 5.5(a), que antes da resintonia da malha de nível do fundo da torre de *stripping* a mesma apresentava-se bastante agressiva, com o controlador ajustado de forma a manter o nível o mais constante possível. Seu fator de ampliação de distúrbios ficou alto: 1,5, mostrando que, apesar do objetivo dessa malha ser de amortecer perturbações, sua sintonia está configurada para manter o valor da variável de processo mais próximo possível do valor de referência

Ao se adotar uma nova sintonia do controlador, com ganho proporcional reduzido e constante de tempo integral aumentada, pode-se observar, pela Figura 5.5(b), que foi conferida à malha de controle do nível do fundo da torre de *stripping* um comportamento de nível pulmão. A mudança de filosofia de controle pode também ser confirmada pela Tabela 5.2, na qual se observa o aumento no índice IAE e a diminuição no fator de ampliação de distúrbios. Além disso, o valor de RtR diminuiu, indicando assim que o tempo de subida em malha aberta é maior do que o tempo de subida em malha fechada. O valor do índice de Harris deve ser analisado com cuidado, uma vez que pela sua interpretação ocorreu uma deterioração no desempenho da malha. Entretanto, por se tratar de uma malha com comportamento de nível pulmão, o aumento no valor do índice de Harris comprova o aumento na variabilidade dessa.

Tabela 5.2: Principais índices de desempenho para a malha de controle de nível do fundo da torre de *stripping*, LIC01, antes e depois da alteração dos parâmetros de sintonia.

Índices de Desempenho	Antes	Depois
Índice de Harris	0,898	0,997
IAE	5157,81	7851,90
Variância PV	27,5519	51,5178
Fator de Ampliação	1,5130	0,3024
R_{tR}	0,6624	0,4462
<i>nosi</i>	0,0950	0.0834
<i>deli</i>	0,0953	0.0972
<i>tuni</i>	0,8097	0.8194

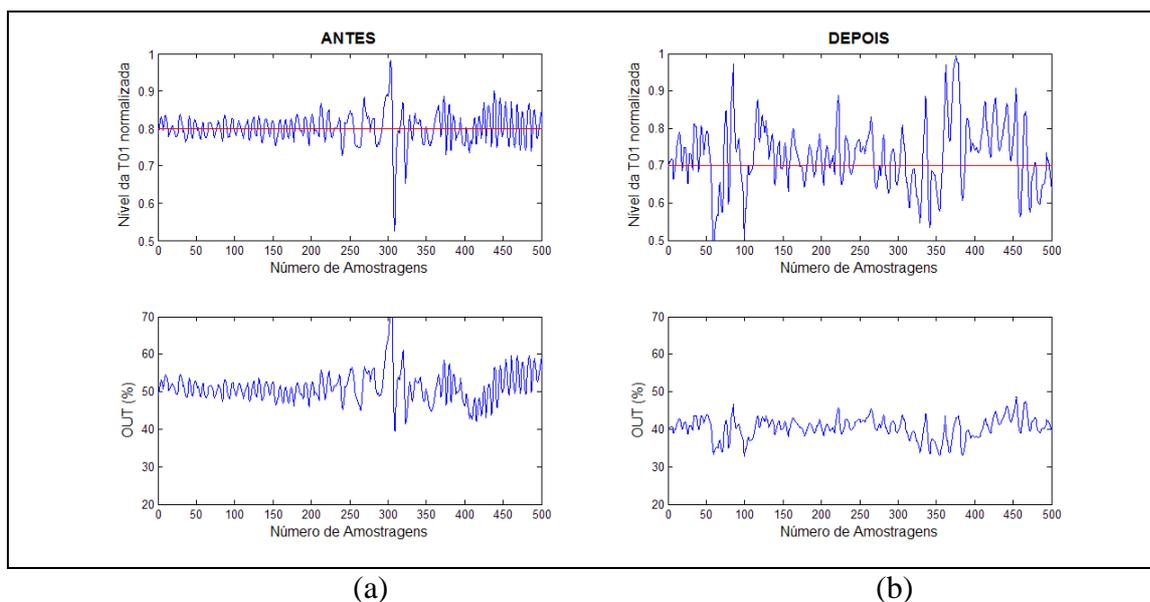


Figura 5.5: Gráficos de tendência representativos do comportamento do nível de fundo da torre de *stripping*. (a) Antes das alterações nos parâmetros de sintonia e (b) Depois das alterações nos parâmetros de sintonia. Nos gráficos acima, em azul observa-se a variável de processo (PV) e em vermelho o valor de referência (SP). Nos gráficos abaixo se tem as ações de controle da malha.

Aproximando a dinâmica desse sistema por uma função de 1ª ordem com tempo morto é obtido os valores da constante de tempo e do tempo morto. Fornecendo esses valores, mais os valores já calculados da razão entre tempos de subida, *nosi* e *deli*, é possível, pelo Modelo de Inferência de Variabilidade prever que a malha de controle de nível de fundo da torre de

stripping pode ter sua variabilidade amplificada em 68,8% face aos 86,9% obtidos na prática. Dessa forma é contabilizado um erro de 26,4% entre o valor predito pelo modelo de inferência e o valor real. Pode-se com isso afirmar que para malhas com comportamento de nível pulmão, as quais se deseja um comportamento mais lento, o Modelo de Inferência de Variabilidade é capaz de predizer de forma coerente o aumento de variabilidade pelo qual a malha pode estar sujeita.

Ao se observar ainda a Figura 5.6, é passível de se observar o comportamento da função alteração de variabilidade para malhas as quais se deseja um comportamento mais lento. O propósito de se obter um maior potencial de aumento da variabilidade com a diminuição da velocidade da malha é confirmado. Para essa malha é verificado que a mesma pode ter ainda sua variabilidade amplificada, pela diminuição ainda maior da razão entre tempo de subida em malha aberta e fechada.

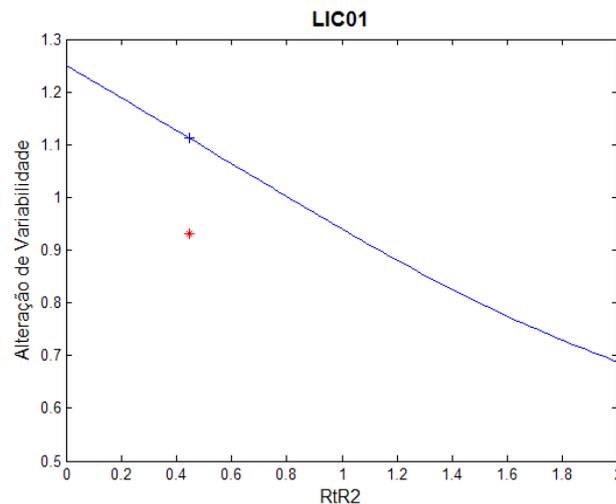


Figura 5.6: Potencial de alteração de variabilidade da malha de controle do nível de fundo da torre de *stripping* em função do aumento de velocidade da mesma. O ponto marcado com ‘*’ refere-se à alteração de variabilidade conseguida na prática enquanto que o ponto marcado com ‘+’ refere-se à alteração de variabilidade predita pelo Modelo de Inferência de Variabilidade.

Malha de Vazão de Vapor

A vazão de vapor é utilizada para alterar a razão de refluxo da coluna, ou seja, alterar a eficiência de separação do equipamento. Através do fornecimento de calor à mistura, consegue-se preferencialmente vaporizar as substâncias mais voláteis, que são condensadas

no topo da coluna. Por sua vez, os componentes menos voláteis tendem a permanecer na fase líquida do fundo da coluna. Dessa forma, a malha de controle da vazão de vapor deve estar configurada de tal forma que o valor da variável de processo não tenha um tempo de resposta elevado, permitindo com isso que pequenas variações nessa variável não acarretem em grandes alterações na eficiência de separação da torre de *stripping*.

Conforme é observado na Figura 5.7(a), a vazão de vapor sofre com picos de valores, que podem alterar de forma significativa a razão de refluxo da coluna. Sendo assim, a ressonância realizada procurou ser mais agressiva, fazendo um controle mais justo da variável de processo em torno do *setpoint*.

Com tal melhoria, é esperado que os índices de desempenho definidos para essa malha tenham seu valor alterado. Tendo em vista que o desempenho em malha fechada foi tornado mais rápido, deve-se verificar um aumento na razão entre tempo de subida em malha aberta e fechada.

Outro ponto importante refere-se ao valor do índice IAE. Caso a melhoria no controlador tenha sido efetiva e o controle passar a ser melhor adequado ao propósito dessa malha de controle, o valor desse indicador deve diminuir. Tal diminuição decorre da diminuição da soma das áreas acima e abaixo do valor de referência, indicativo esse também da redução de variabilidade da variável de processo, conseguida pelos ajustes no controlador.

Tendo então realizado os ajustes necessários nos parâmetros de sintonia do controlador, é evidenciado, pela Tabela 5.3, que tais ajustes trouxeram uma melhora efetiva na malha de controle da vazão de vapor. Observa-se que os principais índices de desempenho dessa malha tiveram uma melhora significativa, sendo que o índice de Harris encontra-se próximo ao valor padrão de 0,2 praticado para malhas de vazão (Kempf, 2003).

Ao se observar ainda o índice *tuni*, o qual quantifica a influência da velocidade do controlador é verificada que sua parcela é bastante pronunciada frente aos demais índices. Observa-se ainda que tal influência diminuiu significativamente após os ajustes realizados na malha de controle, indicando assim que tais ajustes foram efetivos em seu propósito.

A melhoria realizada em tal malha pode ser também ser visualizada na Figura 5.7(b) onde em azul observa-se a variável de processo (PV) e em vermelho o valor de referência (SP).

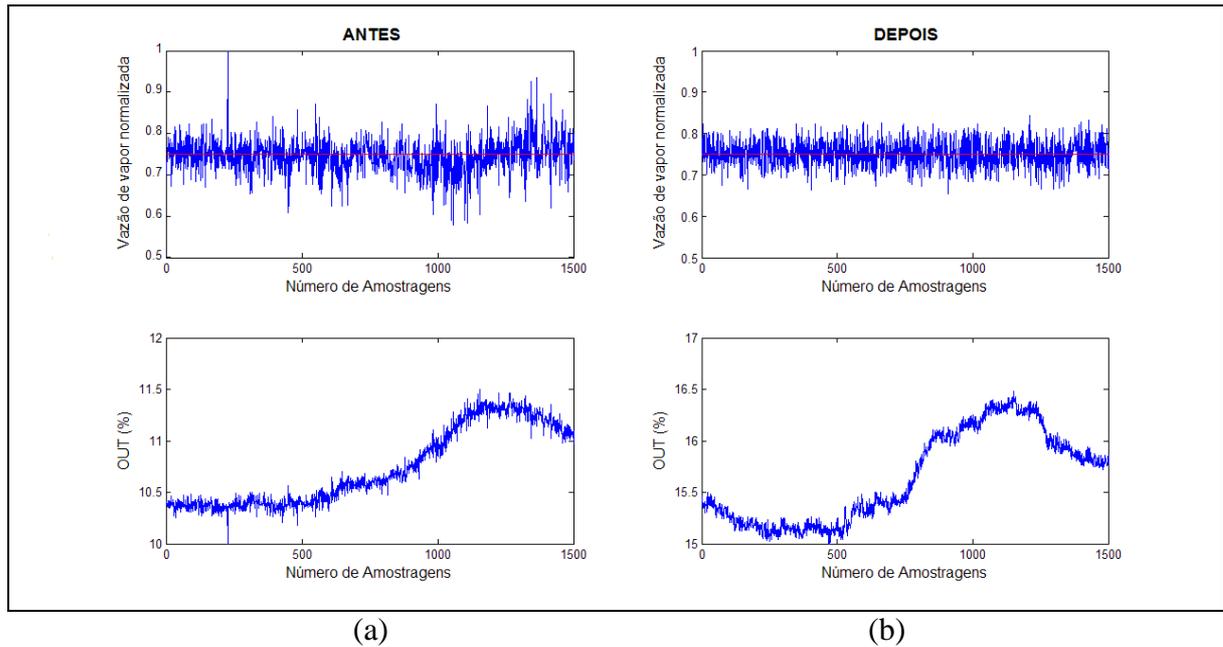


Figura 5.7: Gráficos de tendência representativos do comportamento da vazão de vapor. (a) Antes das alterações nos parâmetros de sintonia e (b) Depois das alterações nos parâmetros de sintonia. Nos gráficos abaixo se tem o valor de abertura da válvula V04.

Tabela 5.3: Principais índices de desempenho para a malha de vazão de vapor, FIC03, antes e depois da alteração dos parâmetros de sintonia.

Índices de Desempenho	Antes	Depois
Índice de Harris	0,140	0,101
IAE	861,77	733,98
Variância PV	0,6514	0,3958
R_{tR}	2,8267	3,1810
<i>nosi</i>	0.2450	0.3693
<i>deli</i>	0.0077	0.0324
<i>tuni</i>	0,7473	0.5893

Ao se analisar a alteração de variabilidade obtida para a malha de vazão de vapor após as melhorias realizadas nos parâmetros de sintonia do controlador, é computado um valor efetivo de redução de variabilidade de -0,3925, ou seja, a variabilidade da variável de processo foi reduzida em 39,25%.

Visando verificar o erro entre esse valor e o valor que seria predito pelo Modelo de Inferência de Variabilidade, deve-se entrar com o valores de tempo morto e constante de tempo aproximados por uma função de 1ª ordem com tempo morto via Método SK, acrescidos das razões entre tempos de subida em malha aberta e fechada, $RtR1$ e $RtR2$, e dos índices *nosi* e *deli* à função desenvolvida em Matlab® para o cálculo de alteração de variabilidade. Feito isso chega-se a um valor de -0,5747, ou seja, pelo Modelo de Inferência de Variabilidade o potencial de redução da variância dessa malha de controle é de 57,47%. Tal valor predito, quando comparado com o valor efetivo conseguido na prática, demonstra um erro relativo de 31,7%, considerado aceitável para os objetivos desse trabalho.

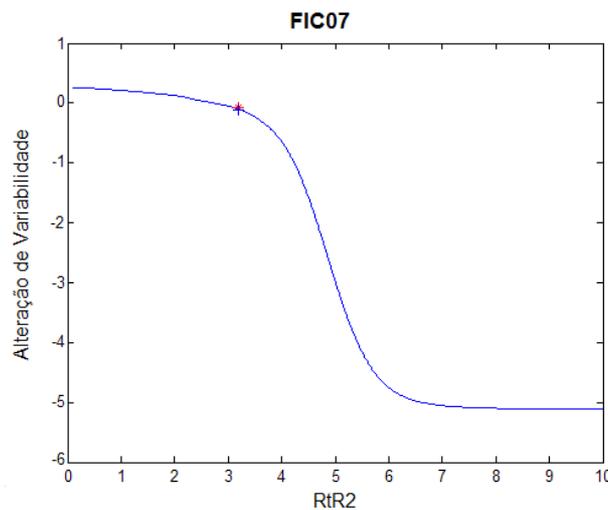


Figura 5.8: Potencial de alteração de variabilidade da malha de controle da vazão de vapor da torre de *stripping* em função do aumento de velocidade da mesma. O ponto marcado com “*” refere-se à alteração de variabilidade conseguida na prática enquanto que o ponto marcado com “+” refere-se à alteração de variabilidade predita pelo Modelo de Inferência de Variabilidade.

Observando ainda o comportamento da função alteração de variabilidade quando do aumento da velocidade do controlador, constata-se que, semelhante à malha de pressão da torre de *stripping*, a malha de vazão de vapor apresenta um valor de $RtR2$ a partir do qual a redução na variabilidade da malha é significativa. Alcançando um valor no qual o tempo de subida em malha fechada é aproximadamente 6 vezes mais rápido do que em malha fechada, o potencial de redução de variabilidade assume um patamar constante. Ao se comparar os valores de alteração de variabilidade das Figuras 5.4 e 5.8 é constatado que para a malha de pressão tal patamar de V_A é maior enquanto para a malha de controle de vazão de vapor, esse patamar é consideravelmente menor. Isto sugere que para malhas as quais já se tem uma

resposta rápida, aumentar o desempenho da mesma não implica em grandes mudanças em seu comportamento.

Malha de Composição

O objetivo dessa malha é a manutenção da composição de propano de saída do vaso TQ01 para o processo em um dado percentual molar, de forma a garantir uma baixa concentração de inertes nos reatores *loop*, não afetando assim o rendimento dos catalisadores. Ultrapassando tal percentual molar ou ainda trabalhando com o mesmo muito abaixo do especificado, a corrente de fundo da torre de *stripping* é enviada para purificação (torre de separação propeno/propano) na Central de Matérias-Primas, que purifica a corrente e revende para a companhia a um valor inferior ao dos monômeros virgens.

Conforme pode ser visualizado na Figura 5.9 (a), por repetidas vezes o valor da composição se apresenta muito longe da variável de referência, implicando assim em um envio maior da corrente de fundo da torre de *stripping*.

Deve-se, portanto, obter condições de controle tais que seja possível trabalhar com a malha de composição com a menor variabilidade possível, para que assim a concentração de saída de propano ao processo seja mantida próxima ao percentual molar estabelecido, e assim seja possível enviar uma menor quantidade à Central de Matérias-Primas, pois isso representa uma perda econômica para a companhia.

Sendo assim, com a finalidade de diminuir a variabilidade desta malha, para valores dentro da especificação de projeto, procedeu-se a alteração dos parâmetros de sintonia do controlador, além da modificação do tipo de controle de PI para PID.

Tendo realizado tais ajustes, é verificado, pela Figura 5.9(b), que a média da composição de propano se aproxima mais do seu valor ótimo. Isso possibilitou a redução das perdas para a Central de Matérias-Primas e conseqüentemente um maior aproveitamento dessa corrente no processo.

Analisando os índices de desempenho dados na Tabela 5.4, é confirmado que tal melhoria foi factível. A malha de controle teve seu desempenho melhorado, sendo conseguido obter uma resposta em malha fechada 5 vezes mais rápida do que em malha aberta. O índice IAE teve seu valor reduzido de forma expressiva, indicando que as melhorias realizadas possibilitaram o trabalho com um controle mais adequado. Ainda é observado que antes das melhorias o índice de Harris apresentava um valor próximo à unidade, significando assim que a malha estava praticamente sem controle. Após as melhorias, o índice de Harris diminuiu de

forma considerável, indicando assim que houve um ganho significativo em termos de redução de variabilidade nessa malha de controle.

Tal redução é confirmada pela observância aos valores da variância da malha de controle de composição. Antes dos ajustes realizados, essa variância se apresentava bastante alta, em torno de 0,08. Após os ajustes, a variância diminuir expressivamente, passando a apresentar um valor de 0,0185, contabilizando dessa forma uma redução efetiva de variabilidade na ordem de 76,87%.

Esse valor poderia ser estimado facilmente pelo Modelo de Inferência de Variabilidade, bastando para isso fornecer como entradas para o modelo de inferência a constante de tempo e o tempo morto, aproximados por uma função de 1ª ordem com tempo morto, a razão entre tempo de subida em malha aberta e fechada atual, R_{tR1} e os índices *nosi* e *deli*. Importante ressaltar que o valor de R_{tR2} deveria ser estimado com base no desempenho desejado para o sistema.

Para a situação aqui analisada, já se possui esse valor de R_{tR2} e por isso o mesmo será utilizado para a predição do valor de alteração de variabilidade pelo Modelo de Inferência de Variabilidade. Fazendo então uso da função desenvolvida em Matlab® torna-se possível predizer um valor de -0,5777, ou seja, pelo modelo de inferência a variabilidade da malha de composição poderia ser reduzida em 57,7%. Comparando esse valor com o obtido na prática, tem-se um erro de 33%, aceitável para os objetivos desse trabalho.

Tabela 5.4: Principais índices de desempenho para a malha de composição, antes e depois da alteração dos parâmetros de sintonia.

Índices de Desempenho	Antes	Depois
Índice de Harris	0,8013	0,3469
IAE	148,18	45,44
Variância PV	0,0800	0,0185
R_{tR}	0,5927	3,0243
<i>nosi</i>	0.0994	0.1073
<i>deli</i>	0.0148	0.0278
<i>tuni</i>	0,8858	0.8649

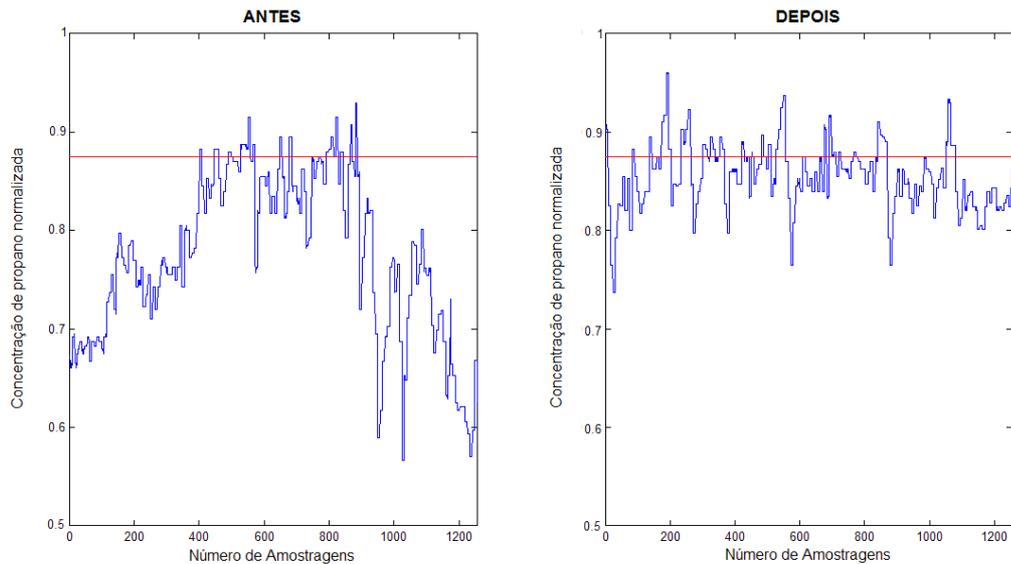


Figura 5.9: Gráficos de tendência representativos do comportamento do composição de propano (a) Antes das alterações nos parâmetros de sintonia e (b) Depois das alterações nos parâmetros de sintonia. Em azul observa-se a variável de processo (PV) e em vermelho o valor de referência (SP).

Analisando a Figura 5.10, observa-se que seria possível aproximar ainda mais a média da composição ao seu valor ótimo, pela redução da variabilidade da malha, caso a velocidade em malha fechada fosse considerada ainda mais rápida do que em malha aberta.

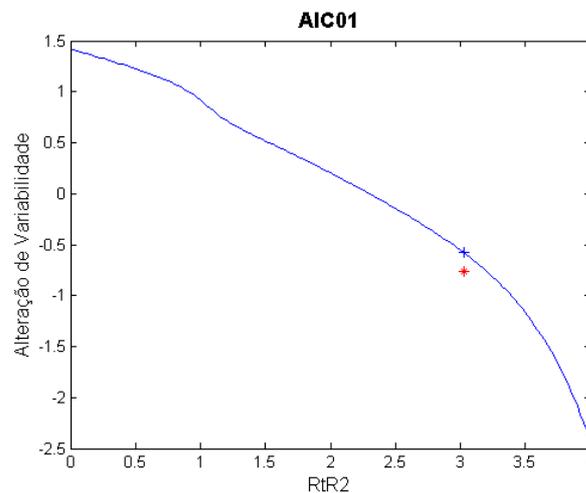


Figura 5.10: Potencial de alteração de variabilidade da malha de controle da composição de propano em função do aumento de velocidade da mesma. O ponto marcado com ‘*’ refere-se à alteração de variabilidade conseguida na prática enquanto que o ponto marcado com “+” refere-se à alteração de variabilidade predita pelo Modelo de Inferência de Variabilidade.

5.2.2 Reator a Leito Fluidizado

Malha de Temperatura

A malha de controle de temperatura do reator a leito fluidizado busca manter a reação em um dado patamar, visando à especificação dos produtos e à manutenção da taxa de produção da unidade. Uma queda dessa temperatura significa redução na taxa de polimerização, isto é, redução no rendimento da reação, e trará como consequência o aumento da pressão. A operação com alto rendimento, ou seja, com uma temperatura mais alta melhora comprovadamente as propriedades finais do polímero (impacto e módulo de flexão especialmente), porém um aumento excessivo de temperatura poderá causar a aglomeração e entupimento do fundo do reator a leito fluidizado. Isso decorre do fato de que a temperatura elevada provoca a migração da “borracha” para a superfície da esfera, gerando um produto mais pegajoso (Neumann *et al.*, 2008)

A temperatura de operação desse reator é determinada pelo tipo de produto que está sendo produzido, sendo que diferentes produtos irão conferir à unidade diferentes comportamentos, devido às diferenças de reatividade do sistema.

Desse modo, um conjunto de parâmetros de sintonia que resulta em um desempenho aceitável para um dado conjunto de produtos, quando usado em produtos mais críticos, resulta em maior variabilidade no controle de temperatura, podendo conduzir inclusive à instabilidade da malha. Pela Figura 5.11(a), é possível observar a grande variabilidade associada à temperatura do reator quando um dado conjunto de parâmetros de sintonia não é conveniente para um determinado produto.

De forma a resolver esse impasse, fez-se uso de sintonias ajustadas às características dos diferentes produtos, a fim de manter o desempenho otimizado na maior parte das situações. Então, por observância às condições operacionais, chegou-se a um conjunto de parâmetros de sintonia, a qual busca adaptar-se aos diversos pontos de operação da planta. Cada uma das sintonias foi associada a um conjunto de produtos específicos e a condições operacionais distintas, as quais observou-se influenciar o comportamento do sistema de troca térmica.

Ao se adotar então tal conjunto de parâmetros de sintonia variável, pode-se obter uma redução significativa na variabilidade da temperatura, sendo assim possível a operação em valores mais próximos da restrição. Sob o ponto de vista gerencial, com a menor variabilidade, alcançam-se patamares mais elevados de segurança e de produção, garantindo maior retorno econômico à unidade. Tais melhorias podem ser confirmadas ao se observar o

comportamento do controle de temperatura do reator, dada pelo gráfico de tendência representativo de um período em operação (Figura 5.11(a)) e pelo acompanhamento dos índices de desempenho constantes na Tabela 5.5.

Nessa tabela, é constatado que, com uma sintonia mais adequada, foi possível aumentar a velocidade do controlador, pois houve um aumento na razão entre o tempo de subida em malha fechada e tempo de subida em malha aberta. Observa-se ainda que a variância da malha de controle de temperatura diminuiu consideravelmente em relação ao seu valor original, contabilizando uma redução efetiva de 63,4%. Tal redução na variabilidade pode ainda ser confirmada pela observância aos valores do índice IAE, pois a diminuição desse índice indica que o controle foi melhorado e que a soma das áreas acima e abaixo do valor de referência foi diminuída.

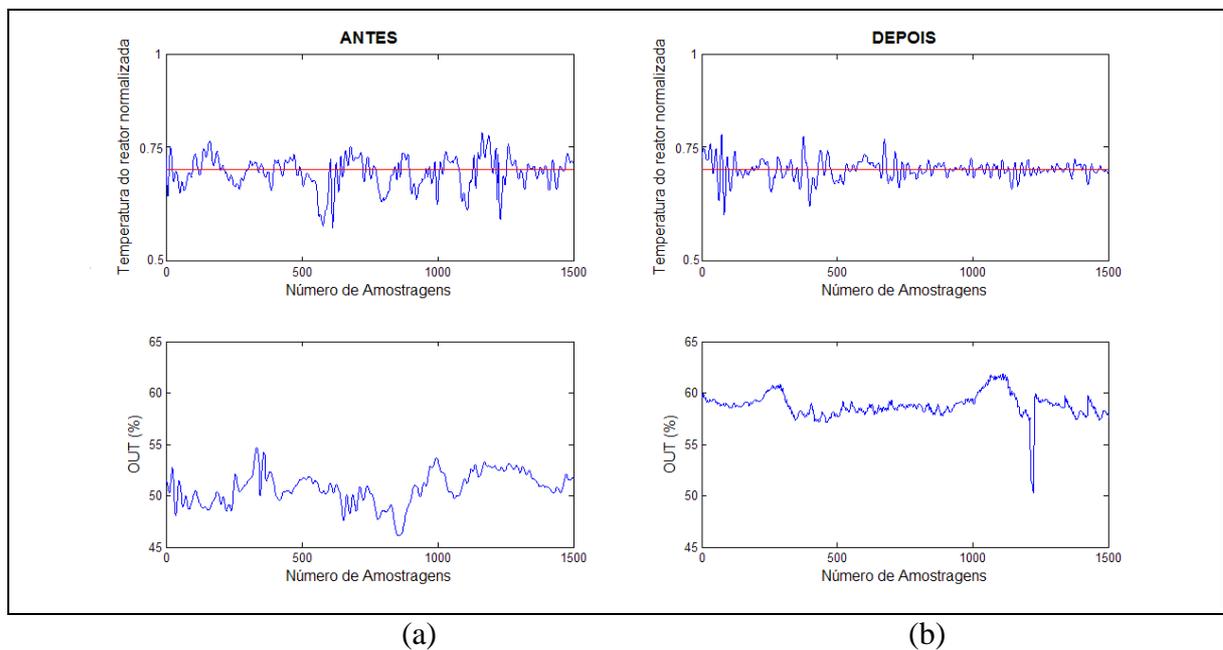


Figura 5.11: Gráficos de tendência representativos do comportamento da temperatura de reação (a) Antes das alterações nos parâmetros de sintonia e (b) Depois das alterações nos parâmetros de sintonia. Nos gráficos acima, em azul observa-se a variável de processo (PV) e em vermelho o valor de referência (SP). Nos gráficos abaixo se tem as ações de controle da malha.

Objetivando comparar o valor real obtido com o valor que seria predito pelo Modelo de Inferência de Variabilidade, os valores dos indicadores $RtR1$, $RtR2$, $nosi$ e $deli$ acrescidos do tempo morto e da constante de tempo (aproximados por uma função de 1ª ordem com tempo morto), foram inseridos como entradas para o modelo de inferência. A saída de tal é a

alteração de variabilidade a qual a malha possa estar sujeita, cujo valor situou-se em -0,4574. Comparando assim esse valor com o valor real (-0,6339) é computado um erro de 38,6%.

Tabela 5.5: Principais índices de desempenho para a malha de controle de temperatura do reator, antes e depois da alteração dos parâmetros de sintonia.

Índices de Desempenho	Antes	Depois
Índice de Harris	0,9491	0,9628
IAE	750,66	420,31
Variância PV	0,4607	0,1686
R_{tR}	0,4910	2,2982
<i>nosi</i>	0.2140	0.3693
<i>deli</i>	0.0915	0.0414
<i>tuni</i>	0,6945	0.5893

Pode-se ainda observar, pela Figura 5.12, que o comportamento da função alteração de variabilidade se assemelha ao observado para as malhas de controle de pressão e de vazão de vapor da torre de *stripping*, indicando assim que o Modelo de Inferência de Variabilidade é capaz de prever coerente o valor de alteração de variabilidade para aquelas malhas cujo desempenho deve ser melhorado.

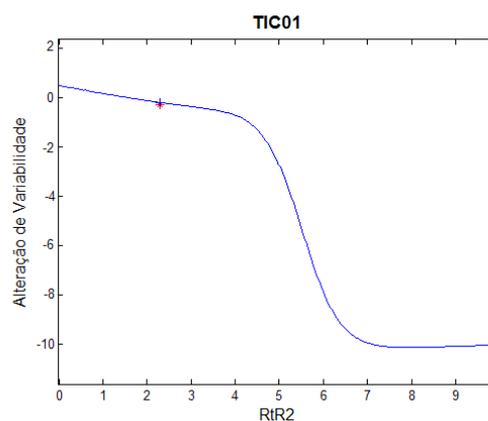


Figura 5.12: Potencial de alteração de variabilidade da malha de controle de temperatura do reator a leito fluidizado em função do aumento de velocidade da mesma. O ponto marcado com “*” refere-se à alteração de variabilidade conseguida na prática enquanto que o ponto marcado com “+” refere-se à alteração de variabilidade predita pelo Modelo de Inferência de Variabilidade.

5.3 Discussões Finais

No presente capítulo buscou-se a aplicação prática em um caso de estudo do modelo de inferência proposto nessa dissertação, denominado Modelo de Inferência de Variabilidade. Tal modelo de inferência propõe-se a traduzir a mudança de desempenho do controlador em potencial de variação de variabilidade.

Os resultados obtidos encontram-se sumarizados na Tabela 5.6, sendo possível afirmar, pela observância dos mesmos, que o Modelo de Inferência de Variabilidade apresentou uma capacidade de predição excelente, com uma margem de erro considerada aceitável para o objetivo desse trabalho.

Tabela 5.6: Resultados obtidos com a aplicação do Modelo de Inferência de Variabilidade ao caso de estudo.

Malha de Controle	Valor Predito	Valor Real	Erro Absoluto	Erro Relativo (%)
PIC01	-0,6979	-0,4146	0,2833	40,59
LIC01	0,6881	0,8698	0,1818	26,42
FIC03	-0,5747	-0,3925	0,1822	31,71
AIC02	-0,5777	-0,7687	0,1910	33,06
TIC03	-0,4574	-0,6339	0,1766	38,60

Outro aspecto relevante deve-se ao comportamento das curvas que relacionam o potencial de variação da variabilidade com o desempenho do controlador. Todas apresentaram o mesmo comportamento, variando apenas as escalas de valores obtidos.

Pode-se com isso comprovar o que é observado na prática industrial. Para malhas às quais se deseja um comportamento mais agressivo, a melhora no desempenho dessas implica a diminuição de sua variabilidade, sendo tão maior o potencial de redução quanto mais adequada for a melhoria executada. Observa-se ainda que ao atingir determinados valores de RtR , a malha não apresenta mais um potencial significativo de variação de variabilidade. Ou seja, uma malha pode ter seu desempenho melhorado até certo ponto, sendo que a partir desse

ponto a melhora no desempenho acaba por não provocar mais uma redução na variabilidade da malha.

Por outro lado, para malhas as quais se deseja um comportamento tal que amortee as perturbações do sistema, como malhas de nível pulmão, a melhora na sua funcionalidade implica em se reduzir a sua velocidade. Para essas, o aconselhável é que o desempenho seja piorado, garantindo assim que a variabilidade aumente. Somente assim é possível que tais malhas possam executar de forma satisfatória sua função de atenuar a propagação de perturbações do processo.

Capítulo 6

Conclusões e Sugestões para Trabalhos Futuros

Ao final da presente dissertação, busca-se sumarizar as conclusões relativas a cada capítulo desenvolvido, evidenciando as principais contribuições desse trabalho. Além disso, propõem-se, sugestões que poderão ser abordadas em trabalhos futuros.

6.1 Considerações Finais

A possibilidade de se operar uma dada unidade em regiões mais próximas de suas restrições de segurança, de meio-ambiente e de processo; permite que se obtenham diversos ganhos, tais como: aumento da capacidade de produção da unidade, redução do consumo de utilidades, aumento da sustentabilidade do processo, aumento da segurança operacional e redução do impacto ao meio ambiente, entre outros. Para atingir tais ganhos, faz-se necessário que as variáveis-chave do processo tenham sua variabilidade reduzida, sendo que a estimativa de quanto a variabilidade pode ser alterada tornou-se um dos principais caminhos para quantificar os benefícios potenciais da melhoria do controle de processos.

Tendo então como objetivo a proposição de uma metodologia rápida e precisa de análise de processo que possa ser aplicada para estimar quanto o desempenho pode ser melhorado através de melhorias nas técnicas de controle, ou seja, o quanto uma malha pode ter sua variabilidade alterada e quanto isso gerará em termos financeiros, procurou-se, no

capítulo 2, realizar uma revisão bibliográfica versando sobre as principais metodologias encontradas na literatura acerca desse tema.

Tal revisão bibliográfica, focada em quantificar os benefícios que poderão advir da melhoria do sistema de controle, mostrou que as principais metodologias existentes na literatura propõem a consideração de um valor fixo para a redução de variabilidade. São poucas as metodologias que se propõem a estimar o potencial de variação de variabilidade a qual uma malha de controle possa estar sujeita. Observou-se ainda que tais metodologias são complicadas de se implementar na prática, uma vez que a estimativa de alteração de variabilidade baseia-se em um profundo conhecimento do processo, além de requererem um conhecimento sobre a forma do controlador escolhido para representar a melhora no controle da operação.

No terceiro capítulo foram discutidos os principais índices de desempenho e robustez mais comumente utilizados, suas vantagens e desvantagens. Ao final deste foram apresentados os índices dados pelo Modelo de Inferência para Desempenho e Robustez, proposto por Farenzena e Trierweiler (2006a), os quais foram utilizados como entradas do modelo de inferência proposto no capítulo 4.

Visando então traduzir a relação entre variação no desempenho e potencial de alteração de variabilidade de uma dada malha, apresentou-se no capítulo 4 o desenvolvimento do Modelo de Inferência de Variabilidade, um modelo de regressão multivariada (modelo de inferência) que utiliza parâmetros que quantificam o desempenho de uma dada malha de controle e de características da planta para prever o quanto uma malha pode ter sua variabilidade alterada.

Para o desenvolvimento de tal modelo partiu-se de um conjunto de dados gerados via simulação, fez-se a seleção do melhor conjunto de variáveis para atuarem como entrada do modelo e assim obteve-se um modelo de inferência que representasse da melhor forma e com menor erro a variável de saída pretendida, sendo os melhores resultados obtidos ao se utilizar redes neurais.

Visando confirmar a aplicabilidade do Modelo de Inferência de Variabilidade, diferentes casos de estudo foram desenvolvidos. Em um primeiro momento procurou-se focar na análise da influência de determinados parâmetros de entrada sobre o modelo de inferência proposto. Para tanto, também no Capítulo 4 foram apresentados os casos de estudo desenvolvidos para sistemas nos quais o modelo de processo pode ser representado por funções de transferência de 1ª e de 2ª ordens com tempo morto, acompanhados de uma minuciosa análise de sensibilidade.

Para o caso de estudo que abordou modelos de 1ª ordem, foram estudadas quatro malhas de controle, obtidas via simulação. Dessas quatro malhas analisadas, em duas se procurou melhorar o seu desempenho, pelo aumento do ganho proporcional do controlador e em duas se procurou piorar o seu desempenho, pela diminuição do ganho proporcional do controlador. Para essas o valor de alteração de variabilidade foi calculado a partir do modelo de inferência proposto, sendo esse comparado com o obtido via simulação. Foi observado que os valores do erro entre V_A predito e V_A teórico são pequenos, dentro do que se espera desse trabalho.

Após ter verificado quantitativamente a capacidade de predição do Modelo de Inferência de Variabilidade, foi realizada uma análise de sensibilidade para verificar como uma alteração nos parâmetros de entrada influenciam na saída do modelo. Foi possível verificar com isso que o modelo de inferência proposto apresenta uma boa qualidade em sua capacidade de predição, pois as curvas de função de alteração de variabilidade apresentaram, para todos os casos, um comportamento suave, comportamento esse que corrobora o que se é observado na prática. Ou seja, para as circunstâncias em que o desempenho da malha de controle é melhorado, ou seja, ocorre um aumento no valor de $RtR2$, pode-se observar que a função alteração de variabilidade tende a apresentar valores cada vez mais negativos. O contrário também se observa, ou seja, ao se assumir que o desempenho em malha aberta seja mais rápido do que em malha fechada os valores da função alteração de variabilidade tendem a aumentar, indicando dessa forma que a variância foi aumentada.

Outro fator importante que deve ser levado em consideração com tal análise de sensibilidade refere-se ao fato de que, com a variação do tempo morto, ocorre uma variação também nas métricas indicativas dos componentes que apresentam maior influência sobre a variância total do sistema, *nosi* e *deli*, uma vez que o tempo morto é requisito para o cálculo dessas. Devido a isso é observado que um erro na estimativa do tempo morto faz com que os valores de alteração de variabilidade apresentem resultados distintos do esperado.

O Modelo de Inferência de Variabilidade também foi aplicado a casos de estudo que abordaram modelos de 2ª ordem com resposta subamortecida, superamortecida e resposta inversa. Para cada tipo de resposta, o comportamento da função alteração de variabilidade foi estudado, obtendo-se com isso um panorama do que se pode esperar do modelo de inferência para cada situação. Foi observado que o Modelo de Inferência de Variabilidade apresenta boa capacidade de predição, tanto pelo baixo erro demonstrado ao se comparar o V_A predito e V_A teórico quanto pela suavidade das curvas da função alteração de variabilidade quando da variação de determinados parâmetros de entrada do modelo.

Já em um segundo momento procurou-se focar na viabilidade da aplicação industrial do Modelo de Inferência de Variabilidade e, para isso, um caso de estudo foi desenvolvido em uma planta industrial, demonstrado no quinto capítulo. Nesse caso de estudo, procurou-se analisar as principais malhas encontradas no cenário industrial e os resultados obtidos mostraram que a ferramenta desenvolvida apresenta um grande potencial de ser utilizada em projetos que contemplem a análise de pontos de melhoria da camada regulatória. A análise das malhas também possibilitou a realização de uma comparação qualitativa entre os principais indicadores de desempenho e a melhora da malha, contribuindo dessa forma para a consolidação dos conhecimentos pertinentes a tal aspecto.

6.2 Transformando Variabilidade em Benefícios Econômicos

Neste trabalho foi apresentada uma metodologia capaz de prever o potencial de alteração de variabilidade que uma malha de controle está sujeita ao ter seu desempenho melhorado ou piorado. Com o uso de tal metodologia é possível prever de forma mais apurada a alteração de variabilidade a qual uma malha está sujeita e a partir desse valor estimar mais precisamente o benefício econômico. Para isso, os seguintes passos devem ser seguidos:

1. Coletar dados da malha de controle em operação normal, sem variações no valor do *setpoint*. O período de amostragem deve ser adequado à dinâmica do sistema;
2. Fornecer esse conjunto de dados, acrescido dos valores da constante de tempo e do tempo morto ao Modelo de Inferência para Desempenho e Robustez, obtendo assim o valor da razão entre tempo de subida em malha aberta e fechada para a situação atual, antes de qualquer melhoria realizada na malha de controle, $RtR1$;
3. Para o cálculo dos índices *nosi* e *deli*, além da janela de dados e do tempo morto, deve ser fornecida ainda ao Modelo de Inferência para Desempenho e Robustez a ordem do modelo AR. Assume que valores entre 15 e 30 são adequados para capturar o comportamento do sistema (Kempf, 2003).
4. De acordo com o desempenho desejado para a malha de controle, deve ser estipulado o valor de $RtR2$;
5. Pelo fornecimento dos valores da constante de tempo, do tempo morto, de $RtR1$, *nosi* e *deli* (estes calculados via Modelo de Inferência para Desempenho e Robustez), acrescidos do valor estipulado para $RtR2$, ao Modelo de Inferência de

Variabilidade, calcula-se o valor de alteração de variabilidade predito para a malha de controle;

6. Tendo o conhecimento do valor de alteração de variabilidade, é possível, através das metodologias e sistemáticas apresentadas no Capítulo 2, estimar o benefício econômico que determinada melhoria no sistema de controle pode trazer.

A contribuição, portanto, desse trabalho é possibilitar que o benefício econômico seja estimado a partir de uma consideração de alteração de variabilidade balizada pelo desempenho da malha de controle em face à consideração de alteração de variabilidade fixa em um dado valor, conforme utilizado nas metodologias apresentadas no Capítulo 2.

6.3 Trabalhos Futuros

De um modo geral, pode-se afirmar que o presente trabalho possibilitou alcançar o objetivo proposto, qual seja, o de desenvolver uma ferramenta de análise de processo que permita traduzir a relação entre variação no desempenho do controlador e potencial de alteração de variabilidade, até então inexistente no cenário industrial.

Entretanto, a metodologia proposta nesse trabalho apresenta como pré-requisito que se possua dados em operação normal da malha de controle, ou seja, é necessário que a estrutura de controle já esteja estabelecida. Um ponto importante de melhoria nessa metodologia seria então a obtenção de um modelo de inferência capaz de prever a alteração de variabilidade para estruturas de controle que virão a ser implementadas, ou seja, para aquelas situações que não se tem disponíveis dados de processo para análise.

Além disso, para a geração dos dados utilizados para a obtenção do modelo de inferência proposto foi utilizado os valores da constante de tempo integral do controlador atrelados à dinâmica da planta. Um ponto importante para trabalhos futuros seria então, para um novo conjunto de dados, obter um modelo de inferência cujos parâmetros do controlador não estivesse vinculado à dinâmica da planta, possibilitando dessa forma diminuir o erro encontrado para a alteração de variabilidade

O presente trabalho pode ser considerado como uma extensão do Modelo de Inferência para Desempenho e Robustez, proposto por Farenzena e Trierweiler (2006a), seguindo sua formulação e utilizando sua base. Entretanto, ao se obter a resposta para o modelo de inferência proposto nesse trabalho, essa resposta é oriunda de dois modelos de inferência em série, o Modelo de Inferência para Desempenho e Robustez e o Modelo de

Inferência de Variabilidade. Dessa forma, somam-se duas fontes de erro que podem afetar o resultado efetivo de alteração de variabilidade. Como sugestão tem-se então a obtenção de um único modelo de inferência, o qual utilizaria como entradas aquelas utilizadas para o Modelo de Inferência de Desempenho e Robustez somadas àquelas utilizadas para o Modelo de Inferência de Variabilidade, tendo como única saída o impacto na variância.

Apêndice A

Medidas de Variabilidade

Segundo Freund e Simon (2000), se um conjunto de dados consiste de todas as observações possíveis, é chamado de uma população; se um conjunto de dados consiste apenas de uma parte dessas observações, e pode servir de base para generalizações válidas sobre as populações das quais foram extraídas, é chamado de amostra. Tendo em vista que para os fins dessa dissertação, irá se tratar somente de amostras de um conjunto de dados históricos, que sejam representativos da operação normal do sistema, somente será apresentado a forma de cálculo referente às estatísticas amostrais.

Alguns autores, tais como Shunta (1995), defendem o uso de medidas estatísticas para caracterizar a variabilidade por duas razões. Primeiro, porque também faz sentido para os engenheiros de controle pensar em termos dessas medidas. Segundo, porque tanto engenheiros de controle quanto profissionais de controle de qualidade estão focados em controlar a variabilidade, mesmo que suas abordagens e ferramentas possam diferir. Portanto, é desejável promover um entendimento e uma integração dessas duas abordagens, para maximizar seus benefícios potenciais.

Entre as medidas estatísticas, as que refletem melhor a variabilidade de uma dada variável estão o desvio-padrão e a variância.

O desvio-padrão, também chamado de raiz da média dos quadrados dos desvios, é dado por:

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}} \quad (\text{A.1})$$

A variância, também chamada de desvio quadrado médio dos valores em relação à média, é dada por:

$$\sigma^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1} \quad (\text{A.2})$$

A média amostral é calculada da seguinte maneira:

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n} \quad (\text{A.3})$$

Não é redundante definir os conceitos de desvio-padrão e variância, pois cada uma dessas grandezas têm algumas propriedades úteis. A vantagem do desvio-padrão, utilizado nessa dissertação, é que se trata de uma medida de variabilidade que leva em conta toda a informação contida na amostra, ou seja, o desvio-padrão é usado para estimar quantos dados estão fora das especificações ou limites.

A variabilidade medida no processo é, na realidade, a variabilidade total, isto é, a soma de todos os componentes de variabilidades que ocorrem no processo, incluindo a variabilidade de medição, que, em alguns casos, não é passível de ser negligenciada uma vez que pode mascarar a real tendência da curva do processo. Em casos dessa natureza, aconselha-se incluir a variância da medida para a determinação da variância do processo (Muske, 2003).

A variância pode ser usada para determinar isso, pois ela tem a propriedade da aditividade. Portanto, se for conhecida a variância da medição é possível calcular a variância do processo:

$$\sigma_{proc}^2 = \sigma_{tot}^2 - \sigma_{med}^2 \quad (\text{A.4})$$

O desvio-padrão do processo é então:

$$\sigma_{prod} = \sqrt{\sigma_{tot}^2 - \sigma_{med}^2} \quad (\text{A.5})$$

A variância relativa à medição é tipicamente menor que a variabilidade do processo na maioria dos casos. Se o desvio-padrão da medição for menor do que 30% do desvio-padrão total, o efeito será menor do que 5%. Se o desvio-padrão da medição for menor do que 10%, o efeito será menos do que 1%, o que é provavelmente muito pouco, e pode ser desprezado.

Uma maneira adicional de se analisar uma variável é ver todo o seu conjunto de valores, por exemplo, com uma curva de distribuição ou um histograma. Vale a pena salientar que, muitas vezes, essas respostas são referidas na literatura como métodos de estimar benefícios (por exemplo, Martin *et al.*, 1991).

A.1 Importância da Análise de Dados Históricos

Para uma correta interpretação da grande maioria das metodologias abordadas nesse trabalho deve-se fazer uso de dados históricos de forma a predizer os benefícios que poderão decorrer do melhoramento das técnicas de controle vigentes e/ou da implementação de novas técnicas para o controle de processos em indústrias. Faz-se necessário, portanto, ressaltar a importância de uma análise criteriosa dos dados históricos e avaliar as diretrizes propostas para a análise dos mesmos.

Martin *et al.* (1991) afirmam que os dados a serem analisados devem ser significativos em relação à dinâmica do processo, ou seja, os dados devem ser representativos da operação em malha fechada com o controle existente. Dados coletados durante operações de manutenção, testes com a malha, ou equipamento com problemas podem levar a conclusões errôneas sobre o desempenho do controlador. Muske (2003) afirma que, se o processo for operado em diferentes condições, a análise dos dados deve ser realizada para cada uma dessas condições, a fim de se ter uma estimativa mais exata dos benefícios atingíveis.

As implicações do tamanho do conjunto de dados são discutidas por Desborough e Harris (1992). Desse estudo pode-se concluir que amostras com tamanho pequeno devem ser evitadas, pois as propriedades estatísticas tornam-se mais sensíveis a pontos ruins e a variabilidade tende a aumentar. Por outro lado, amostras muito grande podem mascarar mudanças no desempenho do controlador ou no processo.

Thornhill *et al.* (1999) aponta que, para dados de refinarias, um bom balanço entre a confiança estatística e a adequada caracterização da malha é obtida com amostras com 1000 a 1500 pontos, sendo que, se possível, deve-se analisar dados “limpos”, ou seja, aqueles que não passaram por um processo de compressão ou filtragem.

Uma vez que se torna difícil obter esses dados, já que as bases de dados dos sistemas de arquivamento normalmente trabalham com algoritmos de filtragem para remoção de ruído e algoritmos de compressão que inevitavelmente removem componentes predizíveis do conjunto de dados visando otimizar o espaço de armazenamento no banco de dados, Martin *et al.* (1991) sugerem a coleta e posterior análise de dados baseado na janela de dados disponível para avaliação tomando-se o devido cuidado na interpretação dos resultados. Cabe salientar que esse problema torna-se crítico para malhas com dinâmica mais rápida, como malhas de vazão. O impacto da compressão na análise de dados históricos encontra-se muito bem explicado em Thornhill *et al.* (2004).

Outro ponto importante refere-se à influência do período de amostragem nas análises realizadas. Deve-se tomar o cuidado de coletar dados nos quais o período de amostragem represente a dinâmica do processo, representado pela constante de tempo (τ). Na prática, um bom compromisso reside em se ter um período de amostragem equivalente a 1/10 de τ . Períodos de amostragem maiores implicam em perda substancial de informações, principalmente com respeito à dinâmica do processo. Ao contrário, ou seja, períodos de amostragem muito pequenos tendem a modelar o ruído.

Atualmente, com os avanços produzidos na área de sistemas de informação, já é possível obter períodos de amostragem mais reduzidos, na ordem de segundos, sendo coletados com sua compressão suprimida, qualificando assim a tarefa de análise de dados históricos. Existem áreas de estudo focadas na análise de dados, as quais aplicam técnicas (a maioria gráficas) que direcionam o usuário a obter de um conjunto de dados históricos suas principais características. Uma dessas áreas é a denominada *Exploratory Data Analysis (EDA)*, originária do trabalho de Tukey (1977). Maiores informações a respeito de tal podem ser encontradas nos trabalhos de Velleman e Hoaglin (1981) e Pearson (2001).

Apêndice B

Redes Neurais Artificiais

As Redes Neurais Artificiais, empregadas neste trabalho, são técnicas de inteligência computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. Essas técnicas podem ser consideradas como sistemas dinâmicos não lineares consistindo de elementos de processamento (neurônios), que são interconectados entre si, com ponderações ajustáveis, sendo que a maneira como os neurônios são organizados define a arquitetura da rede.

B.1 Neurônios Artificiais

As redes neurais artificiais são constituídas de elementos simples operando em paralelo, que armazenam conhecimentos através de experiências de aprendizado, sendo esses elementos inspirados no sistema nervoso biológico e por isso denominados de neurônios. Cada neurônio, quando ativado por um sinal de entrada, apresenta uma resposta que obedece a uma função matemática escolhida para modelar o seu comportamento.

A figura B.1 mostra um desses neurônios. Esse recebe n entradas x_k , sendo cada uma dessas multiplicada por um peso sináptico w_i que quantifica a influência da entrada n sobre cada neurônio. A soma das entradas ponderadas pelos pesos correspondentes w_i é processada sendo que este somatório inclui um termo independente, chamado de (b) e, através de uma função f , é calculado assim o vetor de saída y , que é dado pela seguinte equação:

$$y = f\left(\sum_{i=1}^n x_i w_i + b\right) \quad (\text{B.1})$$

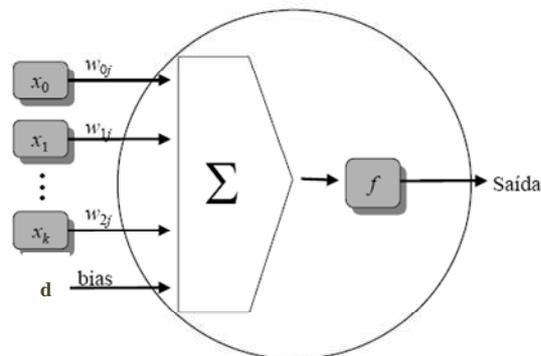


Figura B.1: Estrutura geral de um neurônio artificial (Adaptado de Leigh, 2004).

A função f é chamada de função de ativação, sendo que existem três classes distintas: a função linear, a função linear por partes e a função sigmoide. A mais comumente utilizada é a função sigmoide (Figura B.2), sendo esta definida como uma função monotônica crescente que apresenta propriedades assintóticas e de suavidade, favoráveis para um ajuste mais eficiente dos parâmetros da rede:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (\text{B.2})$$

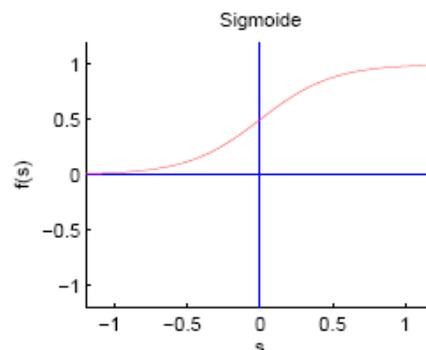


Figura B.2: Função de ativação sigmoide.

B.2 Estruturas das Redes Neurais Artificiais

A estrutura de uma rede neural (também chamada de arquitetura ou topologia) refere-se a maneira como os neurônios estão organizados. Esta estrutura é formada pela organização

dos neurônios em camadas, conectando-os por meio de conexões. Assim sendo, existem redes neurais de camadas simples (também denominadas de *perceptrons*) e as redes multicamadas, utilizada nesse estudo.

Nas redes multicamadas, também chamadas de Redes Neurais Multicamadas (*Multilayer Feedforward Neural Network – MNN*), os neurônios estão dispostos em camadas que se justapõem umas às outras, formando uma configuração em cascata, podendo existir mais de uma camada intermediária. A primeira camada (pseudocamada) é a camada de entrada (*input layer*), as camadas intermediárias são as camadas ocultas (*hidden layers*) e a última camada é a camada de saída (*output layer*). A rede funciona no sentido direto da entrada para a saída (*feedforward*), ou seja, cada possui neurônios que recebem entradas da camada imediatamente anterior e não há conexões entre neurônios dentro da própria camada. Tal configuração é ilustrada na Figura B.3, abaixo:

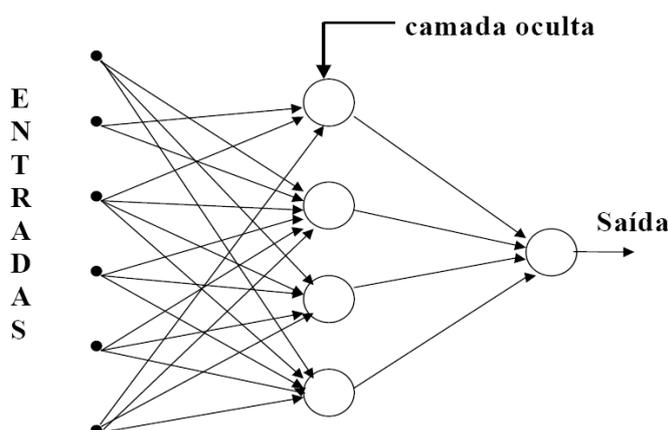


Figura B.3: Redes Neurais Multicamadas (Adaptado de Leigh, 2004).

Na camada de entrada não há processamento e os dados são apresentados à rede enquanto que na camada de saída o processamento é concluído e apresentado, sendo esta a responsável pela geração da resposta da rede. O fator mais importante na capacidade de aprendizagem de uma MNN é o número de neurônios na camada oculta, uma vez que nesses é realizada a maior parte do processamento. Para a construção do Modelo de Inferência de Variabilidade, proposto nessa dissertação, optou-se por variar o número de neurônios na camada oculta, visando assim identificar a melhor estrutura.

B.3 Algoritmos de Aprendizado

De acordo com Mendel e Mclaren (1970) a “Aprendizagem é um processo no qual os parâmetros livres (pesos) de uma rede neural são adaptados através de um processo contínuo de simulação pelo ambiente no qual a rede está embutida. O tipo do aprendizado é determinado pela maneira pela qual a mudança de parâmetros acontece.” (Haykin, 1999)

Nesse contexto, existem dois tipos de processos de aprendizagem, o processo supervisionado e o não supervisionado.

No processo de aprendizado não-supervisionado não se apresenta a saída desejada para a rede, mas somente um conjunto de dados. A rede neural irá então tentar extrair características estatisticamente relevantes desse conjunto de dados e a sua saída irá refletir essas características ou esse “conhecimento” por ela aprendido sobre esses padrões de entrada fornecidos.

Já no processo de aprendizagem supervisionado um conjunto de treinamento, ou seja, um conjunto de entradas e suas respectivas saídas desejadas é fornecido para a rede neural. Essa, por sua vez, irá adaptar seus pesos sinápticos e seu valor de *bias* de tal maneira que a diferença entre os valores da saída desejada e de sua saída atual, calculada para todos os pontos de treinamento, seja mínima (Haykin, 1999). Diversos algoritmos para ajuste dos parâmetros da rede baseados neste conceito existem, sendo o mais utilizado algoritmo de treinamento o *backpropagation* (também denominado de retropropagação). Tal algoritmo foi o escolhido para a construção do Modelo de Inferência de Variabilidade, proposto nessa dissertação.

O algoritmo *backpropagation* possui este nome pelo fato do sinal de erro ser retropropagado ao longo da rede neural, e isso acontece da seguinte forma: na primeira fase de treinamento, o estímulo das entradas é processado através das camadas da rede até a saída. Como o valor da saída desejada para entrada atual é conhecido, o erro para a camada de saída pode ser calculado e os pesos desta camada podem ser ajustados. Já para as camadas ocultas não existem valores de saída desejados, então o ajuste dos pesos sinápticos é feito pela propagação do erro da camada de saída em direção à entrada da rede.

Mais detalhes sobre o algoritmo de retropropagação do erro e suas variantes podem ser obtidos em Haykin (1999).

Referências Bibliográficas

Åström, K. J.; "Introduction to stochastic control theory", 1970.

Åström, K. J., Hägglund, T.; "PID controllers: theory, design, and tuning", 2^a ed. Research Triangle Park: Instrument Society of America, 1995.

Bauer, M., Craig, I. K.; "Economic assessment of advanced process control - A survey and framework", *Journal of Process Control*, 18(1), pp. 2-18, 2008.

Bauer, M., Craig, I.K., Tolsma, E., Beer, H.; "A profit index for assessing the benefits of process control", *Industrial & Engineering Chemistry Research*, (46), pp. 5614-5623, 2007.

Bazanella, A. S., Silva JR., J. M. G.; "Ajuste de Controladores PID", Apostila do Curso de Extensão, Departamento de Engenharia Elétrica, Universidade Federal do Rio Grande do Sul. Porto Alegre, 1999.

Bolton, W.; "Engenharia de Controle", São Paulo: Makron Books do Brasil, 1995.

Bozenhardt, H., Dybeck, M.; "Estimating saving from up-grading process control", *Chemical Engineering*, 93(3), pp. 99-102, 1986.

Brisk, M.L.; "Process control: potential benefits and wasted opportunities", 5th Asian Control Conference, pp 10-16, 2004.

Campos, M. C. M. M. de, Teixeira, H.C.G.; "Controles Tipicos de Equipamentos e Processos Industriais", Ed. Edgard Blucher, 2006.

Canney, W.M.; "The future of advanced process control promises more benefits and sustained value", *Oil & Gas Journal*, 101 (16), pp 48-54, 2003.

Canney, W.M.; "Are you getting the full benefit from your advanced process control system?", *Hydrocarbon Processing*, 84 (6), pp 55-58, 2005.

Craig, I.K., Henning, R.G.D.; "Evaluation of advanced control projects: A framework for determining economic benefits", *Control Engineering Practice*, 8(7), pp 769-780, 2000.

Cutler, C. R., Ramaker, B. L.; "Dynamic Matrix Control- a computer algorithm.", *AIChE 86th National Meeting*, Houston, TX. , 1979.

D'Azzo, J.J., Houpis, C.H.; "Análise e projeto de sistemas de controle lineares", Tradução de Filho, B.S.S., Rio de Janeiro, Ed.Guanabara Dois, 1978.

Dennett, R.; "Polypropylene - The light at the end of the tunnel", *Houston CMAI 11th World Petrochemical Conference*, 1996.

Desborough, L., Harris, T.; "Performance assessment measures for univariate feedback control", *The Canadian Journal Of Chemical Engineering*, Vol. 70, pp. 1186-1197, December 1992.

Edgar, T.F.; "Control and operations: when does controllability equal profitability", *Computers & Chemical Engineering*, 29, pp 41-49, 2004.

Embiruçu, M.; "Relatório técnico: Avaliação de benefícios econômicos", Programa de Pós-Graduação da UFBA, 2002.

Faccin, F.; "Abordagem inovadora no projeto de controladores PID", Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Química, Universidade Federal do Rio Grande do Sul. Porto Alegre, 2004.

Facchin, S.; "Técnicas de análise multivariável aplicadas ao desenvolvimento de analisadores virtuais", Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Química, Universidade Federal do Rio Grande do Sul. Porto Alegre, 2005.

Farenzena, M., Trierweiler, J.O.; "Quantifying closed-loop performance based on online performance indices", *ADCHEM - International Symposium on Advanced Control of Chemical Processes*, Gramado, Brasil, v.2, pp 887-892, 2006a.

Farenzena, M., Trierweiler, J.O.; "Using the inference model as tool to quantify the loop performance and robustness", *SICOP - International Symposium on Advanced Control of Chemical Processes*, Gramado, Brasil, v.2, pp 887-892, 2006b.

Farenzena, M., Trierweiler, J. O.; "Quantifying the impact of control loop performance, time delay and white-noise over the final product variability"; *International Symposium on Dynamics and Control of Process Systems*, Cancun, Mexico, 2007a.

Farenzena, M., Trierweiler, J. O.; "Uma visão geral das tecnologias atualmente empregadas em controle avançado de processos industriais", *Revista Petro&Química*, Ed.294, 2007b.

Farenzena M.; “Novel methodologies for assessment and diagnostics in control loop management”, Doctoral Thesis, Programa de Pós-Graduação em Engenharia Química, Universidade Federal do Rio Grande do Sul. Porto Alegre, 2008.

Farina, L.A., Guerra, C.D.W., Lusa, L.P., Islabão, G.I., Sanchez, J., Oliveira, A.T.M.; “Benefícios de uma mudança de estratégia de controle de inventários em uma coluna de destilação de uma planta petroquímica”, *Revista Petro&Quimica*, Ed.294, 2007.

Freund, J.E., Simon, G.A.; “Estatística aplicada”, Tradução de Alfredo Alves de Farias. 9ª Ed., Porto Alegre, Ed.Bookman, 2000.

Friedmann, P.G.; “Economics of control improvement”, ISA, 1995.

Friedman, Z.; “Tuning of averaging level controllers”, *Hydrocarbon Processing Journal*, Dezembro de 1994.

Gerry, J.; "Performance measurement – The rest of history", *ExperTune Newsletter*, 2004.

Hall, G.F.; “Energy and product savings through advanced control”, *Hydrocarbon Processing*, 64 (7), pp 57-59, 1985.

Harris, T. J. ; "Assessment of control loop performance" ,*Canadian Journal of Chemical Engineering*, 67(5), pp. 856-861, 1989.

Harrold.D.; “What is taking so long?”, *Control Global*. www.controlglobal.com/articles/2007/102.html. Último acesso em 25/09/2007.

Haykin, S.; “Redes neurais”, Artmed Editora Ltda, Porto Alegre, Rio Grande do Sul. Brasil, 1999.

Huang, B., Shah, S. L., Kwok, E. K.; "Good, bad or optimal? Performance assessment of multivariable processes.", *Automatica*, 33(6), pp. 1175-1182, 1997.

Huang, B., Shah, S. L.; "Performance assessment of control loops – theory and applications", Springer-Verlag, 1999.

Jain, M.; "Practical issues in controller performance monitoring ", University of Alberta, Edmonton, AB, 2006.

Jelali, M.; “An overview of control performance assessment technology and industrial applications”, *Control Engineering Practice*, 14, pp 441–466, 2006.

Kamrunnahar, M., Huang, B., Fisher, D. G.; "Estimation of markov parameters and time-delay/interactor matrix", *Chemical Engineering Science*, Vol. 55, pp. 3353-3363, 2000.

Kayser, C.; “Desempenho de malhas de controle – análise e diagnóstico através de técnicas não invasivas”, Trabalho de Conclusão em Engenharia Química, Departamento de Engenharia Química, Universidade Federal do Rio Grande do Sul. Porto Alegre, 2007.

Kempf, A.; “Avaliação de desempenho de malhas de controle”, Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Química, Universidade Federal do Rio Grande do Sul. Porto Alegre, 2003.

Lababidi, H.M.S., Kotob, S., Yousuf, B.; “Refinery advanced process control planning system”, *Computers & Chemical Engineering*, 26, pp 1303-1319, 2002.

Latour, P. R.; “The hidden benefits from better process control”, In *Advances in Instrumentation - Proceedings of the ISA Conference and Exhibit*; Houston, Texas, Instrument Society of America: Research Triangle Park, NC, Vol. 31, Part 1, Paper no. 528, pp 11, 1976.

Latour, P. R.; “Quantifying quality control’s intangible benefits”, *Hydrocarbon Process*, 71 (5), pp 61-68, 1992.

Latour, P. R.; “Process control: cliffent shows it’s more profitable than expected”, *Hydrocarbon Process*, 75, pp 75-80, 1996.

Latour, P.R., Sharpe, J.H., Delaney, M.C.; “Estimating benefits from advanced control”, *ISA Transactions*, 25 (4), pp. 13–21, 1986.

Leigh, J.R.; “Control theory: a guided tour”, 2nd ed, The Institution of Electrical Engineers, London, United Kingdom, 2004.

Marlin, T. E.; “Process Control”, New York: McGraw-Hill ,1995.

Martin, G.D., Turpin, L.E., Cline, R.P.; “Estimating control function benefits”, *Hydrocarbon Processing*, 70 (6), pp 68-73, 1991.

Martin, G.D.; “Understand control benefits estimates”, *Hydrocarbon Processing*, 83 (10), pp 43–46, 2004.

Mejía, R. I. G., Coelho, A. A. R., Farenzena, M., Trierweiler, J. O., Nunes, G. C.; “Auditoria de Malhas de Controle em Processos Industriais”, Augusto Santiago Cerqueira, et al. (Ed.). In: *Tutoriais do XVII Congresso Brasileiro de Automática CBA*. Juiz de Fora, MG, Brasil: Book Editora, ISBN: 978-85-61953-00-3, Cap.7, p.160 – 217, 2008.

Mejía, R. I. G.; “Métodos para a análise do desempenho e da robustez de processos industriais orientados a dados: abordagem determinística e estocástica”, Tese de Doutorado, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Santa Catarina, 2008. Moro, T.L.; “Using advanced control for profitability”, *Process Engineering*, 27, 1999.

Muske, K.R.; “Estimating the economic benefit from improved process control”, *Industrial & Engineering Chemistry Research*, 42, pp 4535-4544, 2003.

Neumann, G.A., Oliveira, A.T.M., Osório, T.S., Brand, F.R., Fernandes, P.B., Gosmann, R.P. ;“Benefícios da melhoria do controle de temperatura de reatores industriais de polimerização”. *InTech Brasil*, Ed.108, 2008.

Oliveira Junior, H.G., Oliveira. L.C.R., Torres, B.S.; “Métodos de monitoramento, redução e controle da variabilidade em processos industriais”, *InTech Brasil*, 92, pp 16-22, 2007.

Paulonis, M.A., Cox, J.W.; “A practical approach for large-scale controller performance assessment, diagnosis and improvement”, *Journal of Process Control*, 13, pp 155-168, 2003.

Pearson, R.K.; “Exploring process data”, *Journal of Process Control*, 11, pp 179-194, 2001.

Qin, S.J.; “Control performance monitoring: a review and assessment”, *Comp.Chem.Eng.*, Vol.23,173,1998.

Rawlings, J. O.; “Applied regression analysis: a research tool”, Pacific Grove, Calif., Wadsworth & Brooks/Cole Advanced Books & Software, 1988.

Reginato, A.S.; “Modelagem e simulação dos reatores de polimerização em fase líquida do processo Spheripol”, *Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Química, Universidade Federal do Rio Grande do Sul. Porto Alegre*, 2001.

Seborg, D. E., Edgar, T. F., Mellichamp, D. A.; “Process dynamics and control”, Hoboken, NJ, Wiley, 2004.

Shah, S. L., Mitchel, W., Shook, D.; “Integration of controller performance metrics in the asset management workflow process”, *IEE Special symposium on Controller Performance Assessment and Diagnosis*, London, June 2005.

Shunta, J.P.; “Achieving world class manufacturing through process control”, Prentice-Hall, New Jersey, U.S.A, 1995.

Silveira, C.C.; “Avaliação da troca térmica em reatores do tipo loop de produção de polipropileno”, *Trabalho de Conclusão em Engenharia Química, Departamento de Engenharia Química, Universidade Federal do Rio Grande do Sul. Porto Alegre*, 2006.

Spheripol Process and Services- “Production of PP Homopolymer, random copolymer, heterophasic impact copolymer”, www.basell.com. Último acesso em 02/02/2008.

Stanton, B.D.; “Using historical data to justify controls”, *Hydrocarbon Processing*, 69 (6), pp 57-60, 1990.

Stout, T.M., Cline, R.P.; “Control system justification”, *Instrumentation Technology*, Vol. 23, No. 9, pp 51-58, 1976.

Stout, T.M.; “Evaluating control system payout from process data”, *Control Engineering*, No.7, pp 93–97, 1960.

Thornhill, N. F., Oettinger, M., Fedenkzuk, P.; "Refinery-wide control loop performance assessment", *Journal of Process Control*, Vol. 9, pp. 109-124, 1999.

Thornhill, N.F., Choudhury M.A.A.S., Shah, S.; “The impact of compression on data-driven process analyses”, *Journal of Process Control*, 14, pp. 389–398, 2004.

Tolfo, F.; “A methodology to estimate the economic returns of advanced control projects”, in: *Proceedings of the American Control Conference*, pp. 1141–1145, 1983.

Trierweiler, J. O., Posser, M. S.; “PID-Toolbox: Uma Ferramenta Para o Ensino e Ajuste de Controladores PIDs”, *Apostila, Departamento de Engenharia Química, Universidade Federal do Rio Grande do Sul. Porto Alegre*, 2002.

Velleman, P., Hoaglin, D.; “The ABC's of EDA: applications, basics, and computing of exploratory data analysis”, *Duxbury*, 1981.

White, D.C.; “Improve your project's prospects”, *Chemical Processing*. www.chemicalprocessing.com/articles/2004/144.html. Último acesso em 25/09/2007.

Williams, T.J.; “Economics and the future of process control”, *Automatic*, 3, pp 1–13, 1965.

Zanin, A.C., Moro, L.F.L.; “Gestão da automação industrial no refino”, *Anais da Rio Oil & Gas Expo and Conference*, 2004.