

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ**  
Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial

**DISSERTAÇÃO**  
apresentada à UTFPR  
para obtenção do grau de

**MESTRE EM CIÊNCIAS**

por

**LUIS FERNANDO KERSCHER**

---

**CONTROLE PREDITIVO BASEADO EM MODELO COM CRITÉRIOS  
DE OTIMIZAÇÃO APLICADO A PROCESSOS DE REFINO**

---

Banca Examinadora:

Presidente e Orientador:

Prof. Dr. FLÁVIO NEVES JR.

UTFPR

Examinadores:

Prof. Dra. LÚCIA VALÉRIA RAMOS ARRUDA

UTFPR

Prof. Dr. JOÃO MANOEL GOMES DA SILVA JR.

UFRGS

Curitiba, abril de 2006



**LUIS FERNANDO KERSCHER**

**CONTROLE PREDITIVO BASEADO EM MODELO COM CRITÉRIOS  
DE OTIMIZAÇÃO APLICADO A PROCESSOS DE REFINO**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial da Universidade Tecnológica Federal do Paraná, como requisito parcial para a obtenção do grau de “Mestre em Ciências” – Área de Concentração: Informática Industrial.

Orientador: Prof Dr. Flávio Neves Jr.

Curitiba  
2006

Ficha catalográfica elaborada pela Biblioteca da UTFPR – Campus Curitiba

K39c Kerscher, Luis Fernando

Controle preditivo baseado em modelo com critérios de otimização aplicado a processo de refino / Luis Fernando Kerscher. Curitiba. UTFPR, 2006  
XXIV, 145 f. : il.; 30 cm

Orientador: Prof. Dr. Flavio Neves Junior

Dissertação (Mestrado) – Universidade Tecnológica Federal do Paraná. Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial. Curitiba, 2006

1. Controle preditivo. 2. Processos elétricos industriais. 3. Automação Eletrônica. 4. Engenharia Química. 5. Otimização de processos de refino. 6. Craqueamento catalítico. 6. Leito fluidizado. 7. Métodos de simulação. I. Neves Junior, Flávio, orient. II. Universidade Tecnológica Federal do Paraná. Curso de Pós-Graduação em Engenharia Elétrica e Informática Industrial. III. Título.

CDD: 665.533

Este trabalho recebeu apoio financeiro da Agência Nacional do Petróleo - ANP - e da Financiadora de Estudos e Projetos - FINEP - por meio do Programa de Recursos Humanos da ANP para o Setor Petróleo e Gás - PRH-ANP/MCT (PRH10-UTFPR).



## **AGRADECIMENTOS**

Gostaria de agradecer a todos que diretamente ou indiretamente contribuíram para a execução deste trabalho.

Ao Prof. Flávio Neves Jr. pela oportunidade e pela orientação.

À Prof. Lúcia Valéria Ramos de Arruda pelo acompanhamento e sugestões.

A toda a minha família, em especial a Idanilda Kerscher, que mesmo de forma indireta foi importante nesta fase da minha vida, como também em todas as outras.

Em especial a minha namorada, Maria Cristina Szpak Swiech, que me ajudou em todas as etapas do desenvolvimento desta dissertação, com a sua paciência, carinho, apoio, sugestões e cobranças, que propiciaram o término deste trabalho.

A todas as pessoas que me inspiram no dia a dia.

Este trabalho é dedicado à memória de Bárbara Kerscher.





## SUMÁRIO

<b>CAPÍTULO 1</b> .....	<b>1</b>
<b>INTRODUÇÃO</b> .....	<b>1</b>
1.1 CARACTERIZAÇÃO DO PROBLEMA E OBJETIVO.....	1
1.2 APLICAÇÃO DA METODOLOGIA.....	2
1.3 CONTRIBUIÇÕES.....	3
1.4 ORGANIZAÇÃO DA DISSERTAÇÃO .....	4
<b>CAPÍTULO 2</b> .....	<b>5</b>
<b>2 REVISÃO BIBLIOGRÁFICA</b> .....	<b>5</b>
2.1 INTRODUÇÃO AO CONTROLE PREDITIVO BASEADO EM MODELO.....	5
2.1.1 ORIGEM DO CONTROLE PREDITIVO BASEADO EM MODELO.....	6
2.1.2 PRINCIPAIS CARACTERÍSTICAS DA METODOLOGIA MPC .....	8
2.1.3 EVOLUÇÃO DA METODOLOGIA MPC.....	11
2.1.4 TIPOS DE APLICAÇÕES.....	16
2.2 INTRODUÇÃO À OTIMIZAÇÃO EM CONTROLE DE PROCESSOS.....	19
2.2.1 OTIMIZAÇÃO EM TEMPO REAL.....	20
2.2.1.1 Otimização em Duas Camadas .....	25
2.2.1.2 Otimização em Uma Camada .....	30
2.3 CONCLUSÃO .....	33
<b>CAPÍTULO 3</b> .....	<b>35</b>
<b>3 METODOLOGIA</b> .....	<b>35</b>
3.1 CONTROLE PREDITIVO .....	35
3.1.1 MODELO DE RESPOSTA AO DEGRAU.....	35
3.1.2 CONTROLADOR PREDITIVO MPC PARA SISTEMAS MONOVARIÁVEIS .....	38
3.1.3 CONTROLADOR PREDITIVO DMC PARA SISTEMAS MULTIVARIÁVEIS.....	41
3.1.3.1 Extensão para QDMC.....	45
3.1.4 CONSIDERAÇÕES SOBRE OS PARÂMETROS DE AJUSTE DO DMC.....	45
3.2 OTIMIZAÇÃO .....	47
3.2.1 OTIMIZAÇÃO EM DUAS CAMADAS.....	47
3.2.2 OTIMIZAÇÃO EM UMA CAMADA.....	51
<b>CAPÍTULO 4</b> .....	<b>55</b>
<b>4 SIMULAÇÕES E RESULTADOS</b> .....	<b>55</b>
4.1 INTRODUÇÃO .....	55

4.2	COLUNA DE DESTILAÇÃO WOOD-BERRY .....	57
4.2.1	CONTROLE PREDITIVO QDMC.....	58
4.2.2	OTIMIZAÇÃO EM DUAS CAMADAS .....	63
4.2.2.1	Objetivo 1: $\phi$ =maximizar $(y_1 - y_2)$ .....	65
4.2.2.2	Objetivo 2: $\phi$ =minimizar $(y_2 - 5u_1)$ .....	67
4.2.2.3	Objetivo 3: $\phi$ =maximizar $(2y_1 - y_2)$ .....	69
4.2.2.4	Objetivo 4: $\phi$ =maximizar $(y_1 - y_2)$ com perturbação .....	71
4.2.2.5	Objetivo 5: $\phi$ =maximizar $(y_1 - y_2)$ com ruído .....	73
4.2.2.6	Objetivo 6: $\phi$ =maximizar $(y_1 - y_1^2 + y_2 - y_2^2)$ .....	75
4.2.3	OTIMIZAÇÃO EM UMA CAMADA .....	79
4.2.3.1	Objetivo 1: $\phi$ =maximizar $(y_1 - y_2)$ .....	80
4.2.3.2	Objetivo 2: $\phi$ =minimizar $(y_2 - 5u_1)$ .....	82
4.2.3.3	Objetivo 3: $\phi$ =maximizar $(2y_1 - y_2)$ .....	84
4.2.3.4	Objetivo 4: $\phi$ =maximizar $(y_1 - y_2)$ com perturbação .....	86
4.2.3.5	Objetivo 5: $\phi$ =maximizar $(y_1 - y_2)$ com ruído .....	88
4.2.3.6	Objetivo 6: $\phi$ =maximizar $(y_1 - y_1^2 + y_2 - y_2^2)$ .....	90
4.2.4	CONCLUSÃO.....	92
4.3	CRAQUEAMENTO CATALÍTICO EM LEITO FLUIDIZADO .....	93
4.3.1	CONTROLE PREDITIVO QDMC.....	96
4.3.2	OTIMIZAÇÃO EM DUAS CAMADAS .....	109
4.3.2.1	Maximização de GLP .....	113
4.3.3	OTIMIZAÇÃO EM UMA CAMADA .....	117
4.3.3.1	Maximização de GLP .....	117
4.3.3.2	Maximização de GLP – Com aumento da restrição de TCV .....	122
4.3.3.3	Maximização de GLP – Com perturbação .....	126
4.3.3.4	Maximização de GLP – Com ruído .....	130
4.3.3.5	Análise da influência de W3 .....	134
4.3.4	CONCLUSÃO.....	135
<b>CAPÍTULO 5 .....</b>		<b>137</b>
<b>5</b>	<b>CONCLUSÃO.....</b>	<b>137</b>
5.1	COMENTÁRIOS FINAIS .....	137
5.2	TRABALHOS FUTUROS.....	139
<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>		<b>141</b>

## LISTA DE FIGURAS

FIGURA 2.1 - ESTRATÉGIA MPC .....	9
FIGURA 2.2 - APLICAÇÃO DA METODOLOGIA MPC <i>VERSUS</i> GRAU DE NÃO LINEARIDADE DO PROCESSO.....	17
FIGURA 2.3- DIAGRAMA DE BLOCOS DA OTIMIZAÇÃO BASEADA EM MODELO.....	21
FIGURA 3.1 – RESPOSTA AO DEGRAU .....	36
FIGURA 3.2 – SEQÜÊNCIA DE VARIAÇÕES NO VALOR DE ENTRADA .....	37
FIGURA 3.3 – SEQÜÊNCIA DE VARIAÇÕES NO VALOR DE ENTRADA .....	37
FIGURA 3.4 – ESQUEMÁTICO DA OTIMIZAÇÃO EM DUAS CAMADAS.....	49
FIGURA 3.5 – FLUXOGRAMA DO ALGORITMO DA ESTRUTURA EM DUAS CAMADAS .....	50
FIGURA 3.6 – ESQUEMÁTICO DA ESTRUTURA EM UMA CAMADA .....	52
FIGURA 3.7 – FLUXOGRAMA DO ALGORITMO DA ESTRUTURA EM UMA CAMADA .....	53
FIGURA 4.1 - RESPOSTA OBTIDA $y_1$ E $y_2$ , CONTROLE DO TIPO QDMC.....	59
FIGURA 4.2 - RESPOSTA OBTIDA $u_1$ E $u_2$ , CONTROLE DO TIPO QDMC. ....	59
FIGURA 4.3 - RESPOSTA OBTIDA $y_1$ E $y_2$ , CONTROLE DO TIPO QDMC, COM MODIFICAÇÃO DOS PARÂMETROS.....	60
FIGURA 4.4 - RESPOSTA OBTIDA $u_1$ E $u_2$ , CONTROLE DO TIPO QDMC, COM MODIFICAÇÃO DOS PARÂMETROS. ....	60
FIGURA 4.5 - ALTERAÇÕES NOS VALORES DE REFERÊNCIA, SAÍDA $y_1$ E $y_2$ .....	61
FIGURA 4.6 - ALTERAÇÕES NOS VALORES DE REFERÊNCIA, SINAL DE CONTROLE $u_1$ E $u_2$ . ....	61
FIGURA 4.7 - ALTERAÇÕES NOS VALORES DE $P(s)$ .....	62
FIGURA 4.8 – INFLUÊNCIA DA PERTURBAÇÃO SOBRE $y_1$ E $y_2$ .....	62
FIGURA 4.9 - RESPOSTA OBTIDA $y_1$ E $y_2$ COM PERTURBAÇÃO DO TIPO DEGRAU INSERIDA NA SAÍDA $y_1$ . ....	62
FIGURA 4.10 - RESPOSTA OBTIDA $u_1$ E $u_2$ COM PERTURBAÇÃO DO TIPO DEGRAU NA SAÍDA $y_1$ .....	62
FIGURA 4.11 - RESPOSTA OBTIDA $y_1$ E $y_2$ COM RUÍDO INSERIDO NA SAÍDA $y_1$ .....	63
FIGURA 4.12 - RESPOSTA OBTIDA $u_1$ E $u_2$ COM RUÍDO INSERIDO NA SAÍDA $y_1$ .....	63
FIGURA 4.13 - RESPOSTAS OBTIDAS PARA A FUNÇÃO OBJETIVO $\phi = \text{MAXIMIZAR } (y_1 - y_2)$ PARA ESTRUTURA EM DUAS CAMADA.....	66
FIGURA 4.14 - RESPOSTAS OBTIDAS PARA A FUNÇÃO OBJETIVO $\phi = \text{MINIMIZAR } (y_2 - 5u_1)$ PARA ESTRUTURA EM DUAS CAMADA.....	68
FIGURA 4.15 - RESPOSTAS OBTIDAS PARA A FUNÇÃO OBJETIVO $\phi = \text{MAXIMIZAR } (2y_1 - y_2)$ COM DIMINUIÇÃO DO LIMITE MÁXIMO DAS VARIÁVEIS MANIPULADAS PARA ESTRUTURA EM DUAS CAMADA .....	70
FIGURA 4.16 - ALTERAÇÕES NOS VALORES DE $P(s)$ - OTIMIZAÇÃO EM DUAS CAMADAS .....	71
FIGURA 4.17 – INFLUÊNCIA DA PERTURBAÇÃO SOBRE $y_1$ E $y_2$ - OTIMIZAÇÃO EM DUAS CAMADAS .....	71
FIGURA 4.18 - RESPOSTAS OBTIDAS PARA A FUNÇÃO OBJETIVO $\phi = \text{MAXIMIZAR } (y_1 - y_2)$ COM PERTURBAÇÃO NA VARIÁVEL $y_1$ PARA ESTRUTURA EM DUAS CAMADA.....	72
FIGURA 4.19 - RESPOSTAS OBTIDAS PARA A FUNÇÃO OBJETIVO $\phi = \text{MAXIMIZAR } (y_1 - y_2)$ COM RUÍDO NA VARIÁVEL $y_1$ PARA ESTRUTURA EM DUAS CAMADA.....	74

FIGURA 4.20 - RESPOSTAS OBTIDAS PARA A FUNÇÃO OBJETIVO $\phi = \text{MAXIMIZAR } (Y_1 - Y_1^2 + Y_2 - Y_2^2)$ PARA ESTRUTURA EM DUAS CAMADA .....	76
FIGURA 4.21 - RESPOSTAS OBTIDAS PARA A FUNÇÃO OBJETIVO $\phi = \text{MAXIMIZAR } (Y_1 - Y_1^2 + Y_2 - Y_2^2)$ PARA ESTRUTURA EM DUAS CAMADA, COM MODIFICAÇÕES DOS AJUSTES .....	78
FIGURA 4.22 - RESPOSTAS OBTIDAS PARA A FUNÇÃO OBJETIVO $\phi = \text{MAXIMIZAR } (Y_1 - Y_2)$ PARA ESTRUTURA EM UMA CAMADA .....	81
FIGURA 4.23 - RESPOSTAS OBTIDAS PARA A FUNÇÃO OBJETIVO $\phi = \text{MINIMIZAR } (Y_2 - 5U_1)$ PARA ESTRUTURA EM UMA CAMADA .....	83
FIGURA 4.24 - RESPOSTAS OBTIDAS PARA A FUNÇÃO OBJETIVO $\phi = \text{MAXIMIZAR } (2Y_1 - Y_2)$ COM DIMINUIÇÃO DO LIMITE MÁXIMO DAS VARIÁVEIS MANIPULADAS PARA ESTRUTURA EM UMA CAMADA .....	85
FIGURA 4.25 - ALTERAÇÕES NOS VALORES DE $P(s)$ – OTIMIZAÇÃO EM UMA CAMADA .....	86
FIGURA 4.26 – INFLUÊNCIA DA PERTURBAÇÃO SOBRE $Y_1$ E $Y_2$ - OTIMIZAÇÃO EM UMA CAMADA .....	86
FIGURA 4.27 - RESPOSTAS OBTIDAS PARA A FUNÇÃO OBJETIVO $\phi = \text{MAXIMIZAR } (Y_1 - Y_2)$ COM PERTURBAÇÃO NA VARIÁVEL $Y_1$ PARA ESTRUTURA EM UMA CAMADA .....	87
FIGURA 4.28 - RESPOSTAS OBTIDAS PARA A FUNÇÃO OBJETIVO $\phi = \text{MAXIMIZAR } (Y_1 - Y_2)$ COM RUÍDO NA VARIÁVEL $Y_1$ PARA ESTRUTURA EM UMA CAMADA .....	89
FIGURA 4.29 RESPOSTAS OBTIDAS PARA A FUNÇÃO OBJETIVO $\phi = \text{MAXIMIZAR } (Y_1 - Y_1^2 + Y_2 - Y_2^2)$ PARA ESTRUTURA EM UMA CAMADA .....	91
FIGURA 4.30 - CONTROLADOR QDMC LIGADO AO MODELO DE SIMULAÇÃO .....	94
FIGURA 4.31 – ARQUITETURA DO SISTEMA DE CONTROLE .....	95
FIGURA 4.32 – SAÍDAS DO FCC - SEQÜÊNCIA DE DEGRAUS APLICADOS AS SAÍDAS DA UNIDADE.....	99
FIGURA 4.33 – ENTRADAS DO FCC - SEQÜÊNCIA DE DEGRAUS APLICADOS AS SAÍDAS DA UNIDADE .....	100
FIGURA 4.34 – ENTRADAS DOS PI'S - SEQÜÊNCIA DE DEGRAUS APLICADOS AS SAÍDAS DA UNIDADE .....	101
FIGURA 4.35 – PERTURBAÇÕES - VARIÁVEIS NÃO CONTROLADAS $RTF$ E $TFP$ .....	102
FIGURA 4.36 – SAÍDAS DO FCC – COM PERTURBAÇÕES NÃO CONTROLADAS .....	103
FIGURA 4.37 – ENTRADAS DO FCC - COM PERTURBAÇÕES NÃO CONTROLADAS .....	104
FIGURA 4.38 – ENTRADAS DOS PI'S - COM PERTURBAÇÕES NÃO CONTROLADAS.....	105
FIGURA 4.39 – SAÍDAS DO FCC – COM RUÍDO DE MEDIÇÃO NA VARIÁVEL $Trx$ .....	107
FIGURA 4.40 – ENTRADAS DO FCC - COM RUÍDO DE MEDIÇÃO NA VARIÁVEL $Trx$ .....	108
FIGURA 4.41 – ENTRADAS DOS PI'S - COM RUÍDO DE MEDIÇÃO NA VARIÁVEL $Trx$ .....	109
FIGURA 4.42 – SAÍDAS DO FCC – OTIMIZAÇÃO EM DUAS CAMADAS .....	114
FIGURA 4.43 – ENTRADAS DO FCC - OTIMIZAÇÃO EM DUAS CAMADAS .....	115
FIGURA 4.44 – ENTRADAS DOS PI'S - OTIMIZAÇÃO EM DUAS CAMADAS.....	116
FIGURA 4.45 – PRODUÇÃO DE GLP - OTIMIZAÇÃO EM DUAS CAMADAS .....	116
FIGURA 4.46 – SAÍDAS DO FCC – OTIMIZAÇÃO EM UMA CAMADAS .....	119
FIGURA 4.47 – ENTRADAS DO FCC - OTIMIZAÇÃO EM UMA CAMADA .....	120
FIGURA 4.48 – ENTRADAS DOS PI'S - OTIMIZAÇÃO EM UMA CAMADA.....	121

FIGURA 4.49 – PRODUÇÃO DE GLP - OTIMIZAÇÃO EM UMA CAMADA.....	121
FIGURA 4.50 – SAÍDAS DO FCC – OTIMIZAÇÃO EM UMA CAMADAS, COM DIMINUIÇÃO DO LIMITE SUPERIOR DE <i>TCV</i> .....	123
FIGURA 4.51 – ENTRADAS DO FCC - OTIMIZAÇÃO EM UMA CAMADA, COM DIMINUIÇÃO DO LIMITE SUPERIOR DE <i>TCV</i> .....	124
FIGURA 4.52 – ENTRADAS DOS PI'S - OTIMIZAÇÃO EM UMA CAMADA, COM DIMINUIÇÃO DO LIMITE SUPERIOR DE <i>TCV</i> .....	125
FIGURA 4.53 – PRODUÇÃO DE GLP - OTIMIZAÇÃO EM UMA CAMADA, COM DIMINUIÇÃO DO LIMITE SUPERIOR DE <i>TCV</i> .....	125
FIGURA 4.54 – OTIMIZAÇÃO EM UMA CAMADA - PERTURBAÇÕES.....	126
FIGURA 4.55 – SAÍDAS DO FCC – OTIMIZAÇÃO EM UMA CAMADAS, COM PERTURBAÇÃO.....	127
FIGURA 4.56 – ENTRADAS DO FCC - OTIMIZAÇÃO EM UMA CAMADA, COM PERTURBAÇÃO.....	128
FIGURA 4.57 – ENTRADAS DOS PI'S - OTIMIZAÇÃO EM UMA CAMADA, COM PERTURBAÇÃO.....	129
FIGURA 4.58 – PRODUÇÃO DE GLP - OTIMIZAÇÃO EM UMA CAMADA, COM PERTURBAÇÃO.....	129
FIGURA 4.59 – SAÍDAS DO FCC – OTIMIZAÇÃO EM UMA CAMADAS, COM RUÍDO.....	131
FIGURA 4.60 – ENTRADAS DO FCC - OTIMIZAÇÃO EM UMA CAMADA, COM RUÍDO.....	132
FIGURA 4.61 – ENTRADAS DOS PI'S - OTIMIZAÇÃO EM UMA CAMADA, COM RUÍDO.....	133
FIGURA 4.62 – PRODUÇÃO DE GLP - OTIMIZAÇÃO EM UMA CAMADA, COM RUÍDO.....	133
FIGURA 4.63 – SAÍDAS DO FCC – OTIMIZAÇÃO EM UMA CAMADAS, ANÁLISE DA INFLUÊNCIA DE W3.....	135



## LISTA DE TABELAS

TABELA 4.1 - PARÂMETROS DE AJUSTE DO CONTROLADOR QDMC.....	58
TABELA 4.2 - LIMITES MÁXIMOS E MÍNIMOS DAS VARIÁVEIS MANIPULADAS .....	58
TABELA 4.3 – MOVIMENTOS MÁXIMOS E MÍNIMOS DA AÇÕES DE CONTROLE.....	58
TABELA 4.4 - LIMITES MÁXIMOS E MÍNIMOS DAS VARIÁVEIS MANIPULADAS E CONTROLADAS PARA OTIMIZAÇÃO EM DUAS CAMADAS. ....	64
TABELA 4.5 - PARÂMETROS DE AJUSTE DO CONTROLADOR PARA OTIMIZAÇÃO EM DUAS CAMADAS.....	64
TABELA 4.6 – MOVIMENTOS MÁXIMOS E MÍNIMOS DA AÇÕES DE OTIMIZAÇÃO.....	64
TABELA 4.7 – MOVIMENTOS MÁXIMOS E MÍNIMOS DA AÇÕES DE CONTROLE.....	64
TABELA 4.8 - LIMITES MÁXIMOS E MÍNIMOS DAS VARIÁVEIS MANIPULADAS E CONTROLADAS, COM MODIFICAÇÃO DOS LIMITES MÁXIMOS PARA OTIMIZAÇÃO EM DUAS CAMADAS.....	69
TABELA 4.9 - LIMITES MÁXIMOS E MÍNIMOS DAS VARIÁVEIS MANIPULADAS E CONTROLADAS, PARA OTIMIZAÇÃO EM UMA CAMADA .....	79
TABELA 4.10 - PARÂMETROS DE AJUSTE DO CONTROLADOR E DA OTIMIZAÇÃO EM UMA CAMADA .....	79
TABELA 4.11 - MOVIMENTOS MÁXIMOS E MÍNIMOS DA AÇÕES DE OTIMIZAÇÃO EM UMA CAMADA.....	79
TABELA 4.12 - MOVIMENTOS MÁXIMOS E MÍNIMOS DA AÇÕES DE CONTROLE PARA OTIMIZAÇÃO EM UMA CAMADA .....	79
TABELA 4.13 - LIMITES MÁXIMOS E MÍNIMOS DAS VARIÁVEIS MANIPULADAS E CONTROLADAS, COM MODIFICAÇÃO DOS LIMITES MÁXIMOS PARA OTIMIZAÇÃO EM UMA CAMADA.....	84
TABELA 4.14 - CONSTANTES DE SINTONIA DOS CONTROLADORES PI.....	95
TABELA 4.15 - LIMITES MÁXIMOS E MÍNIMOS DAS VARIÁVEIS MANIPULADAS E CONTROLADAS PARA UNIDADE DE FCC.....	96
TABELA 4.16 - PARÂMETROS DE AJUSTE DO CONTROLADOR QDMC PARA A UNIDADE DE FCC.....	96
TABELA 4.17 – MOVIMENTOS MÁXIMOS E MÍNIMOS DA AÇÕES DE CONTROLE .....	97
TABELA 4.18 – PROPRIEDADES TÍPICAS DO GÁS-ÓLEO .....	111
TABELA 4.19 – MOVIMENTOS MÁXIMOS E MÍNIMOS DA AÇÕES DE OTIMIZAÇÃO.....	112
TABELA 4.20 – MOVIMENTOS MÁXIMOS E MÍNIMOS DA AÇÕES DE CONTROLE UTILIZADOS NA OTIMIZAÇÃO .....	112
TABELA 4.21 - PARÂMETROS DE AJUSTE DO CONTROLADOR E DA OTIMIZAÇÃO EM UMA CAMADA PARA A UNIDADE DE FCC .....	117





## NOMENCLATURA

---

### ABREVIACOES:

APC	<i>Advanced Process Control</i> Controle Avanado do Processo
ARMAX	<i>Auto-Regressive Moving Average with Exogenous Input</i>
CARIMA	<i>Controlled Autoregressive Integrated Moving Average Input</i>
DMC	<i>Dynamic Matrix Control</i> Controle por Matriz Dinmica
EKF	<i>Extended Kalman Filter</i> Filtro de <i>Kalman</i> estendido
FCC	<i>Fluidized Catalytic Cracking</i> Craqueamento Cataltico em Leito Fuidizado
FIR	<i>Finite Impulse Response</i> Resposta Finita ao Impulso
FSR	<i>Finite Step Response</i> Resposta Finita ao Degrau
GPC	<i>Generalized Predictive Control</i> Controle Preditivo Generalizado
HIECON	<i>Hierarchical Constraint Control</i>
IMC	<i>Internal Model Control</i> Controle por modelo interno,
LDMC	<i>Liner Dynamic Matrix Control</i> Controle Linear por Matriz Dinmica

LPG	<i>Liquified Petroleum Gas</i> Gás Liquefeito de Petróleo
LP	<i>Linear Programming</i> Programação Linear
LQG	<i>Linear Quadratic Gaussian</i> Linear Quadrático Gaussiano
LS	<i>Least Square</i> Mínimos Quadrados
NARMAX	<i>Nonlinear Auto-Regressive Moving Average with Exogenous Input</i>
NLP	<i>Nonlinear Programming</i> Programação Não Linear
NMPC	<i>Nonlinear Model Predictive Control</i> Controle Preditivo Não Linear Baseado em Modelo
MPC	<i>Model Predictive Control</i> Controle Preditivo Baseado em Modelo
MPHC	<i>Model Predictive Heuristic Control</i>
PI	Proporcional, Integral
PID	Proporcional, Integral, Derivativo
QDMC	<i>Quadratic Dynamic Matrix Control</i> Controle Quadrático por Matriz Dinâmica
QP	<i>Quadratic Programming</i> Programação Quadrática
RHC	<i>Receding Horizon Control</i> Controle de Horizonte Retroativo
SISO	<i>Single-input / Single-output</i> Entrada única / Saída única

SMCA	<i>Setpoint Multivariable Control Architecture</i>
SMOC	<i>Shell Multivariable Optimizing Controller</i>
SQP	<i>Sequential Quadratic Programming</i> Programação Quadrática Sequencial

## NOTAÇÕES:

$a_i$	Coefficiente de resposta ao degrau unitário em $i.T_e$
$A_n$	Matriz de ganho do estado estacionário
$A$	Matriz dinâmica dos coeficientes de resposta ao degrau da variável controlada (sistemas monovariáveis)
$\underline{\underline{A}}$	Matriz dinâmica dos coeficientes de resposta ao degrau da variável controlada (sistemas multivariáveis)
$c$	Número de variáveis controladas (saídas)
$d$	Perturbação influenciando a saída ( $y$ )
$E'$	Vetor dos erros preditos considerando as ações futuras e passadas de controle
$E$	Vetor dos erros preditos considerando as ações passadas de controle
$I$	Matriz identidade
$J(t)$	Critério de custo a minimizar
$m$	Número de variáveis manipuladas (entradas)
$N_p$	Horizonte do modelo
$N_u$	Horizonte de controle
$N_y$	Horizonte de predição
$t$	Instante de tempo
$u$	Vetor das variáveis manipuladas (entradas do sistema)
$\bar{u}$	Valor da variável manipulada, considerando-se alteração da referência.
$\Delta U$	Vetor das amplitudes das ações de controle
$\Delta y_{set}$	Vetor das amplitudes dos sinais de referência

$\Delta y_{set}^{\min}$	mínimo valor permitido para amplitude dos sinais de referência
$\Delta y_{set}^{\max}$	máximo valor permitido para amplitude dos sinais de referência
$w$	Coefficiente de peso
$W$	Matriz diagonal de peso das variáveis controladas
$W_1, W_2, W_3,$	Fatores de peso
$y$	Vetor das variáveis controladas (saída do processo)
$y_m$	Vetor dos valores atuais das variáveis controladas
$Y_p$	Vetor da predição das variáveis controladas
$Y_{past}$	Vetor da predição das variáveis controladas, baseado somente nas ações de controle passadas
$y_{set}$	Vetor das referências ( <i>setpoints</i> ) das variáveis controladas
$y_{set}^{\min}$	Mínimo valor permitido para os sinais de referência
$y_{set}^{\max}$	Máximo valor permitido para os sinais de referência
$\bar{y}(t + N_p)$	Valor da saída do processo no estado estacionário futuro, considerando as alterações no valor da referência devidas ao acréscimo de $\Delta y_{set}$

### SÍMBOLOS GREGOS:

$\Lambda$	Matriz diagonal dos fatores de supressão dos movimentos de entrada ( $\lambda$ )
$\lambda$	Coefficiente dos fatores de supressão
$\emptyset$	Função custo do modelo econômico do processo

## RESUMO

Este trabalho apresenta um estudo de uma classe de controladores preditivos baseados em modelo, conhecido por QDMC, e sua aplicação em processos multivariáveis que apresentam características complexas e requerem a utilização de métodos de controle mais elaborados para atender as exigências destes processos.

Propõe-se a inserção de critérios de otimização resolvidos de forma periódica sob a estruturação de otimização em uma camada. Para comparação de resultados, uma segunda forma de implementação de otimização, conhecida por otimização hierárquica, é também implementada.

A aplicação das metodologias propostas é feita através de simulações com o uso de programas matemáticos. Os processos utilizados para o estudo são: Coluna de Destilação Wood-Berry e Unidade de Craqueamento Catalítico em Leito Fluidizado. A coluna de destilação é utilizada para exploração das abordagens de otimização, desta forma, são efetuadas simulações com diferentes funções econômicas com o objetivo de avaliar o desempenho das metodologias e o comportamento frente a critérios distintos. O modelo da Unidade de Craqueamento Catalítico em Leito Fluidizado é utilizado para uma análise final das técnicas propostas.

Os resultados obtidos demonstram uma maior flexibilidade de aplicação da otimização em uma camada, quando comparada à otimização hierárquica, por apresentar bom desempenho no tratamento de variáveis de difícil controle e na resolução de função econômica não linear.



## **ABSTRACT**

This dissertation proposes the study of a model predictive controller, called QDMC, and its application in multivariable systems with complex characteristics that need the employment of robust control methods.

This work also proposes the insertion of both one layer optimization and hierarchic optimization approaches to compare the results.

The methodologies are applied through the simulation of two processes: Wood-Berry Distillation Column and Fluid Catalytic Cracking Unit (FCC). The distillation column is used to explore the optimization approaches. In this manner, simulations with different cost functions are made. The model of Fluid Catalytic Cracking is used to the final analysis of the presented methodologies.

From the results, it is possible to conclude that one layer optimization has a better flexibility when compared to hierarchic optimization because the first approach presented a good performance in the treatment of a variable control difficult and with the utilization of a nonlinear economic function.





# CAPÍTULO 1

## INTRODUÇÃO

---

### 1.1 CARACTERIZAÇÃO DO PROBLEMA E OBJETIVO

As indústrias em geral têm buscado constante melhoria em seus processos com o intuito de obter a melhor relação entre custo e produção através de procedimentos de adequação, como utilização eficiente de matéria prima, aumento da velocidade de processamento, entre outras modificações.

Os sistemas de controle, independentemente das suas características ou família a que pertencem, são a estrutura básica utilizada no meio industrial para a estabilização de plantas e alcance de valores de saída previamente determinados pelos operadores do processo.

Ao longo dos anos, diferentes técnicas de controle foram desenvolvidas e são empregadas atualmente para proporcionar o alcance de objetivos distintos. Apesar da arquitetura básica do controle industrial ser composta principalmente por controladores PID (proporcional-integral-derivativo) que atingem cerca de 90% das malhas de controle industriais (ASTRÖM e HÄGGLUND, 2001), controladores de estrutura mais elaborada podem ser utilizados em sistemas industriais que apresentem características complexas como não linearidades, atrasos de transporte e acoplamento entre as variáveis.

Controladores Preditivos foram originalmente desenvolvidos para o controle específico de plantas em refinarias de petróleo, que apresentam dificuldades características deste tipo de processamento. Apesar de sua origem específica, devido ao bom desempenho desta metodologia, os controladores preditivos podem ser atualmente encontrados em uma grande variedade de áreas industriais (QIN e BADGWELL, 2000).

O controle preditivo baseado em modelo (MPC) se refere a uma classe de algoritmos de controle que utilizam o modelo do processo para prever respostas futuras da planta. A cada intervalo de tempo, o algoritmo MPC otimiza o comportamento futuro da planta a partir do cálculo de uma seqüência de ajustes futuros das variáveis manipuladas.

O controle preditivo baseado em modelo tem sido foco de muitos estudos e aplicações, que visam avaliar seu desempenho e melhorar algumas de suas características, conforme exemplos apresentados no capítulo 2. Isto ocorre atualmente, porque esta

metodologia é capaz de fornecer soluções às necessidades de algumas aplicações industriais complexas.

O objetivo principal deste trabalho é o estudo, aplicação e avaliação de uma determinada metodologia de controladores preditivos baseados em modelo para processos multivariáveis que apresentem características complexas que justificam a utilização de métodos de controle mais elaborados.

Sistemas de controle de processos utilizados no meio industrial, apesar de muitas vezes serem adequados para garantir precisão do comportamento das variáveis envolvidas, podem não ser uma ferramenta suficiente para assegurar a operação da planta em níveis inteiramente satisfatórios e desejados (SÁNCHEZ e RODELLAR, 1996).

A procura por uma maior eficiência nas diversas etapas de produção tem justificado o uso de técnicas de otimização, paralelamente aos sistemas de controle, que possibilitem a exploração do processo em pontos de melhor aproveitamento. A otimização pode ser definida classicamente como a arte de se obter as melhores condições para satisfazer determinados objetivos, simultaneamente ao atendimento de certos requisitos fixos (GOTTFRIED e WEISMAN, 1973).

Em processos industriais, a otimização é obtida pela determinação dos valores de referência para as variáveis controladas, através da maximização de objetivos descritos em uma função custo, que relaciona as variáveis do processo com os requisitos a serem atingidos.

O segundo objetivo deste trabalho é, após a implementação do controle preditivo nos processos estudados, a inserção de critérios de otimização, resolvidos de forma periódica e com implementação automática (*on-line*), sob a estruturação de otimização em uma camada.

Para comparação de resultados, uma segunda estrutura de otimização, conhecida por otimização em duas camadas, será também implementada, possibilitando desta forma uma análise mais significativa dos resultados obtidos. Esta comparação de resultados, entre otimização em uma e duas camadas, é o terceiro objetivo deste trabalho.

## **1.2 APLICAÇÃO DA METODOLOGIA**

A aplicação das metodologias propostas nos processos estudados é feita através de simulações com o uso de *softwares* matemáticos.

O controlador preditivo utilizado nas simulações é denominado *Quadratic Dynamic Matrix Control* (QDMC), ou Controle Quadrático por Matriz Dinâmica.

Este controlador foi eleito, entre a diversidade de controladores preditivos, por apresentar características para o controle de processos multivariáveis complexos, conforme será exposto no capítulo 2, por ser suficiente para o controle dos processos estudados neste trabalho, além de possibilitar a implementação de requisitos de otimização, que é outro objetivo desta dissertação.

As abordagens de otimização em duas e em uma camada serão aplicadas de maneira associada ao controle preditivo.

Os processos utilizados para o estudo das metodologias citadas são: Coluna de Destilação Wood-Berry, e o processo de Craqueamento Catalítico em Leito Fluidizado (FCC).

A coluna de destilação é apenas utilizada para demonstração da flexibilidade da metodologia, uma vez que é um modelo simplificado de uma coluna real. Neste processo, são simulados diferentes critérios de otimização, que não representam necessariamente aspectos práticos, mas que possibilitam a verificação do desempenho da abordagem e o comportamento frente critérios distintos.

O FCC, que é um processo amplamente empregado em refinarias de petróleo, é utilizado através da simulação de um modelo, posteriormente aos testes na coluna de destilação, para a validação final da metodologia. Nesta simulação, são utilizados critérios de controle e otimização corretamente associados a um objetivo econômico coerente.

### **1.3 CONTRIBUIÇÕES**

As contribuições principais deste trabalho podem ser resumidas como o estudo do desempenho do controlador preditivo QDMC aplicado em processos multivariáveis com características distintas, e a comparação de resultados obtidos com a utilização de estrutura de otimização em uma camada e em duas camadas.

O estudo e a implementação de diferentes metodologias em processos simulados garantem o aprimoramento das tecnologias, e proporcionam segurança no meio industrial para absorção de técnicas desenvolvidas no meio acadêmico.

A metodologia apresentada é abrangente, podendo ser estendida a diferentes processos com objetivos de otimização distintos.

## **1.4 ORGANIZAÇÃO DA DISSERTAÇÃO**

No presente capítulo, as motivações, os objetivos, e as contribuições deste trabalho foram apresentados.

O capítulo 2 fará uma introdução ao controle preditivo com ênfase maior na classe de controladores preditivos baseados em modelo, metodologia utilizada neste trabalho, além de alguns exemplos de aplicações encontrados na literatura. Será também apresentada uma introdução à otimização em tempo real, e revisão de literatura sobre aplicação desta técnica, estruturada em uma e duas camadas, conjuntamente ao controle preditivo.

No capítulo 3, as metodologias aplicadas serão descritas, e serão apresentados alguns detalhes de implementação do controlador QDMC utilizado neste trabalho, além das características do algoritmo de otimização incorporado nas simulações.

Os processos simulados para a validação da proposta serão apresentados no capítulo 4, conjuntamente aos resultados obtidos, e à avaliação de cada simulação efetuada.

No capítulo 5, serão apresentados as principais conclusões do trabalho e comentários finais, como também, sugestões para trabalhos futuros.

## CAPÍTULO 2

### 2 REVISÃO BIBLIOGRÁFICA

---

#### 2.1 INTRODUÇÃO AO CONTROLE PREDITIVO BASEADO EM MODELO

Em sistemas de controle de processos industriais, normalmente são utilizadas duas principais abordagens (SEBORG *et al.*, 1989):

- Metodologia Tradicional: A estratégia e o sistema de controle são selecionados a partir de conhecimento prévio do processo e experiência dos operadores. Após o sistema de controle ser instalado na planta, os parâmetros do controlador escolhido são sintonizados.
- Metodologia Baseada em Modelo: Um modelo do processo é desenvolvido e pode ser incorporado diretamente nas leis de controle a serem utilizadas, ou em uma segunda abordagem, pode ser utilizado em simulações para avaliação de estratégias de controle alternativas e para o cálculo preliminar dos parâmetros de ajuste do sistema de controle selecionado.

A metodologia baseada em modelo apresenta algumas vantagens. Em plantas modernas de processamento, verifica-se uma grande integração entre fluxo de material e energia, o que torna a operação da planta mais difícil através da metodologia tradicional. Além disto, existem incentivos econômicos que podem sugerir a operação da planta perto de seus limites de restrições para maximizar lucros sem comprometer critérios de segurança, tais situações podem ser avaliadas através de simulações (SEBORG *et al.*, 1989).

Existem muitos objetivos de controle distintos, que dependem principalmente das características do sistema em questão, e das condições da planta na qual este sistema está incluso. Apesar disto, a estabilidade em malha fechada é um dos fatores principais observados em um sistema de controle.

Diferentes técnicas de controle podem ser utilizadas com o objetivo principal de manter as saídas do processo em valores de referência previamente estipulados. Abordagens de controle clássico, controle ótimo, controle robusto, controle adaptativo e controle inteligente são empregadas para esta proposta.

O Controle Preditivo Baseado em Modelo, ou *Model Predictive Control* (MPC), é uma das principais ramificações do controle preditivo. Esta metodologia permite agregar outras

tarefas aos controladores, além da condução das variáveis controladas a seus valores de referência pré-determinados. Estas tarefas podem ser relacionadas como:

- Prevenir violações de restrições de entradas e saídas.
- Conduzir variáveis controladas e manipuladas a seus valores ótimos de estado estacionário.
- Prevenir movimentação excessiva das variáveis manipuladas.

A metodologia MPC foi inicialmente desenvolvida e introduzida para aplicações em sistemas de potência e refinarias de petróleo, porém, atualmente, sua utilização pode ser observada em outras áreas industriais.

Os algoritmos MPC são fundamentados no comportamento futuro do sistema a ser controlado, com a utilização de um modelo do processo. As saídas preditas são calculadas com base na saída atual do processo, como também nas entradas passadas. O valor da saída predita é calculado minimizando um critério de custo. É previsto determinado número de saídas futuras em um horizonte de predição, mas somente a primeira previsão é aplicada a cada tempo, e assim, uma serie de saídas futuras é novamente calculada.

A metodologia MPC pode ser utilizada como controle tradicional em processos industriais, como também ser empregada paralelamente a técnicas de otimização que visam o alcance de desempenho ótimo.

O presente trabalho visa apresentar exemplos do controle MPC aplicado a processos industriais com características complexas, como não linearidades e acoplamento entre as variáveis, com posterior introdução de outros critérios de otimização.

### **2.1.1 ORIGEM DO CONTROLE PREDITIVO BASEADO EM MODELO**

O conceito base de controle preditivo foi introduzido por Sánchez em sua tese de doutorado em 1974 (SÁNCHEZ e RODELLAR, 1996). Este conceito base determina que, através das características prévias das variáveis de processo de entrada e saída, o controlador preditivo deve gerar um sinal de controle que torne a saída do processo predita igual a saída previamente estipulada, relacionando os objetivos com as restrições físicas. Desta forma, a

saída do processo é encaminhada à referência desejada de maneira satisfatória, rápida e estável, sem ação excessiva de controle (SÁNCHEZ e RODELLAR, 1996).

O projeto de um controlador preditivo pode ser subdividido em duas etapas principais, primeiramente é necessária a identificação de um modelo matemático capaz de representar o comportamento do processo real, e, posteriormente, faz-se a aplicação de um algoritmo de controle adequado (SOETERBOEK, 1990).

Alguns algoritmos de controle foram desenvolvidos, após a introdução do conceito base de controle preditivo, dividindo a metodologia em linhas de pesquisa com algumas características diferentes entre si. As três ramificações do controle preditivo e suas principais características são (KWON e HAN, 2003):

Model Predictive Control (MPC), ou Controle Preditivo Baseado em Modelo (RICHALET *et al.*, 1978):

- Introduzido por engenheiros de controle de processos.
- A relação de entrada e saída do processo é obtida através de modelos de resposta finita ao impulso (*Finite Impulse Response - FIR*), ou ao degrau (*Finite Step Response - FSR*).
- Possibilidade de manipulação das restrições dos atuadores.

Generalized Predictive Control (GPC), ou Controle Preditivo Generalizado (CLARKE<sup>A</sup> *et al.*, 1987) (CLARKE<sup>B</sup> *et al.*, 1987):

- Introduzido por teóricos em controle adaptativo.
- Utiliza, para identificação do processo, modelos de entrada e saída como CARIMA e ARMAX.

Receding Horizon Control (RHC), ou Controle de Horizonte Adaptativo (MAYNE, e MICHALSKA, 1990):

- Introduzido por teóricos em controle ótimo.
- Utiliza modelos de espaço de estados do processo.

Estas três estratégias de controle foram muito investigadas e implementadas no meio industrial de forma independente, na maior parte dos casos (KWON e HAN, 2003). Porém,

atualmente, alguns autores não têm mais distinguido estas ramificações. A representação por espaço de estados utilizada no algoritmo RHC possibilita que as estratégias MPC e GPC possam ser consideradas como casos especiais do RHC, além disto, os resultados obtidos com as três metodologias podem ser considerados equivalentes quando a modelagem é a mesma (KWON e HAN, 2003). É possível encontrar artigos como De Nicolao *et al.* (2000) e Mayne *et al.* (2000), entre outros, nos quais a designação MPC é referenciada como equivalente da RHC. Da mesma forma, Kim (2002) cita as três ramificações, MPC, GPC e RHC como diferentes denominações da mesma metodologia.

Será apresentado a seguir o histórico e as principais características dos controladores preditivos da linha inicialmente referenciada como MPC, pois esta foi a primeira classe a ser desenvolvida e introduzida, tendo as demais subdivisões origem mais recente, e devido ao fato do presente trabalho abordar a utilização de controladores originais desta ramificação.

Após o conceito base introduzido por Sánchez (1974), o histórico do controle preditivo inicia-se, como anteriormente citado, com o desenvolvimento da classe de controladores MPC, mais especificamente do controlador DMC.

A metodologia MPC não é uma estratégia de controle específica, mas um agrupamento de métodos de controle desenvolvidos em torno de determinadas idéias (SOHLBERG, 1998).

### **2.1.2 PRINCIPAIS CARACTERÍSTICAS DA METODOLOGIA MPC**

Apesar de existirem diferentes algoritmos inseridos na metodologia MPC, que serão apresentados na seção 2.1.3, é possível condensar os princípios de funcionamento e as principais características comuns entre os controladores desta classe.

Controladores preditivos baseados em modelo são normalmente estruturados a partir das três seguintes considerações (ROBERTS, 1999):

- Uso explícito de um modelo para prever a saída do processo ao longo de um horizonte de tempo futuro.
- Cálculo de uma seqüência de sinais de controle para otimizar o índice de desempenho.



- Estratégia dinâmica de horizonte de predição, na qual, em cada instante, o horizonte é movido em direção ao futuro.

Outros aspectos referentes à rotina destes algoritmos podem ser condensados da seguinte forma (QIN e BADGWELL, 2003):

- O problema de otimização é resolvido de forma *on-line* a cada execução do controle.
- A primeira entrada da seqüência ótima calculada é aplicada na planta e o problema é repetido novamente, no próximo intervalo de tempo, utilizando-se medidas atualizadas do processo.
- A dinâmica da planta é descrita por um modelo do processo que pode, a princípio, possuir qualquer formato matemático.
- As restrições de entrada e saída do processo são incluídas diretamente na formulação do problema, desta forma, violações futuras podem ser prevenidas.

Desta forma, a estratégia básica de funcionamento dos algoritmos pertencentes à metodologia MPC pode ser estruturada conforme Figura 2.1 (ROBERTS, 1999) (CAMACHO e BORDONS, 2004):

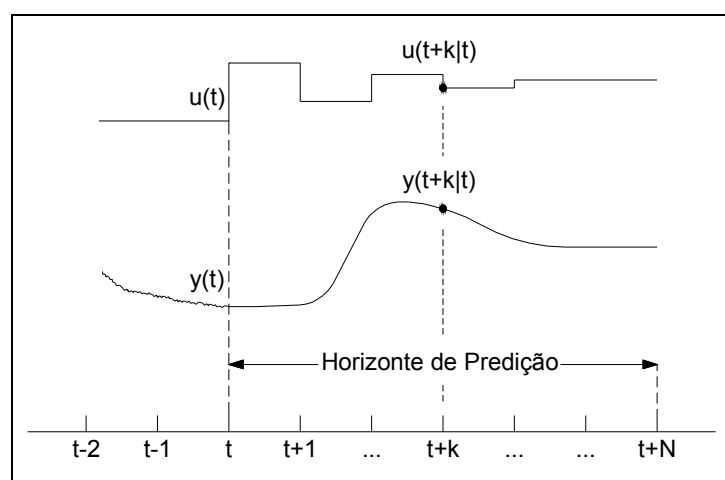


Figura 2.1 - Estratégia MPC

- i. As saídas futuras previstas  $y(t+k|t)$ ,  $k = 1 \dots N$ , para o horizonte de predição  $N$ , são calculadas em cada instante  $t$  através do modelo do processo. As predições das saídas dependem dos valores existentes até o tempo  $t$  (entradas e saídas passadas) e dos sinais de controle  $u(t+k|t)$ ,  $k = 0 \dots N-1$  a serem calculados.
- ii. A seqüência de sinais de controle futuros é calculada minimizando-se um critério de desempenho que visa manter o processo o mais próximo possível de sua trajetória de referência. Este critério normalmente é uma função quadrática do erro entre as saídas previstas e a trajetória de referências, podendo ser incluído também penalização para o esforço do controlador. Para critérios quadráticos e modelo linear, a solução pode ser encontrada de forma direta, caso contrário, é necessária a utilização de métodos numéricos.
- iii. O sinal de controle  $u(t|t)$  é enviado ao processo e os demais sinais são desconsiderados. No instante seguinte ( $t+1$ ), os passos anteriores são repetidos com valores atualizados para os cálculos, ou seja, com o horizonte de predição deslocado.

O controle preditivo baseado em modelo é atualmente considerado uma das técnicas de controle moderno mais potentes, tendo muita aceitação nas aplicações industriais, principalmente na área petroquímica (TORRICO e NORMEY-RICO, 2003).

O sucesso da metodologia MPC pode ser atribuído a três importantes fatores. Primeiramente, a incorporação de um modelo explícito no cálculo de controle. Isto permite que o controlador trabalhe diretamente com todas as características significativas da dinâmica do processo. Em segundo lugar, o algoritmo MPC considera o comportamento da planta sobre um horizonte futuro. Isto significa que os erros podem ser antecipados e removidos, permitindo ao controle direcionar a planta a resultados mais próximos da trajetória futura desejada. Em terceiro lugar, o algoritmo considera as entradas do processo, estados e restrições de saída diretamente nos cálculos de controle, o que proporciona resultados de estado estacionário próximos do ótimo (QIN e BADGWELL, 2000).

Além disto, controladores preditivos possuem a característica de atuar de forma eficiente em sistemas perturbados (SORENSEN *et al.*, 1999) e capacidade de operar sem a intervenção de um especialista por um longo período de tempo (GARCIA *et al.*, 1989).

### 2.1.3 EVOLUÇÃO DA METODOLOGIA MPC

Deste a introdução do conceito de controle preditivo, vários controladores da linha MPC foram desenvolvidos e atualmente continuam em processo de aprimoramento.

A seguir serão apresentadas as principais características dos mais importantes controladores preditivos baseados em modelo, com alguns exemplos de aplicações no meio industrial.

A primeira descrição de aplicações de controle MPC foi apresentada por Richalet *et al.* (1976) (QIN e BADGWELL, 2003). O controlador desenvolvido foi denominado como *Model Predictive Heuristic Control* (MPHC) e o pacote de *software* como *Identification and Command* (IDCOM) (QIN e BADGWELL, 2003).

Richalet *et al.* (1976) utilizaram uma representação na qual as entradas do processo são divididas em variáveis manipuladas que o controlador regula, e variáveis de perturbação que não são disponíveis ao controle. As principais características do MPHC podem ser resumidas da seguinte forma (QIN e BADGWELL, 2003):

- A descrição da relação entre as entradas e saídas do processo é feita através da utilização do modelo de resposta finita ao impulso (FIR) discretizada.
- É utilizada uma função objetivo quadrática com horizonte de predição finito.
- O comportamento futuro desejado das variáveis controladas é especificado por uma trajetória de referência.
- As restrições das variáveis são incluídas na formulação.

A velocidade da resposta em malha fechada desejada é ajustada através da constante de tempo da trajetória de referência. Isto proporciona um caminho natural para o controle da característica de resposta do algoritmo, aumentando-se a constante de tempo induz-se a um controlador mais lento, porém mais robusto (QIN e BADGWELL, 2003).

Em plantas que apresentem instabilidades, Richalet *et al.* (1976) sugeriram a utilização de outra técnica de controle, como controladores PID, para fins de estabilização, com posterior implementação do MPHC em cascata para melhoria do desempenho em malha fechada (QIN e BADGWELL, 2003).

Devido às restrições, o algoritmo de controle não linear resultante não pode ser descrito por uma função de transferência, por isso o MPHC é classificado como um algoritmo heurístico (QIN e BADGWELL, 2003).

Posteriormente, a partir do trabalho de Richalet *et al.* (1978) o algoritmo MPHC ficou conhecido como *Model Algorithmic Control* (MAC) (CAMACHO e BORDONS, 2004).

Exemplos de aplicação do algoritmo MAC podem ser encontrados em Kaynak *et al.* (1987) que avaliaram esta metodologia para o controle de servo posição de sistemas robóticos. Os problemas de regulação e acompanhamento de referência foram estudados e os resultados de simulação apresentados, demonstrando que o MAC possui bom desempenho para esta aplicação.

Chen e Rink (1995) combinaram a estrutura de controle MAC com um compensador de tempo morto adaptativo, para aplicação em sistemas com tempo de atraso e fase não mínima.

Paralelamente ao desenvolvimento do controlador MPHC, Cutler e Ramaker (1979) desenvolveram um controlador denominado *Dynamic Matrix Control* (DMC), ou Controle por Matriz Dinâmica, que difere do trabalho apresentado por Richalet *et al.* (1978) principalmente devido à utilização de um modelo de resposta finita ao degrau (FSR – *Finite Step Response*).

O modelo de resposta ao degrau utilizado no DMC relaciona mudanças na saída do processo a uma soma ponderada de mudanças passadas na entrada. Com a utilização do modelo de resposta ao degrau, escreve-se as variações preditas para saída como uma combinação linear das entradas futuras, através de uma matriz denominada matriz dinâmica. Esta representação permite que o vetor ótimo possa ser calculado como a solução de um problema de mínimos quadrados (QIN e BADGWELL, 2003).

O objetivo do controlador DMC é conduzir as saídas do processo aos seus valores de referência através de uma minimização de erros quadráticos conjuntamente a uma penalidade para movimentações das variáveis manipuladas.

As principais características do controlador DMC são (QIN e BADGWELL, 2003):

- A descrição da relação entre as entradas e saídas do processo é feita através da utilização do modelo de resposta finita ao degrau (FSR).
- É utilizada uma função objetivo quadrática com horizonte de predição finito.
- O comportamento futuro da saída da planta é especificado pela tentativa de acompanhamento de referência constante.
- Soluções ótimas são calculadas como a solução de um *Least Square Problem* (LS), ou Problema de Mínimos Quadrados.

Ochs *et al.* (1998) fizeram uma comparação entre o controle descentralizado PI e controle DMC aplicados a um processo de manufatura de tubos de vidro utilizados para fabricação de fibra óptica. Ambos controladores apresentaram características parecidas para rejeição de perturbações, e o controlador DMC apresentou desempenho superior no acompanhamento de referência.

Alpbaz *et al.* (2002) apresentaram uma comparação entre controladores DMC e controladores PID aplicados a um sistema de controle de uma coluna de destilação piloto. Os resultados da simulação demonstraram que o desempenho do sistema com o controlador DMC é melhor que o obtido através da utilização de controle PID.

Ibarrola *et al.* (2002) apresentaram algumas modificações no algoritmo DMC para trabalhar com funções de transferência com parâmetros variáveis, com objetivo de controlar um processo de pasteurização de tempo curto de alta temperatura.

Prosdóssimo (2003) apresentou uma aplicação do controle preditivo por matriz dinâmica (DMC) em um simulador do conversor de FCC. Apresentou também uma comparação entre o controlador DMC e os tradicionais controladores PI utilizados na indústria.

Em 1982, Garcia e Morari propuseram uma metodologia de MPC conhecida como *Internal Model Control* (IMC), ou controle por modelo interno, tendo como principais características:

- A descrição da relação entre as entradas e saídas do processo é feita através da utilização do modelo de resposta finita ao impulso (FIR).
- Como função custo é utilizada uma função objetivo quadrática.

- O comportamento futuro da saída da planta é especificado pela tentativa de acompanhamento do sinal de referência.
- Como não são inseridas restrições na função objetivo, as ações de controle ótimas são calculadas através de uma solução analítica.

Garcia e Morari (1985) apresentam a aplicação do controlador IMC a dois modelos de simulações distintos, sendo estes uma coluna de destilação proposta por Wood e Berry (1973) e um reator de leito fixo proposto por Foss *et al.* (1980). Os resultados obtidos pelo IMC foram comparados a um controlador do tipo PI, sendo que o IMC apresentou melhor desempenho para ambos os modelos utilizados nas simulações.

Arkun *et al.* (1986) apresentam uma aplicação do controlador IMC em um tanque de águas controlando a temperatura e o nível da água. Foi possível concluir neste trabalho que o controlador IMC apresentou respostas melhores quando comparado a um controlador do tipo PI, como também apresentou melhores resultados quando da inserção proposital de erros de modelagem.

Gentilin (2004) apresenta uma aplicação do controlador preditivo IMC a dois modelos de simulação de unidades de FCC. O primeiro modelo é proposto Prosdóssimo (2003) baseado no trabalho de Moro e Odloak (1995), e o segundo modelo é proposto e implementado por Erthal (2003). O controle preditivo atua gerando setpoints para uma segunda camada de controle, composta por controladores PI. Os resultados demonstram que o controlador IMC respondeu de forma satisfatória as variações nos valores de referência das variáveis controladas. Os resultados também apresentam também uma comparação entre os controladores IMC+PI e os PI, sendo que o primeiro apresentou resultados superiores.

Os algoritmos MPHIC, DMC e IMC apresentam um adequado funcionamento em processos multivariáveis sem restrições. Em certos casos, restrições podem ser incorporadas nestes algoritmos, mas são tratadas de maneira *ad-hoc* (QIN e BADGWELL, 2003).

Com o objetivo de incorporar maior flexibilidade nestes algoritmos, Garcia e Morshedi (1986) apresentaram o *Quadratic Dynamic Matrix Control* (QDMC), ou Controle Quadrático por Matriz Dinâmica, no qual é possível incorporar restrições tanto nas entradas quando nas saídas de maneira explícita.

As principais características deste controlador são (QIN e BADGWELL, 2003):

- A descrição da relação entre as entradas e saídas do processo é feita através da utilização do modelo de resposta finita ao degrau (FSR).
- É utilizada uma função objetivo quadrática com horizonte de predição finito.
- O comportamento futuro da saída da planta é especificado pela tentativa de acompanhamento de referência constante sujeita a um termo de supressão de movimento.
- Soluções ótimas são encontradas através da resolução de um problema de *Quadratic Programming* (QP), ou Programação Quadrática.

As restrições nas variáveis são formuladas como *hard constraints*, o que significa que devem ser estritamente satisfeitas durante todo o horizonte de predição. Em muitos casos, nas variáveis de saída estas restrições são impostas apenas em um intervalo de tempo conhecido como *constraint window*, que se inicia em determinado tempo futuro e se estende até o estado estacionário. Garcia e Morshedi (1986) apresentaram também uma segunda forma de incorporar restrições nas variáveis de saída denominada *soft constraints*, que permite uma violação ocasional da restrição que é minimizada de acordo com um critério de mínimos quadrados (QIN e BADGWELL, 2003).

Dougherty e Cooper (2003) apresentaram uma estratégia de controle adaptativa para controladores DMC e QDMC. A metodologia apresenta o projeto de múltiplos controladores lineares preditivos com ajuste de parâmetros feito através de expressões analíticas. A saída do controlador adaptativo é uma média ponderada dos múltiplos controladores preditivos. A metodologia foi testada em uma simulação de um sistema trocador de calor.

Zheng e Hoo (2004) apresentaram um método particular de identificação para sistemas com parâmetros distribuídos (DPS - *distributed parameter systems*) utilizado no desenvolvimento de um controlador QDMC. O método fornece um modelo finito linear específico que captura variações espaciais e temporais do DPS. A estratégia foi aplicada a um reator químico com não linearidades.

O algoritmo QDMC constitui uma evolução do MPC, que abrange os algoritmos que proporcionam uma maneira sistemática de implementar restrições de entradas e saídas. Isto foi possível através da abordagem do problema MPC como um problema de programação quadrática, com solução alcançada através de códigos de programação padrões (QIN e BADGWELL, 2003).

De modo a resolver situações de ordem práticas (tais como tratamento de restrições, problemas de factibilidade, inserção de objetivos múltiplos, entre outras situações), apresentadas decorrentes da sua aplicação no meio industrial, outras variações das metodologias descritas acima para o MPC, podem ser encontradas na literatura, como também diversos produtos podem ser encontrados no mercado para este fim. Produtos estes como SMOC, IDCOM-M, RMPCT, DMC-*plus*, e etc. Exemplo de aplicação destes produtos, podem ser encontrados em Grosdidier *et al.* (1988), Krishnan *et al.* (1998), Bassett e Wijck (1999), Goodhart *et al.* (2000).

#### **2.1.4 TIPOS DE APLICAÇÕES**

A metodologia MPC foi inicialmente desenvolvida para aplicações específicas em sistemas de potência e refinarias de petróleo (QIN e BADGWELL, 2000), mas nas últimas décadas, o controle preditivo baseado em modelo tem sido extensamente empregado no controle avançado de processos complexos diversos (MELO JR, 2003), como processamento de alimentos, indústrias químicas, automotivas, metalúrgicas e aeroespaciais.

Apesar de grande parte dos processos industriais serem de natureza não linear, a maioria das aplicações da metodologia MPC é baseada em modelos de dinâmica linear, sendo os modelos de resposta ao impulso (FIR) e ao degrau (FSR), os mais utilizados (QIN e BADGWELL, 2000).

Pode-se listar algumas razões para isto. Modelos lineares empíricos podem ser identificados de uma maneira direta a partir de dados de testes efetuados no processo. Além disto, até hoje, a maior parte das aplicações deste algoritmo é efetuada em processos de refino, nos quais, o objetivo principal é manter o processo em um estado estacionário desejado, com rápida movimentação de um ponto de operação para outro. Para esta aplicação, um modelo linear cuidadosamente identificado poderá ser suficientemente preciso. Para finalizar, com a utilização de um modelo linear e uma função objetivo quadrática, o algoritmo MPC assume a forma de um problema convexo de programação quadrática (QP), para o qual uma solução realizável é facilmente encontrada por algoritmos específicos. Isto é importante porque o algoritmo precisa convergir ao ponto ótimo em apenas alguns décimos de segundo para possuir aplicação na indústria de manufatura. Devido a estas razões, em muitos casos um modelo linear pode proporcionar a maioria dos benefícios possíveis com a metodologia MPC (QIN e BADGWELL, 2000).



A distribuição de aplicações da metodologia MPC em comparação ao grau de não linearidade dos processos pode ser observada na Figura 2.2 (adaptado de Qin e Badgwell (2000)).

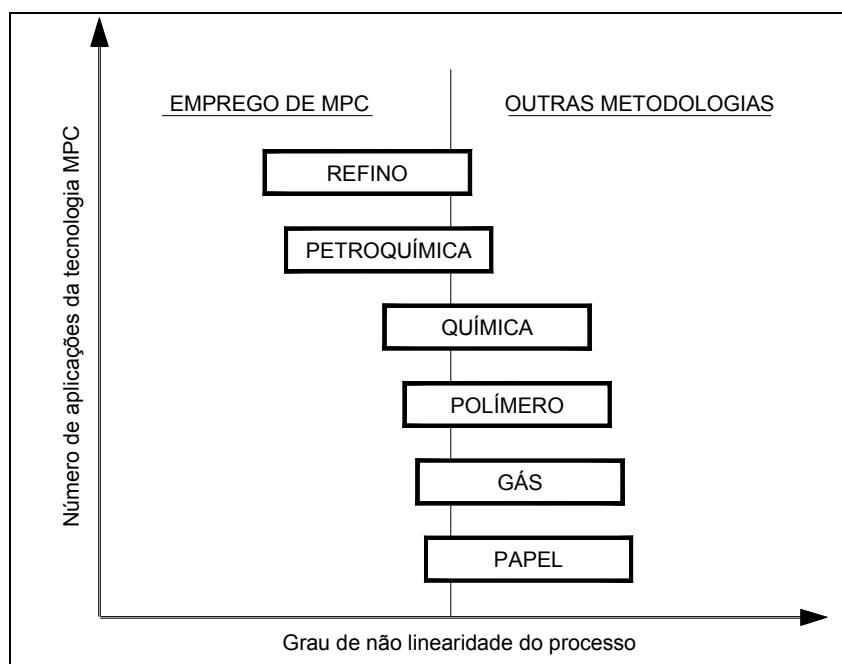


Figura 2.2 - Aplicação da metodologia MPC *versus* grau de não linearidade do processo.

Porém, existem casos nos quais os efeitos não lineares são suficientemente significantes para justificar o uso da metodologia *Nonlinear Model Predictive Control* (NMPC), ou Controle Preditivo Não Linear Baseado em Modelo.

Basicamente, a metodologia NMPC trata plantas através do controle MPC, porém, as não linearidades são consideradas de alguma maneira na representação do processo e na solução do problema (WALLER, 2000).

A modelagem pode ser feita, por exemplo, a partir da utilização de modelos NARMAX ou redes neurais artificiais, entre outras soluções.

Com relação à solução do problema, enquanto a metodologia MPC com modelos lineares requer a solução de problemas convexos em cada tempo de amostragem, usualmente através de programação quadrática (QP) ou programação linear (LP), o NMPC requer a consideração, pelo menos para parte da solução, de um problema não convexo de programação não linear (NLP), que pode ser resolvido, por exemplo, através de *Sequential*

*Quadratic Programming* (SQP), ou Programação Quadrática Seqüencial, que pode não garantir uma solução ótima viável (BIEGLER, 2000) (WALLER, 2000).

Na literatura é possível encontrar aplicações que utilizam diferentes soluções para abordar as não linearidades do processo.

Prett e Gillete (1980) foram um dos primeiros a descrever a aplicação da metodologia DMC em um reator de uma unidade FCC (*Fluidized Catalytic Cracking*), ou Craqueamento Catalítico em Leito Fluidizado, na qual o algoritmo foi modificado para trabalhar com não linearidades e restrições.

Schley *et al.* (2000) apresentaram uma estratégia de controle multivariável não linear, baseada na metodologia QDMC, aplicada ao controle de um reator de polimerização de estireno. O algoritmo apresentado incorpora Filtro de *Kalman* Estendido (EKF) para estimação de parâmetros e variáveis de estado.

Potocnik e Grabec (2002) apresentaram uma abordagem de controle inteligente para a implementação de um NMPC aplicado a um processo de corte instável e não linear. Redes neurais artificiais foram utilizadas para a construção do modelo que foi utilizado para a predição recursiva do MPC, e algoritmos genéticos foram utilizados para a otimização das trajetórias de controle.

Saha *et al.* (2004) desenvolveram um modelo *Weiner-Laguerre* para obtenção da dinâmica estável de malha aberta de um sistema MIMO não linear. O mapa de saída de estado não linear foi construído através de funções polinomiais quadráticas e redes neurais artificiais. Este modelo de identificação foi utilizado para construir um controlador NMPC. A metodologia foi aplicada a um sistema de neutralização de um processo CSTR (*continuous stirred tank reactor*).

Estes são apenas alguns, da grande diversidade de exemplos encontrados na literatura sobre a aplicação de controladores NMPC, porém, conforme citado anteriormente, a maior parte da utilização da metodologia MPC é baseada em modelos de dinâmica linear, devido ao fato desta modelagem ser suficiente para o controle do processo na maior parte dos casos.

Neste contexto, o presente trabalho utiliza controladores QDMC com modelagem linear aplicados a processos não lineares. O controlador QDMC foi eleito devido à possibilidade de tratamento de restrições, e a abordagem linear devido a facilidade e rapidez na busca a partir da utilização de programação quadrática.

Controladores preditivos, lineares ou não lineares, também são empregados paralelamente a estratégias de otimização que visam manter ou direcionar a planta a pontos de melhor desempenho sob diferentes critérios.

Serão apresentados a seguir (seção 2.2) técnicas de otimização aplicadas em controladores preditivos.

## **2.2 INTRODUÇÃO À OTIMIZAÇÃO EM CONTROLE DE PROCESSOS**

O meio industrial é composto por sistemas de controle capazes de proporcionar precisão do comportamento das variáveis existentes em um processo. Porém, este controle pode não ser uma condição suficiente para assegurar que a planta opere inteiramente em níveis satisfatórios (SÁNCHEZ e RODELLAR, 1996).

Freqüentemente, a obtenção de um desempenho desejado em uma planta industrial é associada a uma forma de otimização que envolve a procura por valores de referência apropriados às condições críticas do processo (SÁNCHEZ e RODELLAR, 1996).

Estratégias de otimização utilizam uma formulação do problema, que envolve o modelo do processo com suas restrições e características, e uma função objetivo que representa montantes de lucro, custo, produção, energia, entre outros, em termos das variáveis do processo analisado (EDGAR e HIMMELBLAU, 1989).

O problema de otimização em controle de processo pode possuir diferentes escopos, podendo envolver toda a indústria ou partes deste todo, como uma planta, uma unidade de operação, um equipamento ou sistemas intermediários (EDGAR e HIMMELBLAU, 1989).

A otimização em sistemas industriais pode ocorrer basicamente em três níveis (EDGAR e HIMMELBLAU, 1989):

- Nível gerencial.
- Nível de projeto.
- Nível operacional.

A otimização tratada ao nível gerencial e de projeto opera em um grau de escala de tempo diferente do utilizado no nível operacional. As decisões do nível gerencial são usualmente executadas anteriormente a cada etapa do nível de projeto, que, por sua vez, são executadas previamente à implementação do processo. No nível operacional de um processo,

a otimização pode ser executada em períodos de tempo que variam de vários dias a alguns minutos (EDGAR e HIMMELBLAU, 1989).

Quando trata-se do nível operacional de um processo, a otimização incide sobre a necessidade de se maximizar ou minimizar uma função objetivo através de algoritmos específicos, com o objetivo de se determinar valores para variáveis independentes (*setpoints*), com a utilização de modelos matemáticos que representem o sistema a ser otimizado (ZANIN, 2001).

A determinação destas referências pode ser realizada basicamente por duas formas. Na primeira delas, os valores ótimos do sistema são obtidos através de um computador externo ao processo, portanto esta estratégia é denominada de otimização *off-line*. Na segunda maneira, a obtenção dos *setpoints* é feita periodicamente e implementada de forma automática, podendo assim ser chamada de otimização *on-line* ou otimização em tempo real (RTO - *Real-Time Optimization*).

O presente trabalho trata da otimização inserida no nível operacional de uma indústria.

### **2.2.1 OTIMIZAÇÃO EM TEMPO REAL**

A otimização de um processo consiste na determinação de suas variáveis independentes através de um modelo e de um algoritmo de programação matemática com a finalidade de maximizar ou minimizar uma função objetivo sem violar as restrições deste sistema (ZANIN, 2001).

A otimização em tempo real (RTO) realiza um monitoramento constante na planta, de forma a mantê-la em funcionamento no ótimo ponto econômico, realizando ajuste caso necessário, a fim de obter a máxima lucratividade.

Nos últimos anos, muitos fatores vêm contribuindo para a otimização em tempo real dos processos de grande porte. Entre eles pode-se citar o desenvolvimento de computadores mais velozes, o avanço no desenvolvimento de algoritmos de programação matemática e o surgimento de modelo de processos rigorosos (ZANIN, 2001).

A otimização para controle em tempo real pode ser dividida de maneira simplificada em duas estruturas de metodologia: método da busca de direção e método baseado em modelo.

O método da busca de direção utiliza experimentação da planta *on-line* para medir a direção dos índices de desempenho. Estas informações do processo são usadas para gerar uma superfície de desempenho, que é usada para determinar a direção do próximo passo da RTO (HALIM, 2003). Os atrativos do uso das técnicas de busca de direção são devidos ao fato de que são métodos simples e bem compreendidos, e podem ser eficazes quando se tem pequeno conhecimento sobre o processo a ser otimizado. Porém, em processos com muitos graus de liberdade, a utilização desta técnica pode ser dificultosa (FRALEIGH, 1999).

O método baseado em modelo faz uso de um modelo matemático de estado estacionário ou de um modelo dinâmico para representar o processo. Um diagrama simplificado desta técnica é apresentado na Figura 2.3.

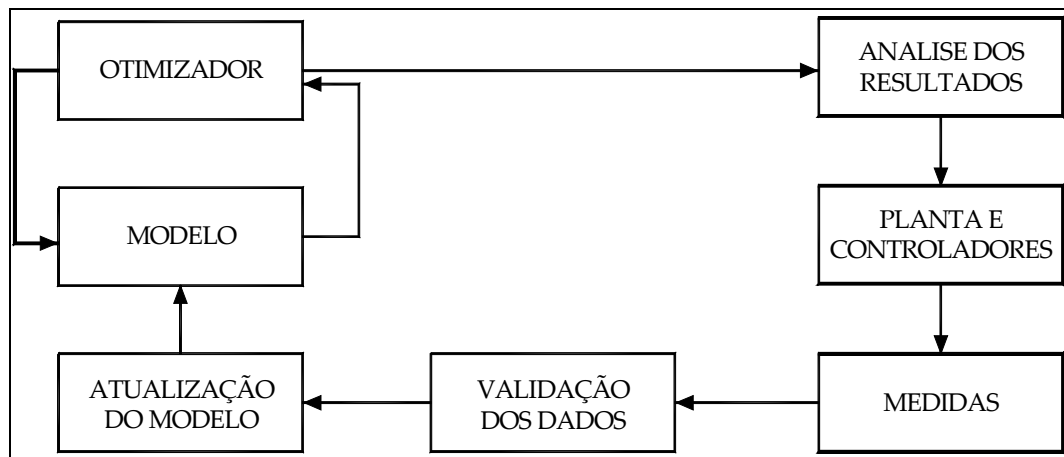


Figura 2.3- Diagrama de Blocos da otimização baseada em modelo.

Os blocos da Figura 2.3 podem ser descritos da seguinte maneira (HALIM, 2003):

- Medidas: São levantadas medições referentes ao processo através de sensores posicionados na planta. Estas medições são utilizadas para atualizar os parâmetros do modelo do processo.
- Validação dos dados: Em processos reais nos quais estão presentes ruídos e erros de medição, existe a necessidade de filtragem dos dados coletados.
- Atualização do modelo: Um modelo de processo fixo é incapaz de uma predição satisfatória de desempenho, além das condições operacionais projetadas. Um modelo necessita ser atualizado para representar o comportamento do processo real, pois, normalmente os processos são

variantes no tempo e não lineares por natureza. Por exemplo, em um reator catalítico, as propriedades do catalisador mudam com o tempo, pois variam com a temperatura, taxa de alimentação, e outras condições operacionais.

- **Modelo:** O modelo consiste em um conjunto de equações que relacionam as entradas com as saídas do processo. Também são relacionadas as equações de restrição, os valores limites de máximo e de mínimo das variáveis de entrada e saída. Estas restrições são uma parte do modelo, e devem ser satisfeitas para adquirir representação satisfatória do desempenho de processo. O modelo é usado para estimar as saídas para diferentes condições operacionais do processo.
- **Otimizador:** O otimizador executa uma otimização baseada em modelo de estado estacionário, para determinar o ponto que proverá o maior lucro dentro dos limites especificados pelas restrições.
- **Análise dos Resultados:** Nesta etapa, é verificado se os *setpoints* propostos pelo otimizador podem ser implementados sem violar as restrições físicas do processo.
- **Planta e controle:** O controle implementa os resultados calculados pelo otimizador, encaminhando a planta para o ponto de maiores benefícios econômicos.

O método baseado em modelo é o mais popular na indústria, pois requer poucos experimentos. O método de busca de direção, devido ao custo e ao tempo gastos na experimentação da planta, é pouco atrativo para processos multivariáveis (HALIM, 2003).

O presente trabalho apresenta um estudo de controle e critérios de otimização, portanto, devido a utilização de processos simulados, as etapas descritas acima não são abordadas neste estudo.

Segundo Beautyman (2004) alguns fatores deverão ser considerados no momento de avaliar a necessidade ou não de se implementar uma otimização em tempo real:

- **Grau de liberdade:** Variáveis de decisão, aparentemente disponíveis para uso pela RTO, já podem ter sido, ou podem ser, otimizadas simplesmente com a utilização de programação linear (PL) de planejamento, ou por sistema de

controle avançado do processo (APC). Neste caso, os valores obtidos pela RTO seriam redundantes. Porém, se uma função objetivo ou restrições são não lineares, a RTO poderá encontrar valores diferentes para as variáveis de decisão.

- Complexidade: Muitas vezes o ponto ótimo de um processo pode ser simplesmente determinado pela experiência dos operadores, através de cálculos simples ou regras empíricas dos engenheiros de processo, ou por modelos matemáticos simplificados. Para se avaliar a necessidade de implementação de uma RTO, aspectos como interação e intercâmbio entre variáveis, tamanho do problema de otimização, número de variáveis operacionais envolvidas e a não linearidade das respostas, são importantes na escolha do modelo de otimização.
- Alterações: A otimização em tempo real somente é justificada se houver mudanças econômicas e operacionais frequentes no sistema. Mudanças como qualidade e vazão das alimentações do sistema, especificações de produtos, desempenho de equipamentos, valores econômicos e condições ambientais.
- Aspectos econômicos: Deverá ser avaliado aspecto de custos para implementação de uma RTO. Deverão ser feitas análises econômicas futuras para tendências de mercado, para se verificar o tempo de retorno do investimento. Também deverão ser analisados aspectos como objetivo e rigor do modelo a ser implementado. Apesar de um modelo reduzido poder trazer perda de benefícios, também reduz custo e pode apresentar um tempo de retorno mais rápido. Também deverão ser verificadas quais unidades do sistema serão modeladas de forma mais rigorosa.

Por mais de quarenta anos a indústria e os meios acadêmicos vêm reconhecendo os benefícios potenciais da otimização em tempo real, porém, em muitas aplicações este método vem demonstrando um rendimento limitado (HALIM, 2003). A aplicação próspera de um sistema de RTO depende de uma compreensão completa do processo e da própria aplicação deste conhecimento em cada um dos componentes do sistema. (KORCHINSKI *et al.*, 1998). Algumas das razões para o possível fracasso de RTO são apresentadas abaixo (WHITE, 1998):

- Nenhuma atualização de parâmetros *on-line*: Muitas vezes uma otimização é baseada em projetos de equipamentos e dados experimentais da planta para uma estimação dos parâmetros iniciais do sistema, porém, com o passar do tempo, a resposta do sistema pode se modificar e, desta maneira, os parâmetros iniciais não mais representam o comportamento da planta. Assim, sem uma atualização constante não é possível prever precisamente as repostas do sistema.
- Implementação em uma infra-estrutura incerta: Sistemas de otimização são como uma cadeia de equipamentos e *softwares* na qual a ineficiência de qualquer uma das partes pode causar fracasso ao sistema global. O sistema precisa extrair dados da rede de medição do processo, precisa executar seus cálculos, e precisa devolver as respostas ao processo. Os usuários, operadores da planta e o pessoal da manutenção do sistema, deverão ser capazes de determinar o que o sistema está executando e, se necessário, fazer alterações. Determinados problemas podem incapacitar o sistema de otimização, como por exemplo, problemas de rede, problemas de interface do usuário, sistema de computador ou problemas de banco de dados, entre outros. No aspecto de infra-estrutura, pode-se também citar problemas com a falta de investimentos na manutenção da planta, principalmente em sensores, sendo estes de fundamental importância na precisão de valores, nos quais problemas poderiam comprometer todo o sistema, pois são nas informações colhidas das plantas que estão baseadas as atualizações de parâmetros, estimativas do processo, reconciliação de dados etc.
- Falta de informações da alimentação da unidade: Ao desenvolver um projeto de um processo industrial, os responsáveis tentam minimizar o número de instrumentos de medidas por economia financeira. Isto reduz o investimento de capital no processo as custas da controlabilidade ou da observabilidade do processo. Desta forma, se torna difícil a análise de dados e a minimização de perturbações.
- Discordâncias organizacionais nos preços usados: Em um ambiente industrial, como uma refinaria, o preço da matéria prima (óleo cru) e os produtos (por exemplo, gasolina, diesel) nunca são precisamente conhecidos.



As unidades do processo compartilham os mesmos insumos e o consumo destes por cada uma delas é raramente medido. Portanto, a determinação da quantia exata de valor somada por cada unidade é uma tarefa difícil.

- Perturbações freqüentes: Variáveis medidas que apresentam muita perturbação ou ruído podem gerar problemas na hora da otimização. Em modelos de otimização baseados em estado estacionário, a determinação dos *setpoints* da planta, nos casos em que o sistema apresenta perturbações excessivas, é difícil.

Conforme citado anteriormente, White (1998) declara que o segredo do sucesso de otimização em tempo real depende de um correto ajuste dos parâmetros do modelo do processo. Segundo Moro (2003), para o bom desempenho da otimização em tempo real é necessária uma melhoria nos modelos de otimização, procedimentos mais confiáveis para caracterização de alimentação e algoritmos melhores para estimação de parâmetros.

Os aspectos acima mencionados referem-se a implantação da otimização em tempo real no meio industrial. Considerando que o presente trabalho está limitado a um estudo baseado em simulação, as recomendações acima têm apenas caráter informativo.

A otimização de processos consiste, portanto, em se determinar os ajustes das referências das variáveis manipuladas de maneira a se trabalhar com a planta do processo no seu ponto ótimo de rendimento, como também propiciar ajustes no processo sempre que houver mudanças nos objetivos econômicos. A permanência da planta em determinado estado estacionário ou no deslocamento para outro estado, conforme planejamento, sem violação de restrições, é possível através da utilização de controladores avançados, como a classe de controladores preditivos abordados anteriormente. Serão apresentados a seguir, com exemplos de aplicações encontradas na literatura, duas formas de implementação de otimização, em uma e duas camadas, que se utilizam desta classe de controladores para o controle da planta.

### **2.2.1.1 Otimização em Duas Camadas**

Uma das mais populares formas de implementação de otimização é a chamada otimização em duas camadas, que é uma forma de controle hierárquico, no qual uma camada inferior é composta por um sistema de controle avançado, normalmente um controlador

preditivo multivariável (MPC), e os *setpoints* para este controlador são calculados através de um nível superior de otimização (GOUVÊA E ODLOAK, 1998a).

Moro e Odloak (1995) simulam, em uma planta de FCC, um método que introduz uma otimização com programação linear (LP), incluindo todas as restrições do processo, dentro de um controlador preditivo do tipo DMC. A otimização calcula os *setpoints* das variáveis controladas e de algumas manipuladas, disponibilizando-as para uso do controlador preditivo. A otimização e o controlador utilizam funções de custos diferenciadas, mas que são executadas consecutivamente a cada amostra de tempo. O artigo descreve as formulações para o referido método, como também apresenta as principais características. Os resultados apresentados na simulação foram satisfatórios e a metodologia aplicada na refinaria Duque de Caxias de propriedade da Petrobrás. Rabello *et al.* (2005) apresentam uma revisão deste projeto implementada devido a modificações operacionais ocorridas na unidade desde a implantação do controle avançado. Este artigo descreve as etapas de inferência, identificação do processo, comissionamento e resultados preliminares.

Pedersen *et al.* (1995) descrevem a implementação de uma otimização em três camadas. A camada superior é composta por uma otimização não linear do processo com o uso de um modelo estático rigoroso; na camada intermediária é realizada uma otimização linear; e na última camada, encontra-se o algoritmo preditivo multivariável. As duas últimas camadas são executadas em uma mesma frequência. Este modelo é implementado em uma planta de hidrocraqueamento. O tempo computacional gasto na primeira camada é de aproximadamente 40 minutos. Trinta e dois *setpoints* são calculados e enviados em uma média de 7 vezes ao dia para dez controladores multivariáveis e cinco PID's. Neste artigo, os autores relatam as dificuldades encontradas na modelagem do processo, na atualização dos parâmetros dos modelos, na formulação do problema econômico e no comissionamento. Os benefícios econômicos diários foram na ordem de US\$ 5000 a US\$ 12000.

Uma otimização em três camadas em unidades integradas de craqueamento e polimerização catalítica é apresentada por McCormick *et al.* (1996). Nesta metodologia, existe um único otimizador que controla oito controladores preditivos multivariáveis instalados nas unidades. O otimizador faz uso de um modelo rigoroso de um processo de craqueamento e polimerização catalítica com aproximadamente 29.000 variáveis e 27.000 equações, e existem 61 variáveis manipuladas que são atualizadas de 15 a 30 vezes por dia pelos controladores. Os

ganhos econômicos obtidos com a otimização em três camadas representam aproximadamente 3% da lucratividade do sistema.

Outra otimização de uma unidade de craqueamento é apresentada por Lid e Stand (1997). O problema de otimização possui aproximadamente 20 variáveis independentes e 40 equações do modelo do processo. Na camada regulatória, é utilizado um MPC. No artigo são descritas as etapas para a modelagem do problema de otimização, como também as etapas de implementação. Os resultados se mostraram bastante satisfatórios, com um tempo de retorno de investimento de aproximadamente 2 meses.

O uso de um método não tradicional de otimização para um complexo de isomerização de naftas na Alemanha é apresentado por Besl *et al.* (1998). O ciclo tradicional de uma otimização *on-line* consiste na detecção do estado estacionário, reconciliação dos dados e ajuste dos parâmetros do modelo do processo, otimização e a implementação dos resultados no nível de controle. Então, em um sistema tradicional, a confiabilidade do modelo do processo, como também a qualidade da otimização, estão relacionados com o a conciliação dos dados e ajustes dos parâmetros, que, por sua vez, estão relacionados com a detecção do estado estacionário. Mas, em processos com um nível elevado de perturbações, o sistema raramente se encontra em estado estacionário, e, conseqüentemente a otimização é feita com uma baixa freqüência. No método não tradicional, proposto neste artigo, não existe a espera da detecção do estado estacionário para execução da otimização. Uma vez o sistema ajustado, novos valores ótimos somente serão calculados caso haja alterações das perturbações do processo ou da qualidade da carga. Como a deterioração do modelo do processo ocorre de uma forma mais lenta, a atualização poderá ser executada em uma freqüência menor que a otimização, ou o modelo do processo poderá ser ajustado de uma forma *off-line*. Nesta aplicação, a otimização da unidade foi executada até seis vezes por hora, sendo que a conciliação de dados e ajustes dos parâmetros, neste mesmo período, foi executada na freqüência duas a três vezes menor. Como benefício, a otimização não tradicional teve um acréscimo de 25% em comparação a otimização tradicional.

Em Sorensem e Cutler (1998) são apresentadas as principais vantagens da inclusão de uma programação linear (LP) dentro de um controlador preditivo, tais como: estabilidade, alto grau de robustez, flexibilidade (permite ao usuário de especificar quais variáveis controladas serão operadas com *setpoints* ou por faixa), possibilidade de utilização de dados

de especialistas, etc. Também são apresentados métodos para se determinar a função custo requerido pelo LP.

Uma aplicação do método de otimização em duas camadas é apresentado por Oliveira e Carrapiço (1998). Neste artigo são realizados a otimização e o controle de uma unidade de coqueamento retardado na refinaria RPBC da Petrobrás. A otimização resolve um problema de programação linear (PL) trabalhado na mesma frequência do controlador preditivo que utiliza um DMC. O sistema possui 16 variáveis manipuladas, 47 variáveis controladas e 5 distúrbios. A aplicação desta metodologia permitiu um aumento de 4,1% de rendimento na unidade de coqueamento. Como estes tipos de unidades são considerados o gargalo de uma refinaria, a utilização da otimização e controle em duas camadas possibilitou o aumento na capacidade total da refinaria.

Uma comparação entre o método de duas camadas e o método de três camadas é encontrado em Ying e Joseph (1999). As duas técnicas são aplicadas a um problema de controle proposto pela Shell. No artigo, é exposto que não existe a necessidade de utilização da otimização em três camadas quando a frequência de otimização não linear é a mesma frequência de execução do MPC. Mas, caso isto não seja verificado, devido à complexidade do modelo do processo, o método de três camadas é superior a otimização em duas camadas, para este processo, nos seguintes aspectos (YING e JOSEPH, 1999):

- Melhor desempenho dinâmico. Devido a necessidade de suprimir grandes variações nas variáveis manipuladas, a otimização em duas camadas é relativamente lenta para rejeitar perturbações, e a otimização em três camadas detecta as perturbações em um nível intermediário e ajusta o controlador preditivo.
- Melhor desempenho econômico de estado estacionário. Devido a perturbações não medidas, o ponto ótimo encontrado pelo otimizador não linear pode ser deslocado, como este é executado em uma frequência menor, o processo pode trabalhar em pontos sub-ótimos. Com introdução da camada intermediária, executada com uma frequência igual ao do controlador preditivo, o sistema é mantido no ponto ótimo.
- Eliminação de *off-set*. Devido a perturbações na planta, pode ocorrer perda de graus de liberdade do sistema, o que pode ocasionar o surgimento de *off-sets*. No caso da otimização em três camadas, isto não ocorre, pois, o nível

intermediário detecta a perturbação e determina um novo ponto ótimo de modo a eliminar os *off-sets* nas variáveis controladas.

Ramos *et al.* (2002) descreve a aplicação de um método de duas camadas em uma planta industrial química piloto, na qual são controlados o nível, a temperatura e a vazão. Neste trabalho, são simuladas e comparadas duas situações. Na primeira delas, é considerado um sistema com otimização linear em uma camada superior, uma camada com controle preditivo do tipo DMC em uma hierarquia intermediária, e por último, um nível regulatório constituído de um PI (Proporcional e Integral), chamado assim de LP-DMC-PI. Na outra situação, é considerado um sistema sem o nível regulatório, o qual é chamado de LP-DMC. Na comparação das duas estratégias, ambas apresentaram desempenho satisfatório, maximizaram a qualidade e quantidade do produto objetivo. O regulador LP-DMC-PI apresentou melhor comportamento em sistemas instáveis e também uma melhor flexibilidade na mudança de *setpoints*.

Tosukhowong *et al.* (2004) propuseram a utilização de um método de otimização em tempo real, chamado de modelo *slow-scale*, para promover a otimização completa de uma planta (*plant-wide optimization*). Este método de otimização é executado em uma taxa um pouco mais lenta que a taxa do MPC de nível local, para trilhar dinamicamente mudanças nas condições de operação ótima. A principal vantagem desta metodologia é devido ao fato que o RTO não necessita aguardar o estado estacionário da planta. Neste trabalho, também se procura solucionar os problemas relacionados às condições operacionais ótimas entre as unidades. Esta metodologia foi aplicada em um sistema com duas unidades conectadas via pontes dinâmicas, e também em um outro sistema, no qual existe um reator, um tanque de esguicho e um tanque de armazenamento, conectados via corrente de retorno. Esta metodologia foi comparada ao método de otimização em tempo real de estado estacionário. O método de *slow-scale* se mostrou mais eficiente. No artigo são demonstradas as formas de conseguir um modelo de planta para a execução da *slow-scale* até uma frequência de otimização desejada, e também como realizar as permutações de informações entre o otimizador global da planta (executada a uma taxa lenta) com os controladores multivariáveis executados em uma taxa alta em cada unidade.

Estes foram alguns exemplos encontrados na literatura, que apresentam técnicas de otimização hierárquica aplicadas a processos industriais.

### 2.2.1.2 Otimização em Uma Camada

Uma outra maneira de se realizar a otimização e controle de um sistema, consiste na realização destas duas operações simultaneamente em um mesmo nível. Desta forma, tanto os objetivos de controle quanto a função objetivo custo são resolvidos ao mesmo tempo.

Yousfi e Tournier (1991) introduziram a otimização dentro de um controlador preditivo multivariável. A otimização foi realizada com a inclusão de um termo quadrático relativo ao objetivo econômico junto à função objetivo do MPC. Neste trabalho, tanto o modelo do sistema quanto a função econômica custo eram lineares, não correspondendo assim à realidade da maioria dos problemas econômicos, já que estes, quase sempre, possuem características não lineares.

Uma aplicação de uma metodologia em uma camada é encontrada em Almeida *et al.* (1996). Neste trabalho, é descrita a aplicação da otimização e controle em uma unidade de destilação a vácuo da refinaria Alberto Pasqualini da Petrobrás. Para tanto, foi definida uma variável que representa a função objetivo do sistema (valores dos produtos, custos da matéria prima e custos com energia), sendo que esta variável, sempre que houver graus de liberdade, será levada para valores mais elevados. A função objetivo foi maximizada forçando o limite mínimo da variável econômica para um valor um pouco superior ao seu valor atual. A otimização em estado estacionário e o sistema de controle foram resolvidos simultaneamente através da solução de um problema de programação linear (PL) com todas as restrições do sistema. Neste trabalho, foi utilizado o LDMC (Linear Dynamic Matrix Control) proposto por Morshedi *et al.*, 1985. Os resultados econômicos encontrados foram bastante satisfatórios.

Odloak e Gouvêa (1996) propuseram a otimização em uma única camada utilizando um controlador preditivo do tipo DMC. O ponto ótimo de operação é buscado através da combinação entre um modelo dinâmico linear e um modelo em estado estacionário. Foi realizada uma linearização da função econômica custo, mas, devido a isto, caso o sistema seja altamente não linear, é possível a ocorrência de uma instabilidade da planta em malha fechada.

Em Gouvêa e Odloak (1998a) foi proposta a aplicação do método em camada única em uma planta de craqueamento catalítico com o objetivo de maximizar a produção de GLP (*Liquified Petroleum Gas*). O problema de otimização não linear da planta é resolvido diretamente dentro do controlador preditivo do tipo DMC. Segundo os autores, a sintonia deste controlador se torna uma tarefa complexa devido a não linearidade introduzida pela

função objetivo, a sintonia, neste caso, somente foi possível após exaustivas simulações. Uma outra característica, devido a não linearidade da função objetivo, é a necessidade de opção de um algoritmo de resolução robusto e eficiente. Neste trabalho, foi utilizado um algoritmo adaptado baseado no SQP (*Sequential Quadratic Programming*), maiores detalhes desta implementação poderão ser verificados em Gouvêa e Odloak (1998b). Os resultados desta aplicação foram comparados com um segundo método no qual a otimização e o controle são executados em etapas diferentes, ou seja em duas camadas, sendo que o método em camada única dirigiu a planta para um melhor ponto de operação. Nas mudanças do objetivo econômico, o método em camada única leva a planta de maneira rápida e mais suave ao novo ponto de operação, mas, caso o sistema seja altamente perturbado, ajustes para aumentar a robustez do sistema poderão torná-lo mais lento. Uma outra desvantagem da otimização intrínseca no problema de controle é que este é mais sensível a erros de modelo.

Uma formulação alternativa para a otimização em única camada foi desenvolvida por Schiavon Jr (1998) e publicada em Schiavon Jr e Corrêa (2000). Neste método, as ações de controle futuras e as saídas previstas são calculadas a cada período de amostragem através do inverso do ganho do processo, utilizando-se um controlador do tipo QDMC. Devido a esta metodologia, a resposta do problema econômico é sempre convexa, desta forma, um algoritmo de solução para o problema econômico pode ser simples. Esta metodologia foi aplicada em dois modelos lineares, sendo um SISO (*Single-input / Single-output*) e outro MIMO (*Multiple-input / Multiple-output*), além de uma coluna de destilação binária que se trata de um modelo não linear. Foram utilizados modelos econômicos lineares e não lineares para todos os sistemas. Os resultados foram comparados com o método de otimização e regulação em duas camadas. A otimização em uma camada apresentou resultados satisfatórios para todos os modelos e fácil ajuste dos parâmetros do controlador. O sistema em duas camadas apresentou resultados equivalentes para modelos econômicos lineares comparados ao controlador em um único nível, mas para o caso da sua utilização em modelos não lineares, em ambos os casos, tanto para SISO quanto para MIMO, os resultados foram inferiores à estrutura em duas camadas.

Em Zanin (2001) é apresentada uma implementação industrial da otimização em uma única camada, que foi aplicada para maximização da produção de GLP em uma unidade de craqueamento catalítico na refinaria Henrique Lages da Petrobrás. A otimização é executada através de um controlador preditivo do tipo QDMC, no qual todas as variáveis controladas e

manipuladas são restringidas. A função econômica objetivo utiliza componentes dinâmicos e estáticos. O problema econômico não linear é resolvido com a utilização de um algoritmo SQP. Foram realizadas simulações utilizando otimização e controle em uma camada, como também em duas camadas. Na simulação dos processos, foi utilizado um modelo estático não linear rigoroso do sistema e um outro modelo estático linear simplificado, com o objetivo de se verificar a importância do modelo da planta na otimização. Após as simulações iniciais, foi realizada uma revisão no algoritmo de otimização e controle em uma camada, para a correção de oscilações nas ações de controle e correção de *off-sets*. Como resultado, pode se verificar que ambos os modelos, tanto o rigoroso quanto o simplificado, captam a tendência correta da estratégia de otimização, sendo que o modelo rigoroso apresentou um desempenho significativamente superior. Quanto ao método de otimização, apesar de ambos se apresentarem eficientes, a otimização em uma camada mostrou-se superior por manter uma operação mais suave. Neste trabalho, também são contempladas as etapas para ajuste, comissionamento e implementação do controlador otimizado dentro do *software* existente utilizado na refinaria. Como resultados práticos da implantação da estratégia de otimização intrínseca dentro do controlador, foram constatados um aumento significativo na produção de GLP e também um aumento na estabilidade da planta, quando comparado à estratégia em duas camadas utilizada anteriormente pela refinaria.

Uma implementação de controle e otimização em uma única camada é apresentado em Costa (2003), no qual é apresentada a otimização em um secador tipo leito de jorro. Este trabalho é baseado na dissertação apresentada por Schiavon Jr (1998). No trabalho de Costa (2003), foram realizadas simulações com controle e otimização em uma camada, como também simulação e implementação experimental em duas camadas. Foram utilizadas funções econômicas tanto lineares quanto não lineares. Também foram apresentados os passos para os ajustes do controlador QDMC e demais parâmetros dos sistemas. Como resultado, o controlador em uma camada apresentou um melhor desempenho que o controlador em duas camadas, pois os *setpoints* foram modificados de maneira mais suave, o que permitiu a eliminação do erro entre as saídas do processo e seus valores desejados em um intervalo de tempo menor.



### 2.3 CONCLUSÃO

Na literatura é possível encontrar grande diversidade de aplicações de controladores preditivos, conforme demonstrado neste capítulo. As variações são percebidas principalmente no tipo de controle utilizado (DMC, QDMC, RMPC, etc), no emprego ou não de estruturas linearizadas, como também de características não lineares quando consideradas.

Os exemplos de aplicações citados neste capítulo são apenas alguns do grande variabilidade de publicações observada atualmente, e tiveram como objetivo demonstrar que o controle preditivo não possui um formato usual ou tradicional de utilização, mas apresenta flexibilidade para ser estruturado de acordo com as características do processo, como também dos objetivos de otimização que possam estar presentes.

Um dos objetivos do presente trabalho é a aplicação e avaliação da metodologia de controladores preditivos baseados em modelo em processos multivariáveis. Para este objetivo, utiliza-se o algoritmo QDMC, pois, este algoritmo proporciona uma maneira direta de implementar restrições de entradas e saídas.

Outros objetivos deste trabalho são a introdução de critérios de otimização nos processos simulados, e a comparação do desempenho entre a otimização em duas camadas e em camada única.

A utilização de técnicas de otimização para processos petroquímicos, como o FCC utilizado nas simulações, se justifica devido à presença de grande número de variáveis envolvidas acopladas, e dinâmica não linear. Além disso, é freqüente observar neste tipo de processo, alterações na qualidade, vazão e temperatura das alimentações e especificações de produtos dependentes das condições de mercado.

O presente trabalho apresenta, portanto, uma otimização inserida no nível operacional feita em tempo real através do método baseado em modelo. A revisão bibliográfica sobre otimização em tempo real, inserida neste capítulo, apresentou alguns exemplos de emprego de otimização em uma, duas e três camadas associadas ao uso de controladores preditivos.

No presente trabalho, se aplicará a formulação alternativa para a otimização em única camada proposta por Schiavon Jr (1998). Em seu trabalho, Schiavon apresentou sua proposta em três processos, o primeiro de dimensão 1x1 linear, o segundo de dimensão 2x2 linear e o terceiro, de dimensão 2x2 não linear. Posteriormente, Costa (2003) contribuiu com a aplicação da formulação alternativa de Schiavon Jr (1998) em uma aplicação prática de um

secador tipo leito de jorro, porém, este processo também apresenta apenas duas variáveis manipuladas e duas controladas.

Neste trabalho, propõe-se a utilização da formulação alternativa de Schiavon Jr (1998) em um modelo de FCC, que é um processo com um maior número de variáveis, grandes interações e características não lineares. Desta forma, é possível avaliar o desempenho da formulação alternativa de Schiavon Jr (1998) em processos mais complexos.

O presente trabalho é, portanto, um complemento aos estudos de controle preditivo associado a otimização em tempo real, em uma e duas camadas, já existentes na literatura.

Uma outra característica deste trabalho é dar uma continuidade aos trabalhos desenvolvidos nesta instituição de ensino, de Prosdócimo (2003), Melo Jr (2003), Gentilin (2004), os quais implementaram um controlador DMC, GPC e IMC respectivamente. Nestes trabalhos foram implementados com sucesso sistemas de controle preditivo, mas estes não contemplavam critérios de otimização. Então este presente trabalho, também tem como objetivo, dar um complemento inicial a estes trabalhos, com o estudo de inserção de critérios de otimização juntamente com controle preditivo baseado em modelo.

#### 3.1 CONTROLE PREDITIVO

O conceito e as características do controlador preditivo baseado em modelo foram devidamente expostos no Capítulo 2. A seguir serão apresentadas as formulações do DMC e do QDMC, como também das abordagens de otimização, utilizadas nas simulações deste trabalho.

Como mencionado nos capítulos anteriores, este trabalho foi baseado na utilização de um controlador preditivo do tipo QDMC, que se difere de um DMC principalmente pelo fato de ser possível a inclusão de restrições tanto nas entradas quanto nas saídas dos processos. Uma outra distinção é dada pela maneira pela qual são encontradas as soluções ótimas, sendo o DMC resolvido por métodos dos mínimos quadrados e o QDMC por programação quadrática (QP).

A formulação apresentada nesta dissertação descreve um controlador preditivo do tipo DMC (CUTLER e RAMAKER, 1979) e as modificações necessárias para a obtenção de um QDMC (GARCIA e MORSHEDI, 1986) .

##### 3.1.1 MODELO DE RESPOSTA AO DEGRAU

Para a obtenção de um controlador preditivo baseado em modelo, é necessária a utilização de um modelo do processo com o qual seja possível prever os valores da saída do sistema, através das mudanças nos valores de entrada. No caso da metodologia DMC e QDMC, é utilizado um modelo de convolução.

A formulação do DMC e do QDMC, adota como modelo de convolução o modelo de resposta ao degrau (FSR).

A Figura 3.1 mostra a resposta de um processo quando submetido a uma variação degrau ( $\Delta u_1$ ) em sua entrada, no tempo  $t=0$ . Os valores  $a_1, a_2, a_3... a_n$  são as amplitudes da resposta obtida a cada período de amostragem  $T$ . O valor  $N_p$  é o tempo necessário para que a

resposta em malha aberta do sistema atinja aproximadamente 99% da resposta final, também conhecido, como horizonte de modelo.




Figura 3.1 – Resposta ao degrau

O valor de  $y$ , para uma variação  $\Delta u$  unitária, pode ser calculado como:

$$\begin{aligned}
 y(t+1) &= a_1 \Delta u_1 \\
 y(t+2) &= a_2 \Delta u_1 \\
 y(t+3) &= a_3 \Delta u_1 \\
 &\dots \\
 y(t+N_p) &= a_{N_p} \Delta u_1
 \end{aligned}
 \tag{3.1}$$

Estendendo para uma seqüência de alterações unitárias nos valores de entrada ( $\Delta u_1$ ,  $\Delta u_2$  e  $\Delta u_3$ ) conforme a Figura 3.2, aplicadas nos instantes  $t-1$ ,  $t$  e  $t+1$ .

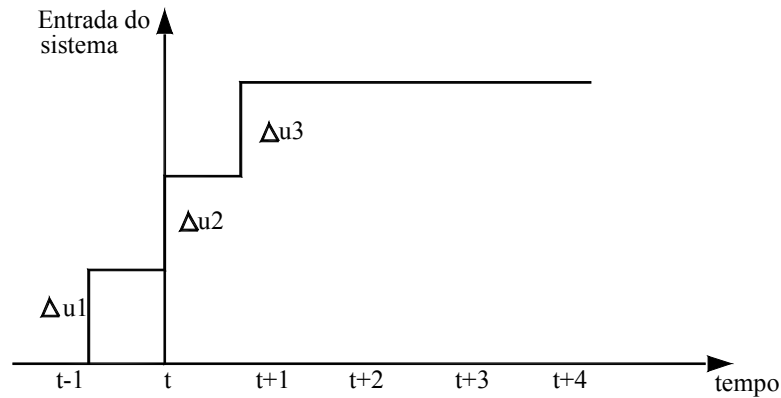


Figura 3.2 – Sequência de variações no valor de entrada

As respostas individuais da saída  $y$  do processo para cada variação de  $u$  são mostradas na Figura 3.3.




Figura 3.3 – Sequência de variações no valor de entrada

A resposta total do valor de  $y$  para cada instante de amostragem é dada pela sobreposição das respostas individuais, sendo assim:

$$\begin{aligned}
 y(t) &= a_1 \Delta u(t-1) \\
 y(t+1) &= a_2 \Delta u(t-1) + a_1 \Delta u(t) \\
 y(t+2) &= a_3 \Delta u(t-1) + a_2 \Delta u(t) + a_1 \Delta u(t+1)
 \end{aligned}
 \tag{3.2}$$

generalizando a Equação (3.2), a resposta do modelo ao degrau para uma seqüência de alterações no valor de entrada e assim determinada :

$$y(t) = \sum_{i=1}^{N_p} a_i \Delta u(t-i) \quad (3.3)$$

onde:  $N_p$  é o horizonte de modelo, conforme definido anteriormente.

Descrições detalhadas a respeito dos modelos de convolução discretos podem ser encontradas em Ogata (1998) e Flaus (1994).

### 3.1.2 CONTROLADOR PREDITIVO MPC PARA SISTEMAS MONOVARIÁVEIS

Partindo do modelo de convolução de resposta ao degrau dado pela Equação (3.3), a saída predita ( $y_p$ ) para um instante qualquer é assim determinada:

$$y_p(t+k) = \sum_{i=1}^{N_p} a_i \Delta u(t+k-i) \quad (3.4)$$

Separando as entradas passadas conhecidas das entradas a serem previstas, a equação anterior pode ser arranjada para:

$$y_p(t+k) = \sum_{i=1}^k a_i \Delta u(t+k-i) + \sum_{i=k+1}^{N_p} a_i \Delta u(t+k-i) \quad (3.5)$$

Considerando que o sistema seja perturbado por um sinal  $d(t)$ , assumido no instante  $(t)$  constante ao longo do horizonte ( $d(t+k) = d(t)$ ). Desta forma, a perturbação será igual à saída real ( $y_m(t)$ ) no instante  $t$  menos o valor da saída predita  $y_p$  no mesmo instante.

$$d(t) = y_m - y_p(t) \quad (3.6)$$

Considerando a influência da perturbação, a Equação (3.5) é modificada da seguinte forma:

$$y_p(t+k) = \sum_{i=1}^k a_i \Delta u(t+k-i) + \sum_{i=k+1}^{Np} a_i \Delta u(t+k-i) + d(t) \quad (3.7)$$

substituído  $d(t)$  pela Equação (3.6)

$$y_p(t+k) = \sum_{i=1}^k a_i \Delta u(t+k-i) + \sum_{i=k+1}^{Np} a_i \Delta u(t+k-i) + (y_m(t) - y_p(t)) \quad (3.8)$$

sendo:

$$y_p(t) = \sum_{i=1}^{Np} a_i \Delta u(t-i) \quad (3.9)$$

ficando:

$$y_p(t+k) = \sum_{i=1}^k a_i \Delta u(t+k-i) + \sum_{i=k+1}^{Np} a_i \Delta u(t+k-i) + (y_m(t) - \sum_{i=1}^{Np} a_i \Delta u(t-i)) \quad (3.10)$$

agrupando-se os termos:

$$y_p(t+k) = \sum_{i=1}^k a_i \Delta u(t+k-i) + \sum_{i=1}^{Np} (a_{i+1} - a_i) \Delta u(t-i) + (y_m(t)) \quad (3.11)$$

é possível escrever:

$$y_p(t+k) = \sum_{i=1}^k a_i \Delta u(t+k-i) + y_{past}(t+k) \quad (3.12)$$

onde  $y_{past}$  é a chamada resposta livre do sistema, pois não sofre as influências das ações de controle futuras, sendo então:

$$y_{past}(t+k) = \sum_{i=1}^{Np} (a_{i+1} - a_i) \Delta u(t-i) + (y_m(t)) \quad (3.13)$$

Considerando que o controlador irá realizar  $N_y$  predições ao longo do horizonte ( $k=1, \dots, N_y$ ), e  $N_u$  ações de controle  $\Delta u(0), \Delta u(1), \dots, \Delta u(N_u-1)$  aplicadas a entrada, a equação (3.12) pode ser escrita sobre a forma matricial como:

$$\begin{bmatrix} y_p(t+1) \\ y_p(t+2) \\ y_p(t+3) \\ \vdots \\ y_p(t+N_y) \end{bmatrix} = \begin{bmatrix} a_1 & 0 & 0 & \cdots & 0 \\ a_2 & a_1 & 0 & \cdots & 0 \\ a_3 & a_2 & a_1 & \cdots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ a_{N_y} & a_{N_y-1} & a_{N_y-2} & \cdots & a_{N_y-N_u+1} \end{bmatrix} \begin{bmatrix} \Delta u(t) \\ \Delta u(t+1) \\ \Delta u(t+2) \\ \vdots \\ \Delta u(t+N_u-1) \end{bmatrix} + \begin{bmatrix} y_{past}(t+1) \\ y_{past}(t+2) \\ y_{past}(t+3) \\ \vdots \\ y_{past}(t+N_y) \end{bmatrix} \quad (3.14)$$

ou, como sobre a forma vetorial:

$$Y_p = A\Delta U + Y_{past} \quad (3.15)$$

A matriz  $A$  é a chamada matriz dinâmica de controle que dá a origem ao nome do controlador preditivo *DMC* (*Dynamic Matrix Control*).

### Cálculo da Lei de Controle

A função objetivo do controlador preditivo é dada por:

$$j = \sum_{i=1}^{i=N_y} (y_{set}(t+i) - y_p(t+i))^2 \quad (3.16)$$

A lei de controle tem como objetivo encontrar a ação de controle ( $\Delta u$ ) que minimiza o erro quadrático médio entre a saída predita ( $y_p$ ) e o sinal de referência ( $y_{set}$ ) desejado para as saídas.

Na equação (3.16) é incluída uma segunda parcela, de modo a se obter um menor esforço do sistema de controle.

$$j = \sum_{i=1}^{i=N_y} (y_{set}(t+i) - y_p(t+i))^2 + \lambda^2 \sum_{i=1}^{i=N_u} (\Delta u(t+i))^2 \quad (3.17)$$



onde  $\lambda$  é o fator de supressão dos movimentos de entrada.

A Equação (3.17) sobre a forma vetorial pode ser assim representada:

$$J = (Y_{set} - Y_p)^T (Y_{set} - Y_p) + \Delta U^T \lambda^T \Lambda \Delta U \quad (3.18)$$

Para obtenção do valor  $\Delta U$  que minimiza o critério  $J$  é utilizado o método dos mínimos quadrados, sendo então a lei de controle obtida como:

$$\Delta U(t) = (A^T A + \lambda^2 I)^{-1} A^T [Y_{set}(t) - Y_{past}(t)] \quad (3.19)$$

sendo  $I$ , a matriz identidade.

A Equação (3.19) fornece as ações de controle para todo o horizonte de controle ( $N_u$ ), porém, somente o primeiro termo de ( $\Delta u$ ) é implementado. Então, o valor de  $u$  é dado como:

$$u(t) = u(t-1) + \Delta u_1(t) \quad (3.20)$$

A descrição de como se obter a lei de controle utilizando o método dos mínimos quadrados será demonstrada na seção 3.1.3

### 3.1.3 CONTROLADOR PREDITIVO DMC PARA SISTEMAS MULTIVARIÁVEIS

Admitindo-se um sistema multivariável com  $c$  variáveis controladas, onde  $c = 1, 2, \dots, C$ , e com  $m$  variáveis manipuladas, onde  $m = 1, 2, \dots, M$ , a formulação do modelo é expressa por:

$$\begin{aligned}
 y_1(t) &= y_1(0) + \sum_{i=1}^{i=Np} a_{11}(i)\Delta u_1(t-i) + \dots + \sum_{i=1}^{i=Np} a_{1M}(i)\Delta u_M(t-i) \\
 y_2(t) &= y_2(0) + \sum_{i=1}^{i=Np} a_{21}(i)\Delta u_1(t-i) + \dots + \sum_{i=1}^{i=Np} a_{2M}(i)\Delta u_M(t-i) \\
 &\vdots \\
 y_C(t) &= y_C(0) + \sum_{i=1}^{i=Np} a_{C1}(i)\Delta u_1(t-i) + \dots + \sum_{i=1}^{i=Np} a_{CM}(i)\Delta u_M(t-i)
 \end{aligned} \tag{3.21}$$

A saída predita do processo multivariável pode ser escrita de forma abreviada como segue:

$$Y_p = \underline{\underline{A}}\Delta U + Y_{past} \tag{3.22}$$

onde:

$$Y_p = \begin{bmatrix} y_{p1}(t+1) \\ \vdots \\ y_{p1}(t+N_y) \\ \vdots \\ y_{pC}(t+1) \\ \vdots \\ y_{pC}(t+N_y) \end{bmatrix}, \Delta U = \begin{bmatrix} \Delta u_1(t+1) \\ \vdots \\ \Delta u_1(t+N_u) \\ \vdots \\ \Delta u_M(t+1) \\ \vdots \\ \Delta u_M(t+N_u) \end{bmatrix}, Y_{past} = \begin{bmatrix} Y_{past,1}(t+1) \\ \vdots \\ Y_{past,1}(t+N_y) \\ \vdots \\ Y_{past,C}(t+1) \\ \vdots \\ Y_{past,C}(t+N_y) \end{bmatrix} \text{ e } \underline{\underline{A}} = \begin{bmatrix} \underline{\underline{A}}_{11} & \underline{\underline{A}}_{12} & \dots & \underline{\underline{A}}_{1M} \\ \underline{\underline{A}}_{21} & \underline{\underline{A}}_{22} & \dots & \underline{\underline{A}}_{2M} \\ \vdots & \vdots & & \vdots \\ \underline{\underline{A}}_{C1} & \underline{\underline{A}}_{C2} & \dots & \underline{\underline{A}}_{CM} \end{bmatrix} \tag{3.23}$$

A matriz dinâmica  $\underline{\underline{A}}$  possui um tamanho de  $N_y C \times N_u M$ , e é constituída pelas matrizes individuais  $\underline{\underline{A}}_{c,m}$  de tamanho  $N_y \times N_u$ , que relacionam os valores das respostas aos degraus das  $C$  saídas em relação às  $M$  entradas.

A saída predita  $Y_p$  é um vetor que tem dimensões de  $N_y \times C$ , o vetor das ações de controle possui dimensão de  $N_u \times M$ , e os efeitos das ações passadas  $Y_{past}$  terá seu tamanho definido por  $N_y \times C$ .

### Cálculo da Lei de Controle

A função objetivo controlador preditivo DMC para sistemas multivariáveis é determinada a partir da seguinte formula vetorial:

$$J = (Y_{set} - Y_p)^T W^T W (Y_{set} - Y_p) + \Delta U^T \Lambda^T \Lambda \Delta U \quad (3.24)$$

onde  $W$  é uma matriz diagonal de ponderação de dimensão  $N_p \times C$ , que permite a introdução de penalidades nos erros preditos  $(Y_{set} - Y_p)$ . Esta matriz proporciona um controle ponderado de uma variável controlada em relação a outras.  $\Lambda$  é a matriz diagonal dos fatores de supressão de movimentos, de dimensão  $N_u \times M$ , aplicada nas variáveis manipuladas.  $Y_{set}$  é o vetor de referências (*setpoints*).

A lei de controle para sistemas multivariáveis é obtida através dos métodos dos mínimos quadrados. A descrição da obtenção da lei de a partir da função econômica (Equação (3.24)) e apresentado conforme descrito no trabalho de Porfírio (2001):

modificando a Equação (3.24)

$$J = E'^T W^T W E' + \Delta U^T \Lambda^T \Lambda \Delta U \quad (3.25)$$

onde o erro predito ( $E'$ ) é determinado como:

$$E' = (Y_{set} - Y_p) \quad (3.26)$$

o erro  $E$  o qual considera somente os efeitos passados é determinado como:

$$E' = Y_{set} - Y_p = Y_{set} - Y_{past} - A \Delta U \quad (3.27)$$

$$E = Y_{set} - Y_{past} \quad (3.28)$$

então:

$$E' = E - A \Delta U \quad (3.29)$$

substituindo E' na Equação (3.25):

$$J = (-A\Delta U + E)^T W^T W (-A\Delta U + E) + \Delta U^T \Lambda^T \Lambda \Delta U \quad (3.30)$$

desenvolvendo a Equação (3.30):

$$J = E^T W^T W E - E^T W^T W A \Delta U - \Delta U^T A^T W^T W E + \Delta U^T (A^T W^T W A + \Lambda^T \Lambda) \Delta U \quad (3.31)$$

como os termos são escalares podemos dizer que:

$$E^T W^T W A \Delta U = \Delta U^T A^T W^T W E^T \quad (3.32)$$

então é possível agrupá-los:

$$J = E^T W^T W E - 2\Delta U^T A^T W^T W E + \Delta U^T (A^T W^T W A + \Lambda^T \Lambda) \Delta U \quad (3.33)$$

A aplicação do método dos mínimos quadrados consiste em se determinar o ponto onde a derivada parcial é zero, então:

$$\frac{\partial J}{\partial \Delta U} = 0 \quad (3.34)$$

$$\frac{\partial J}{\partial \Delta U} = -2A^T W^T W E + 2(A^T W^T W A + \Lambda^T \Lambda) \Delta U \quad (3.35)$$

igualando a Equação (3.35) a zero, temos:

$$0 = -2A^T W^T W E + 2(A^T W^T W A + \Lambda^T \Lambda) \Delta U \quad (3.36)$$

isolando  $\Delta U$ , obtemos:

$$\Delta U = (A^T W^T W A + \Lambda^T \Lambda)^{-1} A^T W^T W E \quad (3.37)$$

sendo:

$$E = Y_{set} - Y_{past} \quad (3.38)$$

A lei de controle para a metodologia DMC e assim apresentada:

$$\Delta U = (A^T W^T W A + \Lambda^T \Lambda)^{-1} A^T W^T W (Y_{set} - Y_{past}) \quad (3.39)$$

Uma descrição completa do método dos mínimos quadrados pode ser encontrada em Söderström e Stoica (1989).

### 3.1.3.1 Extensão para QDMC

O controlador DMC, tem a solução do cálculo das ações de controle resolvida de forma analítica, contudo, quando são impostas restrições ao problema de otimização, como no caso do QDMC, a solução dos cálculos de  $\Delta u$  é feita através de procedimentos iterativos (MELEIRO, 2002).

A função objetivo do QDMC pode ser expressa conforme a Equação (3.30), sendo então:

$$\min_{\Delta u} J = (-A\Delta U + E)^T W^T W (-A\Delta U + E) + \Delta U^T \Lambda^T \Lambda \Delta U$$

$$\text{sujeito a: } \Delta u_{\min} \leq \Delta u \leq \Delta u_{\max} \quad (3.40)$$

$$u_{\min} \leq u \leq u_{\max} \quad (3.41)$$

onde:  $E = y_{set} - y_{past}$

### 3.1.4 CONSIDERAÇÕES SOBRE OS PARÂMETROS DE AJUSTE DO DMC

O controlador DMC possui diversos parâmetros de ajuste, que têm influência direta no desempenho do algoritmo, são eles:

- Horizonte de controle ( $N_u$ ): é o número de ações de controle sucessivas sobre a entrada do sistema, necessárias para levar a saída do processo ( $y$ ) ao valor

desejado ( $y_{set}$ ). O aumento de  $N_u$  poderá acarretar um aumento da velocidade de resposta do processo, em contrapartida, o esforço computacional sofrerá acréscimo, como também, grandes variações na variável manipulada serão ocasionadas, diminuindo assim a robustez do controlador (COSTA, 2003). Normalmente, valores de  $N_u > 5$  não influenciam na melhora do desempenho do controlador. Por outro lado, quanto menor o valor do horizonte de controle ( $N_u$ ), mais robusto é o controlador, particularmente frente aos erros do modelo (PROSDÓSSIMO, 2003).

- Horizonte de modelo ( $N_p$ ): é o tempo que o sistema leva para alcançar de 95% a 99% da resposta final, após aplicação do degrau na entrada do sistema, ou seja o tempo que o sistema leva para alcançar o estado estacionário.
- Horizonte de predição ( $N_y$ ): é o comprimento do intervalo de tempo futuro no qual são preditas as saídas do controlador. Um grande valor de  $N_y$  ocasiona em geral um efeito estabilizante sobre o sistema, mas conseqüentemente, acarreta um maior esforço computacional (PROSDÓSSIMO, 2003).
- Fator de supressão dos movimentos ( $\lambda$ ): é responsável ponderar as mudanças na entrada, evitando movimentos bruscos de controle. Quanto maior o valor de  $\lambda$ , mais lenta se torna a resposta do sistema, e ocorre a redução dos movimentos de controle. O valor de  $\lambda$  normalmente é determinado através de tentativa e erro, com análise da resposta do sistema (COSTA, 2003).
- Matriz diagonal de pesos ( $W$ ): A matriz de pesos tem a função de ponderar o erro entre o sinal de referência ( $y_{set}$ ) e as saídas preditas ( $y_p$ ). Tem também a função de ajustar as diferenças entre as grandezas de cada saída, desta forma, poderá ser utilizado para determinar priorização de uma variável controlada em relação às outras.

Maiores detalhes sobre a formulação do controlador preditivo poderão ser encontrados em Cutler e Ramaker (1979), Camacho e Bordons (1999), Seborg *et al.* (1989), Schiavon (1998), Prosdóssimo (2003).

### 3.2 OTIMIZAÇÃO

Neste trabalho foram analisadas duas estruturas de otimização, com utilização de controladores QDMC, baseadas no trabalho de Schiavon (1998) e Costa (2003). A primeira delas, chamada de otimização em duas camadas, na qual o cálculo do ótimo operacional é executado em uma camada superior que envia os valores de referência ( $y_{set}$ ) para a camada inferior, composta por controle preditivo e responsável por levar as saídas ao ponto ótimo. Neste caso, os cálculos de regulação e otimização são executados em uma mesma frequência.

A segunda metodologia avaliada é a estrutura chamada de otimização em uma camada, na qual os valores do ponto ótimo do processo ( $y_{set}$ ), como também das ações de controle ( $\Delta u$ ), são calculados simultaneamente.

#### 3.2.1 OTIMIZAÇÃO EM DUAS CAMADAS

O objetivo da camada superior de otimização é gerar o incremento das referências para o controlador QDMC que neste caso implementa o nível regulatório:

$$\min_{\Delta y_{set}} \phi \left( \bar{y}(t + N_p), \bar{u}(t) \right) \quad (3.42)$$

Sujeita às seguintes definições:

$$\bar{y}(t + N_p) = y_{past}(t + N_p) + \Delta y_{set} \quad (3.43)$$

$$\bar{u}(t) = u(t) + \left( \frac{1}{A_n} \right) \Delta y_{set} \quad (3.44)$$

E às seguintes restrições de desigualdade:

$$\Delta y_{set}^{\min} \leq \Delta y_{set} \leq \Delta y_{set}^{\max} \quad (3.45)$$

$$y_{set}^{\min} \leq (y_{set} + \Delta y_{set}) \leq y_{set}^{\max} \quad (3.46)$$

onde:

$\bar{y}(t + N_p)$  é o valor da saída do processo no estado estacionário futuro, considerando as alterações no valor da referência devidas ao acréscimo de  $\Delta y_{set}$ .

$\bar{u}$  é o valor da variável manipulada, considerando-se alteração da referência.

$\mathcal{O}$  é uma função custo que representa o modelo econômico do processo, que depende do valor de  $\bar{u}$  e  $\bar{y}(t + N_p)$ .

$A_n$  é a matriz de ganho do estado estacionário.

A camada de controle recebe o valor de  $y_{set}$ , determinado pela camada de otimização, e executa o seguinte cálculo:

$$\min_{\Delta u} J = (-A\Delta U + E)^T W^T W (-A\Delta U + E) + \Delta U^T \Lambda^T \Lambda \Delta U \quad (3.47)$$

$$\text{sujeito a: } \Delta u_{\min} \leq \Delta u \leq \Delta u_{\max} \quad (3.48)$$

$$u_{\min} \leq u \leq u_{\max} \quad (3.49)$$

onde:  $E = y_{set} - y_{past}$

A otimização em duas camadas pode ser esquematicamente representada pela Figura 3.4.



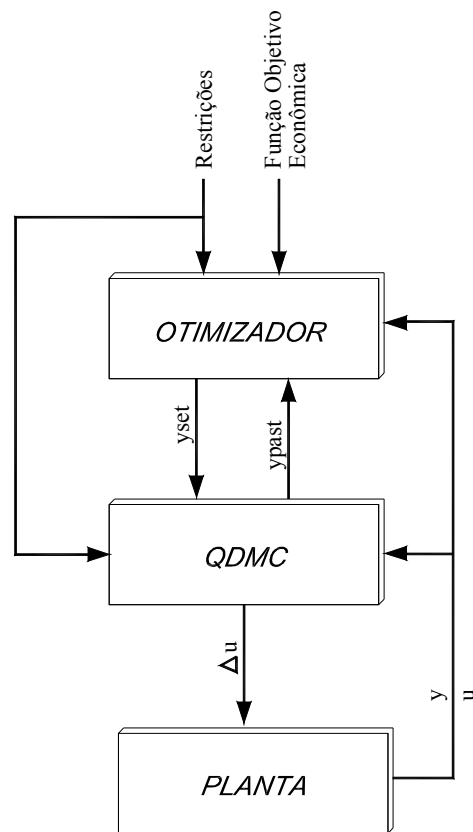


Figura 3.4 – Esquemático da otimização em duas camadas

Nesta metodologia, na camada de otimização, as restrições não são aplicadas diretamente nas variáveis controladas, mas nos seus valores de referência.

Um fluxograma das etapas realizadas no algoritmo de otimização e controle para a estrutura em duas camadas é apresentada na Figura 3.5.

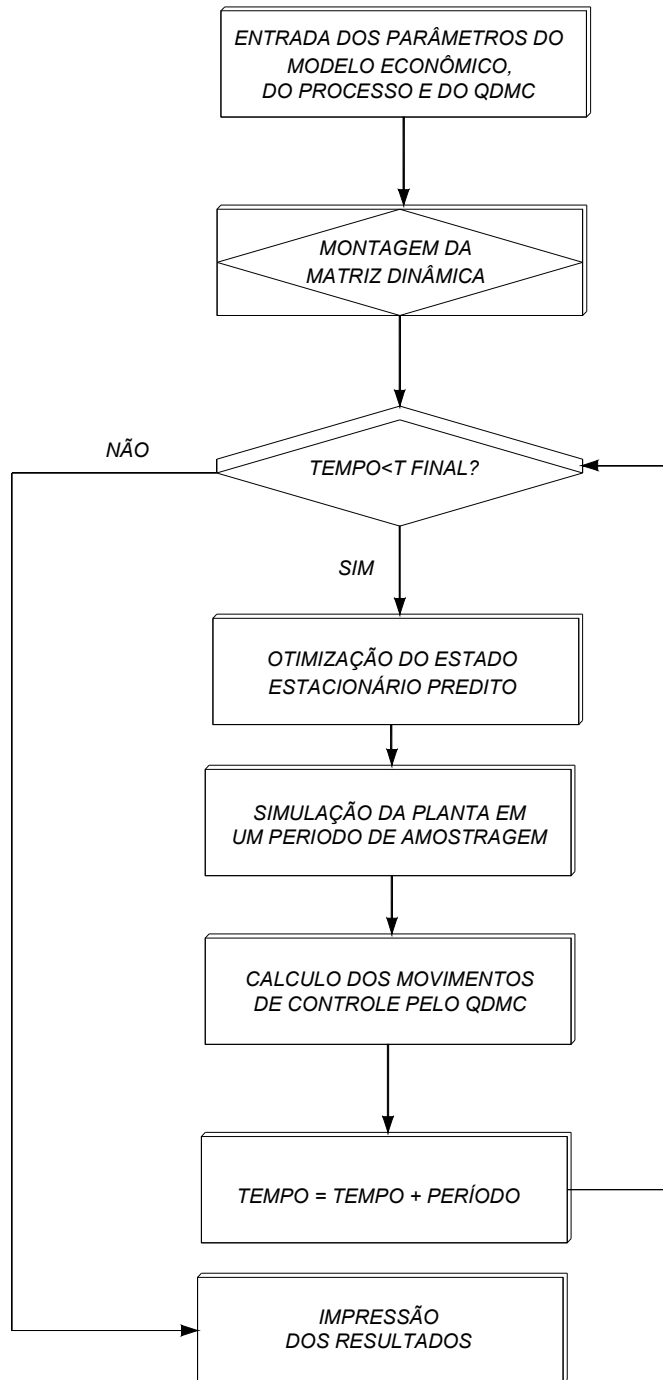


Figura 3.5 – Fluxograma do algoritmo da estrutura em duas camadas

### 3.2.2 OTIMIZAÇÃO EM UMA CAMADA

Na estrutura em uma camada a função econômica do processo é inserida diretamente dentro da camada de controle, sendo o problema de otimização assim formulado:

$$\min_{\Delta u, \Delta y_{set}} \psi = W_1 [(-A\Delta U + E)^T W^T W (-A\Delta U + E)] + W_2 [\Delta U^T \Lambda^T \Lambda \Delta U] + W_3 (\Phi) \quad (3.50)$$

sujeito às seguintes restrições:

$$\Phi = f\left(\bar{y}(t + N_p), \bar{u}(t)\right) \quad (3.51)$$

$$\bar{y}(t + N_p) = y_{past}(t + N_p) + \Delta y_{set} \quad (3.52)$$

$$\bar{u}(t) = u(t - 1) + \left(\frac{1}{A_n}\right) \Delta y_{set} \quad (3.53)$$

$$\Delta y_{set}^{\min} \leq \Delta y_{set} \leq \Delta y_{set}^{\max} \quad (3.54)$$

$$y_{set}^{\min} \leq y_{set} \leq y_{set}^{\max} \quad (3.55)$$

$$\Delta u_{\min} \leq \Delta u \leq \Delta u_{\max} \quad (3.56)$$

$$u_{\min} \leq u \leq u_{\max} \quad (3.57)$$

$$E = y_{set} - y_{past} \quad (3.58)$$

onde:  $W_1$ ,  $W_2$  e  $W_3$  são fatores de peso que ponderam as parcelas referentes ao controle preditivo e à função econômica do processo.

Como pode ser observado nas Equações (3.51) a (3.57), não foram impostas restrições diretas sobre as variáveis controladas, porém, seus movimentos são limitados pelas restrições impostas aos valores de referência.

A otimização em uma camadas pode ser esquematicamente representada pela Figura 3.6.

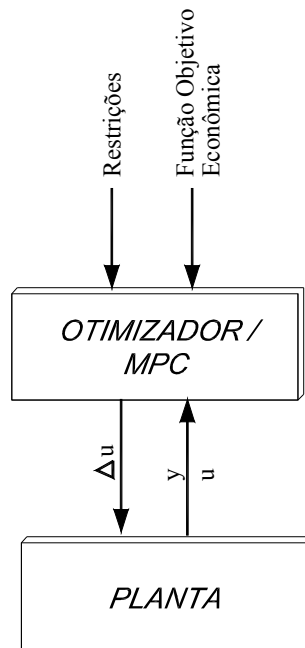


Figura 3.6 – Esquemático da estrutura em uma camada

Um fluxograma das etapas realizadas no algoritmo de otimização e controle para a estrutura em duas camadas é apresentada na Figura 3.7.

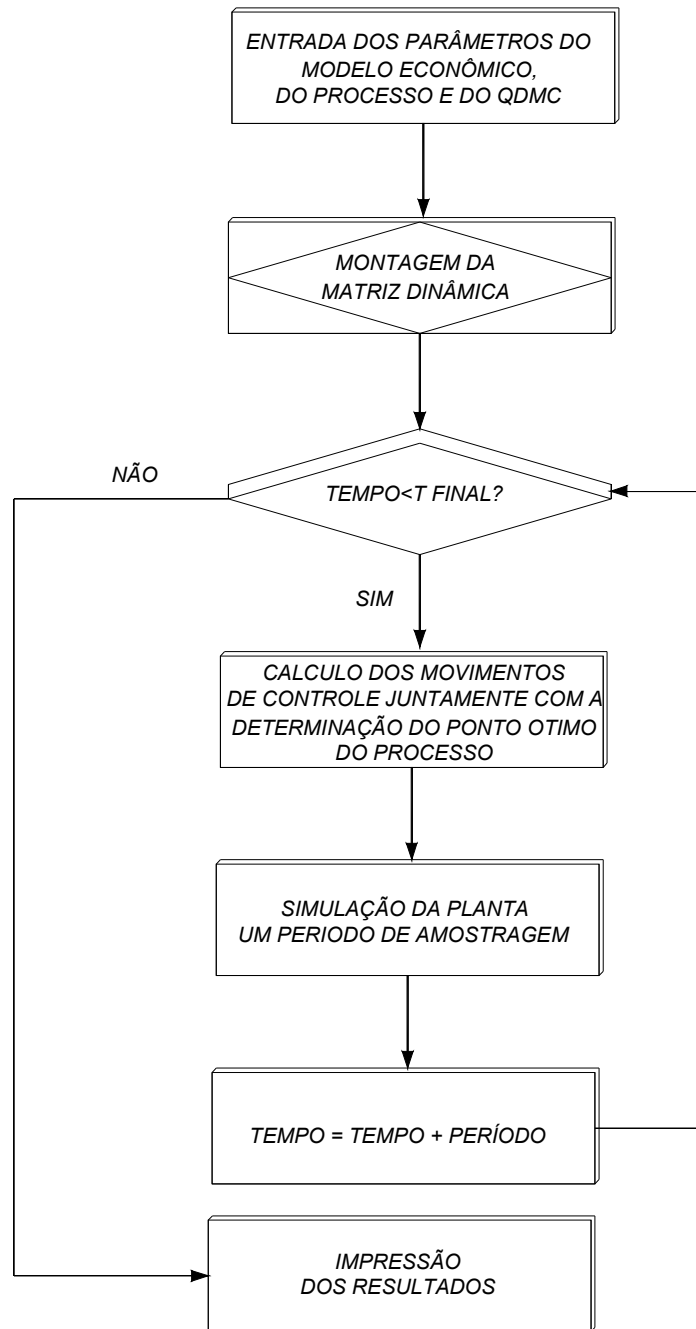


Figura 3.7 – Fluxograma do algoritmo da estrutura em uma camada

As metodologias de controle preditivo e otimização em uma e duas camadas aqui abordadas, serão aplicadas a dois processos multivariáveis para avaliação de desempenho e resultado, conforme será apresentado no Capítulo 4.



#### 4.1 INTRODUÇÃO

Os processos utilizados para o estudo das metodologias apresentadas no capítulo anterior são: Coluna de Destilação Wood-Berry (WOOD e BERRY, 1973) e Processo de Craqueamento Catalítico em Leito Fluidizado (PROSDÓSSIMO, 2003). Para cada um destes processos foram realizadas simulações em diversas condições de operação.

A coluna de destilação Wood-Berry é um modelo multivariável com duas entradas, duas saídas e acoplamento entre as variáveis.

O Processo de Craqueamento Catalítico em Leito Fluidizado ou *Fluidized Catalytic Cracking* (FCC) é empregado para a produção de derivados nobres de petróleo, como gasolina e gás liquefeito de petróleo, sendo, portanto, largamente utilizado na indústria de refino (MELO JR., 2003). Para fins de controle, o FCC pode ser modelado como um sistema não linear, multivariável com cinco entradas e cinco saídas, conforme modelo utilizado neste trabalho, apresentando características complexas como grandes constantes de tempo, atraso de transporte e não linearidades (PROSDÓSSIMO, 2003).

Para os dois modelos, as simulações foram efetuadas em três etapas. Primeiramente, somente o controlador preditivo QDMC foi inserido de modo a se verificar e obter os ajustes para o tempo de resposta, e avaliar características de sobre-sinal, erro de estado estacionário, e a robustez do controlador quando da inserção de perturbações e ruídos no sistema.

A segunda etapa consiste na aplicação do modelo de otimização em duas camadas. Para a coluna de destilação Wood-Berry, foram aplicados diversos tipos de objetivos econômicos (lineares e não lineares) de modo a se verificar a eficiência desta otimização em condições distintas, sendo que os modelos econômicos utilizados não necessariamente representam aspectos práticos deste processo, mas compreendem diferentes situações para uma abrangente avaliação da metodologia.

Posteriormente à avaliação preliminar da otimização em duas camadas efetuada com a utilização da coluna de destilação Wood-Berry, esta técnica foi aplicada ao modelo do Craqueamento Catalítico em Leito Fluidizado, porém, neste caso, para uma validação final,

foram considerados aspectos práticos deste processo no objetivo econômico, correspondentes à maximização da produção de Gás Liquefeito de Petróleo (GLP).

A terceira etapa de simulações corresponde à aplicação do modelo de otimização em uma camada. Seguindo os mesmos procedimentos da etapa anterior, a coluna de destilação Wood-Berry foi utilizada para uma avaliação preliminar da metodologia, com aplicação das funções econômicas antes empregadas abrangendo diferentes situações; e o FCC utilizado para uma validação final da técnica, também com a mesma função econômica adotada anteriormente. Desta forma, foi possível obter uma comparação entre as duas metodologias de otimização. Além disto, para o Craqueamento Catalítico em Leito Fluidizado, também foram realizadas simulações com variação do parâmetro de ajuste do modelo de otimização em uma camada, permitindo, desta forma, a análise dos efeitos de configuração deste parâmetro.

Para as simulações utilizou-se o *software* matemático Matlab® versão 7.0. As funções do controlador preditivo foram desenvolvidas, desta forma não foi utilizado o *toolbox* de controle preditivo existente dentro do programa Matlab, o que permitiu uma maior flexibilidade.

Para a solução dos problemas econômicos, foi utilizada a função *fmincon* existente no Matlab.

Devido à demora na realização das simulações com o uso do programa Matlab, relacionada ao número excessivo de equações que representam o modelo, a simulação do processo não linear do FCC foi realizada no *software* C++ Builder® 5. Porém, as rotinas do controlador preditivo e de otimização foram mantidas no programa Matlab, sendo, portanto, necessário o estabelecimento de uma comunicação entre os dois *software*'s.

As simulações apresentadas foram realizadas com a utilização de um computador com as seguintes características: Athlon (TM) XP 2600+, 2 GHz, 512 MB RAM.



## 4.2 COLUNA DE DESTILAÇÃO WOOD-BERRY

Um modelo de coluna de destilação para separação de metanol e água desenvolvido em escala piloto, foi proposto por Wood e Berry (1973). O modelo é do tipo MIMO com duas variáveis manipuladas e duas variáveis controladas, sendo estas:

Variáveis manipuladas:

- Vazão mássica de refluxo ( $u_1(s)$ ) expresso em lb/min.
- Vazão mássica de vapor ( $u_2(s)$ ) expresso em lb/min.

Variáveis controladas:

- Porcentagem mássica de metanol no topo ( $y_1(s)$ ).
- Porcentagem mássica de metanol no fundo ( $y_2(s)$ ).

O comportamento deste processo é representado pelas seguintes equações de transferência:

$$\begin{bmatrix} y_1(s) \\ y_2(s) \end{bmatrix} = \begin{bmatrix} \frac{12,8e^{-s}}{16,7s+1} & \frac{-18,9e^{-3s}}{21,0s+1} \\ \frac{6,6e^{-7s}}{10,9s+1} & \frac{-19,4e^{-3s}}{14,4s+1} \end{bmatrix} * \begin{bmatrix} u_1(s) \\ u_2(s) \end{bmatrix} \quad (4.1)$$

A unidade de tempo padrão é o minuto, e os pontos de operação da coluna de destilação são:

- Para  $y_1(s)$  o valor de referência é 96% .
- Para  $y_2(s)$  o valor de referência é 0.5% .

A coluna de destilação de Wood-Berry é um processo acadêmico para simulação de um processo multivariável com duas entradas e duas saídas. Devido a pouca complexidade inerente deste modelo, a coluna poderia ser controlada a partir de controladores menos complexos como, por exemplo, o PID. Porém, neste trabalho, utiliza-se esta coluna com o objetivo de explorar as metodologias estudadas, através da análise dos ajustes, variação das funções custo, e observação das características de respostas obtidas, para posterior aplicação destas abordagens no processo FCC, que apresenta um maior grau de complexidade.

#### 4.2.1 CONTROLE PREDITIVO QDMC

A primeira etapa de simulação consiste no ajuste do controlador preditivo QDMC desenvolvido para o controle da coluna de destilação Wood-Berry.

O processo de sintonia tem como objetivo verificar o ajuste do QDMC sob os aspectos de tempo de resposta, sobre-sinal, erro de estado estacionário e robustez frente a perturbações e ruídos.

O controlador QDMC utilizado foi ajustado conforme a Tabela 4.1:

Parâmetro	Valor
$N_p$	120
$N_u$	2
$N_y$	25
$W$	[1 0.8]
$\lambda$	[25 30]

Tabela 4.1 - Parâmetros de ajuste do controlador QDMC

onde  $N_p$  é o horizonte do modelo,  $N_u$  é o horizonte de controle,  $N_y$  corresponde ao horizonte de predição,  $W$  e  $\lambda$  são as matrizes diagonais de ponderação das variáveis controladas e supressão de movimentos respectivamente, cujos valores foram obtidos de forma heurística, após análise de diversas simulações, sendo escolhidos os que obtiveram melhores resultados.

Os limites impostos ao sistema, foram definidos conforme a Tabela 4.2 e Tabela 4.3

Variáveis do Processo	Valor Inicial	Valor Máximo	Valor Mínimo
Variável Manipulada $u_1$	0	0,2	0
Variável Manipulada $u_2$	0	0,2	0

Tabela 4.2 - Limites máximos e mínimos das variáveis manipuladas

Parâmetro	$\Delta u^{\max}$	$\Delta u^{\min}$
Entrada $u_1$	0,1	-0,1
Entrada $u_2$	0,1	-0,1

Tabela 4.3 – Movimentos máximos e mínimos da ações de controle.

A Figura 4.1 e a Figura 4.2 mostram as respostas obtidas para os valores de referência de 0.96 e de 0.05 para  $y_1$  e  $y_2$  respectivamente. Ambas as saídas estacionaram sobre os valores de referência após aproximadamente 70 min, não havendo erro de estado estacionário. Tanto para na saída  $y_1$  quanto na saída  $y_2$ , é observado sobre-sinal.




Figura 4.1 - Resposta obtida  $y_1$  e  $y_2$ , controle do tipo QDMC.

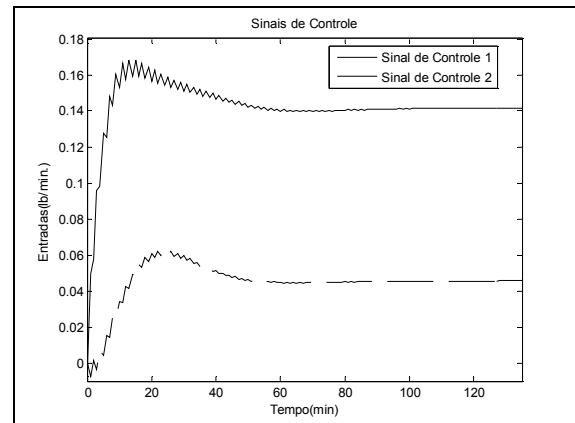


Figura 4.2 - Resposta obtida  $u_1$  e  $u_2$ , controle do tipo QDMC.

Apesar dos sobre-sinais ocorridos serem de amplitude baixa, a Figura 4.3 e a Figura 4.4 apresentam as respostas de uma simulação na qual o QDMC teve os seus valores de ajuste alterados, de maneira a diminuir os sobre-sinais verificados anteriormente.

O parâmetro  $\lambda$ , responsável por limitar as ações de controle, foi alterado para [100, 80]. Um segundo parâmetro,  $W$ , responsável pela ponderação entre o erro do sinal de saída em relação ao sinal de referência, foi modificado para [1, 6]. Com esta segunda modificação, o sistema de controle passou a dar uma maior prioridade à resposta da saída  $y_2$ .




Figura 4.3 - Resposta obtida  $y_1$  e  $y_2$ , controle do tipo QDMC, com modificação dos parâmetros.




Figura 4.4 - Resposta obtida  $u_1$  e  $u_2$ , controle do tipo QDMC, com modificação dos parâmetros.

Com as alterações efetuadas, a saída  $y_2$  atinge o valor de referência com sobre-sinal menor que o verificado na simulação anterior mantendo o erro de estado estacionário zero. A saída  $y_1$  apresentou sobre-sinal nulo, e também manteve o de estado estacionário também nulo, porém, o tempo de resposta foi maior, passando de 70 min para aproximadamente 100 min.

As duas soluções apresentadas podem ser empregadas para o controle do processo e demonstram a flexibilidade de ajuste do controlador QDMC. O julgamento de qual comportamento do sistema é melhor, se com sobre-sinal e uma resposta mais rápida, ou com sobre-sinal igual a zero e resposta mais lenta, dependerá das necessidades do projeto, ficando a critério do projetista.

Desta forma, para as simulações que seguem, os ajustes do controlador QDMC foram mantidos como inicialmente conforme a Tabela 4.1.

A análise seguinte consiste na inserção de três valores distintos de referência para  $y_1$  e  $y_2$ . Este procedimento tem como objetivo analisar o comportamento do QDMC quando da necessidade de se controlar o sistema com uma sucessão de mudanças nos valores de referência. As respostas podem ser observadas na Figura 4.5 e na Figura 4.6. Ambas as respostas obedeceram aos sinais de referência, não havendo a presença de erros de estado estacionário. É possível observar que o valor de sobre-sinal ocorrido foi pequeno para as duas saídas.




Figura 4.5 - Alterações nos valores de referência, saída  $y_1$  e  $y_2$ .




Figura 4.6 - Alterações nos valores de referência, sinal de controle  $u_1$  e  $u_2$ .

Para se verificar o comportamento do sistema frente a perturbações, foi inserida na equação que representa o modelo da coluna de Wood-Berry uma segunda parcela, conforme a Equação (4.2), que representa a influência da variação na vazão mássica de alimentação ( $p(s)$ ) sobre as variáveis controladas  $y_1$  e  $y_2$ .

$$\begin{bmatrix} y_1(s) \\ y_2(s) \end{bmatrix} = \begin{bmatrix} \frac{12,8e^{-s}}{16,7s+1} & \frac{-18,9e^{-3s}}{21,0s+1} \\ \frac{6,6e^{-7s}}{10,9s+1} & \frac{-19,4e^{-3s}}{14,4s+1} \end{bmatrix} * \begin{bmatrix} u_1(s) \\ u_2(s) \end{bmatrix} + \begin{bmatrix} \frac{3,8e^{-8,1s}}{14,9s+1} \\ \frac{4,9e^{-3,4s}}{13,2s+1} \end{bmatrix} * p(s) \quad (4.2)$$

As alterações nos valores de  $p(s)$  como também a influencia da perturbação em  $y_1$  e  $y_2$  são mostrados nas Figura 4.7 e Figura 4.8 respectivamente.

As respostas obtidas com esta perturbação podem ser verificadas na Figura 4.9 e na Figura 4.10. Analisando estas respostas, é possível verificar que houve mudanças bruscas tanto em  $y_1$  como em  $y_2$ , porém, com a ação do QDMC foi possível compensar os efeitos da perturbação, com a correção dos valores das saídas.




Figura 4.7 - Alterações nos valores de  $p(s)$




Figura 4.8 – Influência da perturbação sobre  $y_1$  e  $y_2$




Figura 4.9 - Resposta obtida  $y_1$  e  $y_2$  com perturbação do tipo degrau inserida na saída  $y_1$ .




Figura 4.10 - Resposta obtida  $u_1$  e  $u_2$  com perturbação do tipo degrau na saída  $y_1$ .

Também foi verificado o comportamento do controlador QDMC quando da inserção de um ruído do tipo gaussiano, com variância de 0.01 e média zero, sobre a saída  $y_1$ . Na Figura 4.11 e na Figura 4.12 são observadas as respostas do sistema, e verifica-se que mesmo com significativa amplitude de ruído o controlador possibilitou a condução das saídas aos valores de referência desejados ( $y_1=0.96$  e  $y_2 = 0.05$ ).




Figura 4.11 - Resposta obtida  $y_1$  e  $y_2$  com ruído inserido na saída  $y_1$ .




Figura 4.12 - Resposta obtida  $u_1$  e  $u_2$  com ruído inserido na saída  $y_1$ .

Após a presente etapa de análise do comportamento do controlador preditivo QDMC no controle da coluna de destilação Wood-Berry, com verificação do comportamento frente a perturbações, ruído e mudanças sucessivas de referência, e conseqüente constatação do comportamento satisfatório deste sistema de controle, é possível seguir para as próximas etapas que tratam da inserção de critérios de otimização no sistema.

#### 4.2.2 OTIMIZAÇÃO EM DUAS CAMADAS

Após o emprego do controlador preditivo QDMC, a coluna de destilação Wood-Berry foi submetida à inserção do modelo de otimização em duas camadas.

Esta forma de implementação de otimização é constituída por uma camada otimizadora em um nível superior que envia os sinais de referência ( $y_{set}$ ) a serem seguidos pela camada de controle em um nível abaixo. Apesar de separadas, as duas camadas possuem interação e são executadas em uma mesma frequência, conforme a metodologia apresentada no capítulo 3.

Os limites impostos ao sistema, como também o ajuste do controlador e da camada de otimização, foram definidos conforme a Tabela 4.4, Tabela 4.5, Tabela 4.6, e Tabela 4.7.

Variáveis do Processo	Valor Inicial	Valor Máximo	Valor Mínimo
Variável Controlada $y_1$	0	1	0
Variável Controlada $y_2$	0	1	0
Variável Manipulada $u_1$	0	0,2	0
Variável Manipulada $u_2$	0	0,2	0

Tabela 4.4 - Limites máximos e mínimos das variáveis manipuladas e controladas para otimização em duas camadas.

Parâmetro	Valor
$N_p$	120
$N_u$	2
$N_y$	25
diagonal $W [y1; y2]$	[1; 0,8]
diagonal $\lambda [y1; y2]$	[25; 30]

Tabela 4.5 - Parâmetros de ajuste do controlador para otimização em duas camadas.

Parâmetro	$\Delta y_{set}^{\max}$	$\Delta y_{set}^{\min}$
Saída $y1$	0,1	-0,1
Saída $y2$	0,1	-0,1

Tabela 4.6 – Movimentos máximos e mínimos da ações de otimização.

Parâmetro	$\Delta u^{\max}$	$\Delta u^{\min}$
Entrada $u1$	0,1	-0,1
Entrada $u2$	0,1	-0,1

Tabela 4.7 – Movimentos máximos e mínimos da ações de controle.

As simulações foram iniciadas com somente a camada de controle ativa, que foi responsável por conduzir as saídas do sistema para os valores de referência iniciais definidos em 0.7 e 0.3 para  $y_1$  e para  $y_2$  respectivamente. Depois de decorridos 100 minutos, a camada de otimização foi ativada, conduzindo o sistema para o ponto ótimo, conforme definido pelo objetivo econômico.

Os objetivos econômicos aqui utilizados não necessariamente refletem aspectos práticos da coluna de destilação Wood-Berry, mas têm por objetivo permitir uma abrangente análise do método de otimização sob diferentes critérios.

Os objetivos econômicos empregados e os respectivos resultados são apresentados nas seções a seguir.



**4.2.2.1 Objetivo 1:  $\phi = \text{maximizar } (y_1 - y_2)$** 

A primeira análise de otimização em duas camadas foi realizada utilizando uma função objetivo econômica conforme a Equação ( 4.3), que consiste na maximização da variável controlada  $y_1$  e da minimização da variável controlada  $y_2$ .

$$\phi = \text{maximizar } (y_1 - y_2) \quad (4.3)$$

Os resultados podem ser observados na Figura 4.13. Após ativa a camada de otimização, no tempo de 100 min, os valores de referência foram manipulados de modo a se obter o máximo valor para a função objetivo, conforme mostra a Figura 4.13e.

A camada de controle rapidamente conduz as saídas para os respectivos valores de referência. Ambas as saídas apresentam pequenos valores de sobre-sinal, que são compensados após 70 min de ativada a camada de otimização. O erro de estado estacionário foi nulo e todos os limites foram respeitados.

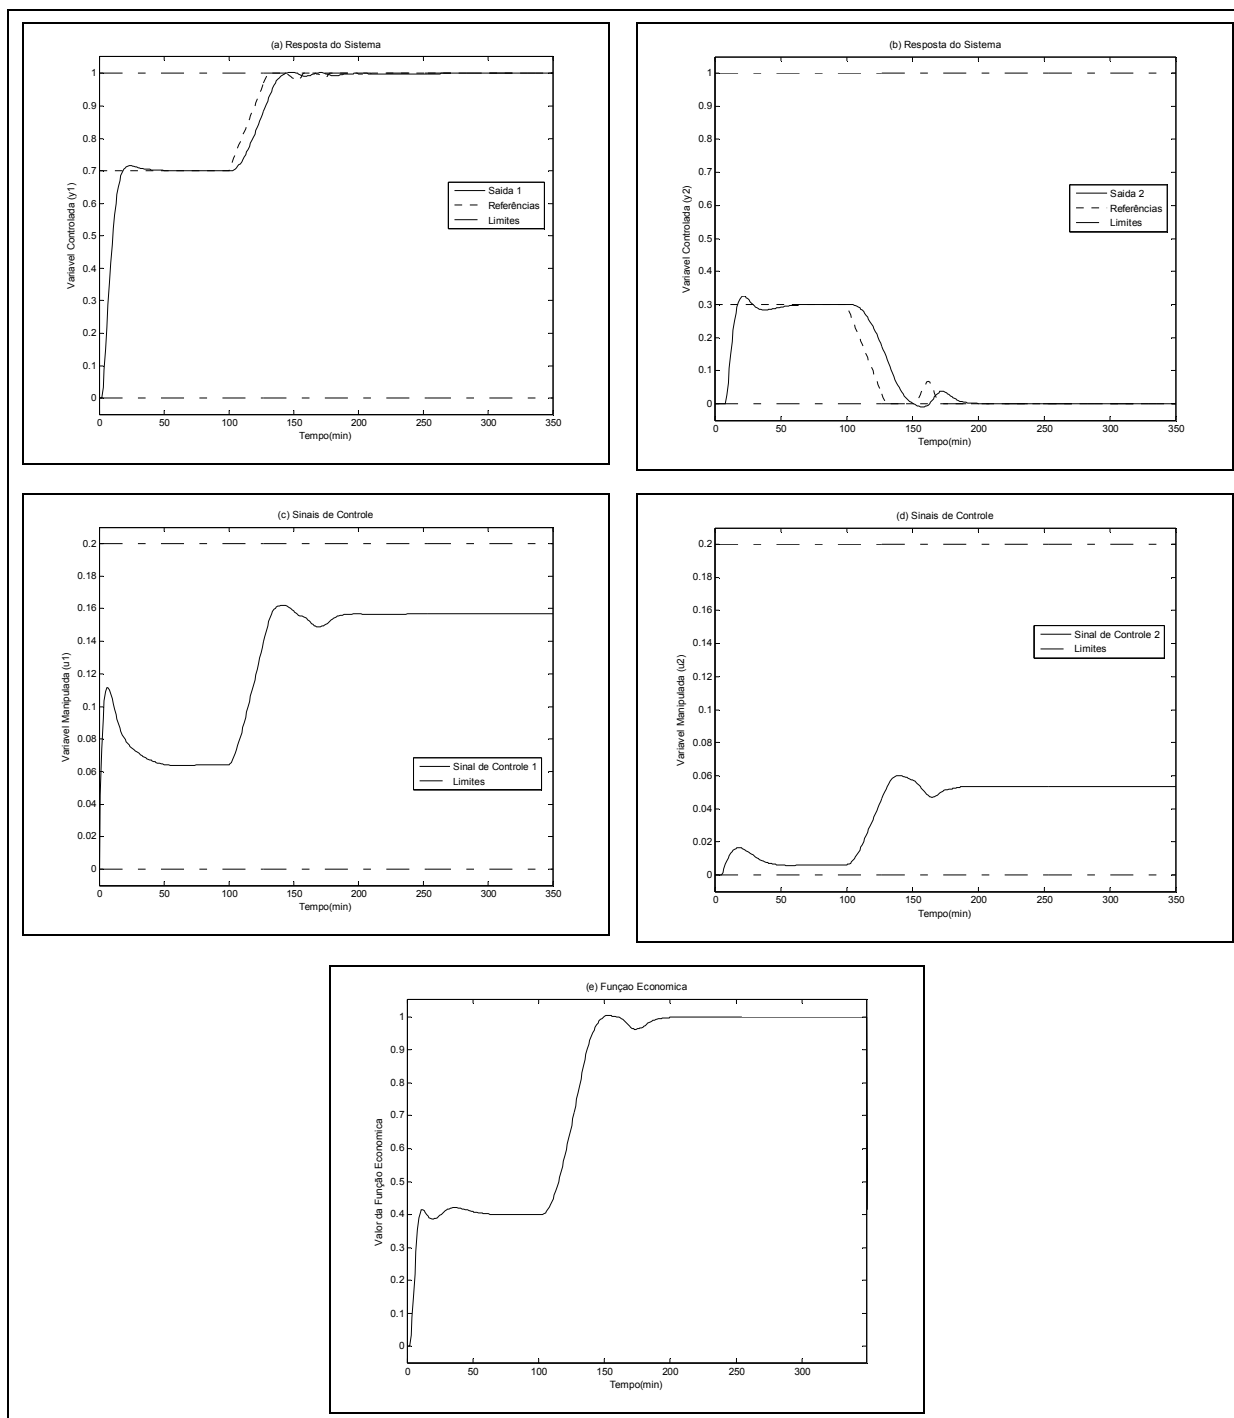


Figura 4.13 - Respostas obtidas para a Função objetivo  $\phi = \text{maximizar } (y_1 - y_2)$  para estrutura em duas camada

**4.2.2.2 Objetivo 2:  $\phi = \text{minimizar } (y_2 - 5u_1)$** 

Esta simulação consiste na minimização da saída  $y_2$  e da maximização da entrada  $u_1$ , conforme a Equação (4.4). Esta situação imposta pela função objetivo econômica, consiste em se verificar o comportamento da camada de otimização quando da inserção da variável manipulada dentro da função econômica.

$$\phi = \text{minimizar } (y_2 - 5u_1) \quad (4.4)$$

Os resultados obtidos podem ser observados na Figura 4.14. A referência da saída  $y_1$ , apesar de não fazer parte da função objetivo econômica, tem seu valor modificado devido a influência das movimentações da saída  $y_2$  e da entrada  $u_1$ , que alteram-se de modo a satisfazer os objetivos da Equação (4.4). O sobre-sinal praticamente foi nulo para ambas as variáveis, como também erros de estado estacionário não foram verificados. Em nenhum momento houve violação das restrições impostas para a referência  $y_{set}$ , como também para os valores limites de  $u$ .

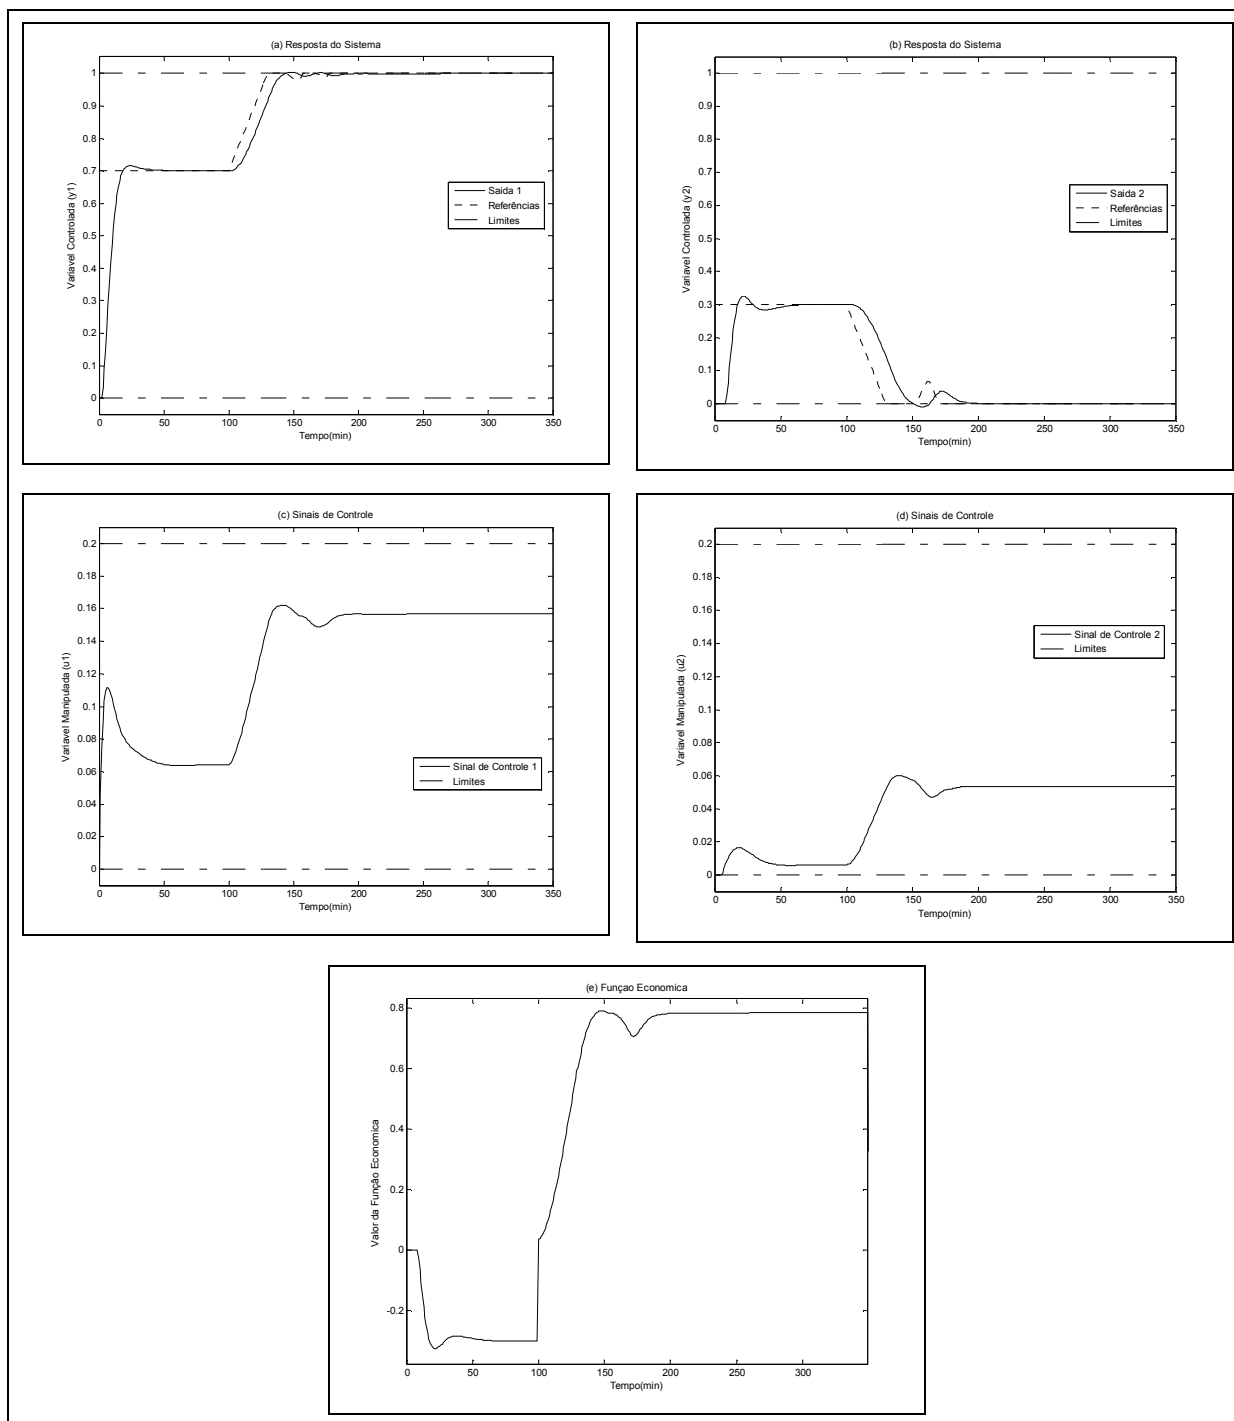


Figura 4.14 - Respostas obtidas para a Função objetivo  $\phi = \text{minimizar } (y_2 - 5u_1)$  para estrutura em duas camada

#### 4.2.2.3 Objetivo 3: $\phi = \text{maximizar } (2y_1 - y_2)$

O objetivo desta simulação é maximizar  $y_1$  e minimizar  $y_2$ , considerando um peso maior à variável  $y_1$  conforme demonstra a Equação (4.5). Para esta simulação, foi diminuído o valor do limite máximo das variáveis manipuladas, conforme Tabela 4.8, com o objetivo de verificar o comportamento das saídas do sistema quando isoladamente os valores das variáveis controladas ( $u$ ) não possuem condições de levar as saídas para o valor máximo e mínimo, conforme solicitado pela função econômica.

$$\phi = \text{maximizar } (2y_1 - y_2) \quad (4.5)$$

Variáveis do Processo	Valor Inicial	Valor Máximo	Valor Mínimo
Variável Controlada $y_1$	0	1	0
Variável Controlada $y_2$	0	1	0
Variável Manipulada $u_1$	0	0,1	0
Variável Manipulada $u_2$	0	0,1	0

Tabela 4.8 - Limites máximos e mínimos das variáveis manipuladas e controladas, com modificação dos limites máximos para otimização em duas camadas

Os resultados obtidos podem ser observados na Figura 4.15. É possível observar que a saída  $y_2$ , após ativa a camada de otimização, rapidamente  $u_1$  atinge o valor máximo permitido,  $y_2$  movimenta-se de maneira a favorecer a maximização de saída  $y_1$ , que possui maior peso no objetivo econômico.

Devido à limitação nos valores de entrada, a referência movimenta-se de maneira mais lenta para o máximo operacional. Analisando a Figura 4.15a, observa-se que não houve erro de estado estacionário.

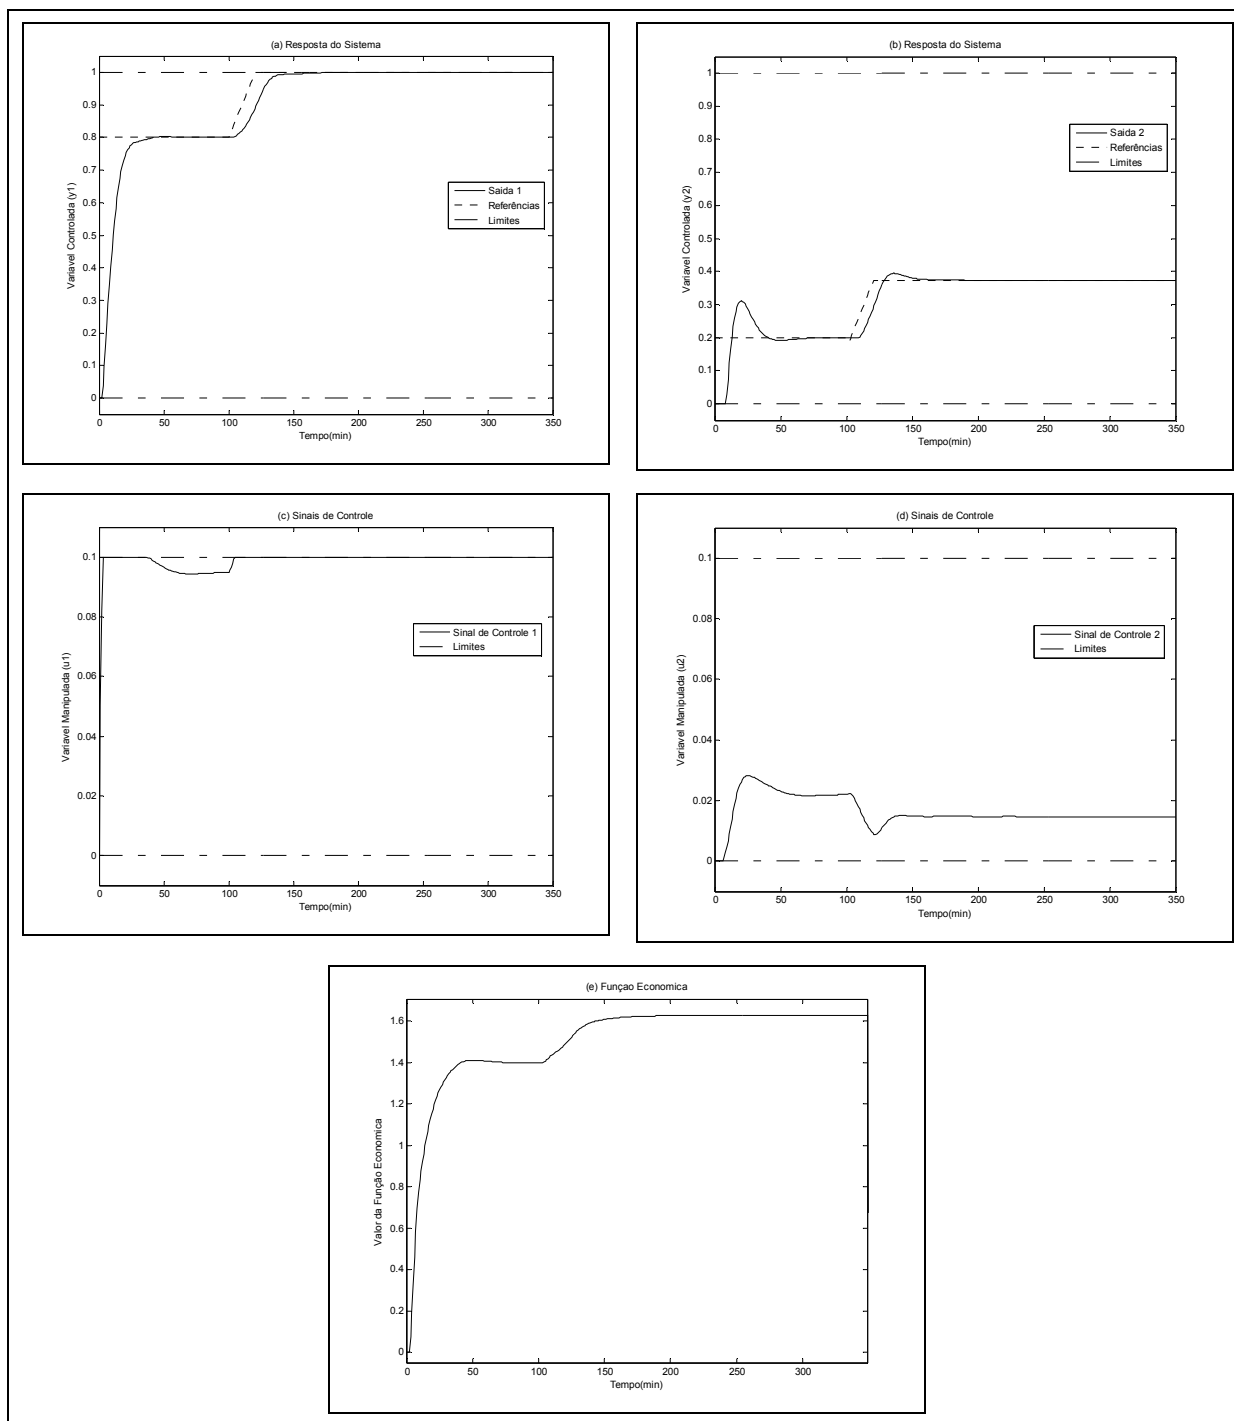


Figura 4.15 - Respostas obtidas para a Função objetivo  $\phi = \text{maximizar } (2y_1 - y_2)$  com diminuição do limite máximo das variáveis manipuladas para estrutura em duas camada

**4.2.2.4 Objetivo 4:  $\phi = \text{maximizar } (y_1 - y_2)$  com perturbação**

Para verificar a robustez do sistema (otimização+controle) nesta simulação, foram inseridas perturbações, conforme a Equação (4.6) e Figura 4.16 e Figura 4.17. Utiliza-se, para tanto, um objetivo econômico analisado anteriormente, e aqui representado na Equação (4.7).

$$\begin{bmatrix} y_1(s) \\ y_2(s) \end{bmatrix} = \begin{bmatrix} \frac{12,8e^{-s}}{16,7s+1} & \frac{-18,9e^{-3s}}{21,0s+1} \\ \frac{6,6e^{-7s}}{10,9s+1} & \frac{-19,4e^{-3s}}{14,4s+1} \end{bmatrix} * \begin{bmatrix} u_1(s) \\ u_2(s) \end{bmatrix} + \begin{bmatrix} \frac{3,8e^{-8,1s}}{14,9s+1} \\ \frac{4,9e^{-3,4s}}{13,2s+1} \end{bmatrix} * p(s) \quad (4.6)$$

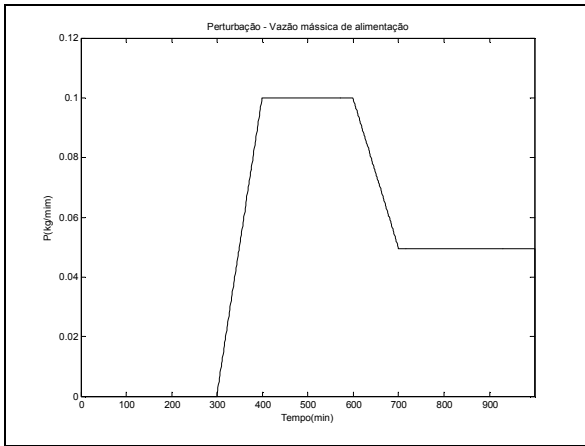


Figura 4.16 - Alterações nos valores de  $p(s)$  - Otimização em duas camadas




Figura 4.17 – Influência da perturbação sobre  $y_1$  e  $y_2$  - Otimização em duas camadas

$$\phi = \text{maximizar } (y_1 - y_2) \quad (4.7)$$

Os resultados podem ser observados na Figura 4.18. Quando ocorrem mudanças na valores da perturbação ( $p(s)$ ), os valores das saídas ultrapassam os valores máximos e mínimos definidos na Tabela 4.4. A camada de otimização, ao constatar a ultrapassagem dos limites, reage rapidamente trazendo estes valores novamente para dentro da faixa de operação, para, então, manipular mais uma vez as variáveis controladas de modo a se obter o maior valor da função objetivo econômica.

Apesar dos grandes picos de mudanças de valores, tanto das saída quando das entradas, ocasionados pela perturbação, o sistema interpreta corretamente o objetivo da função econômica.

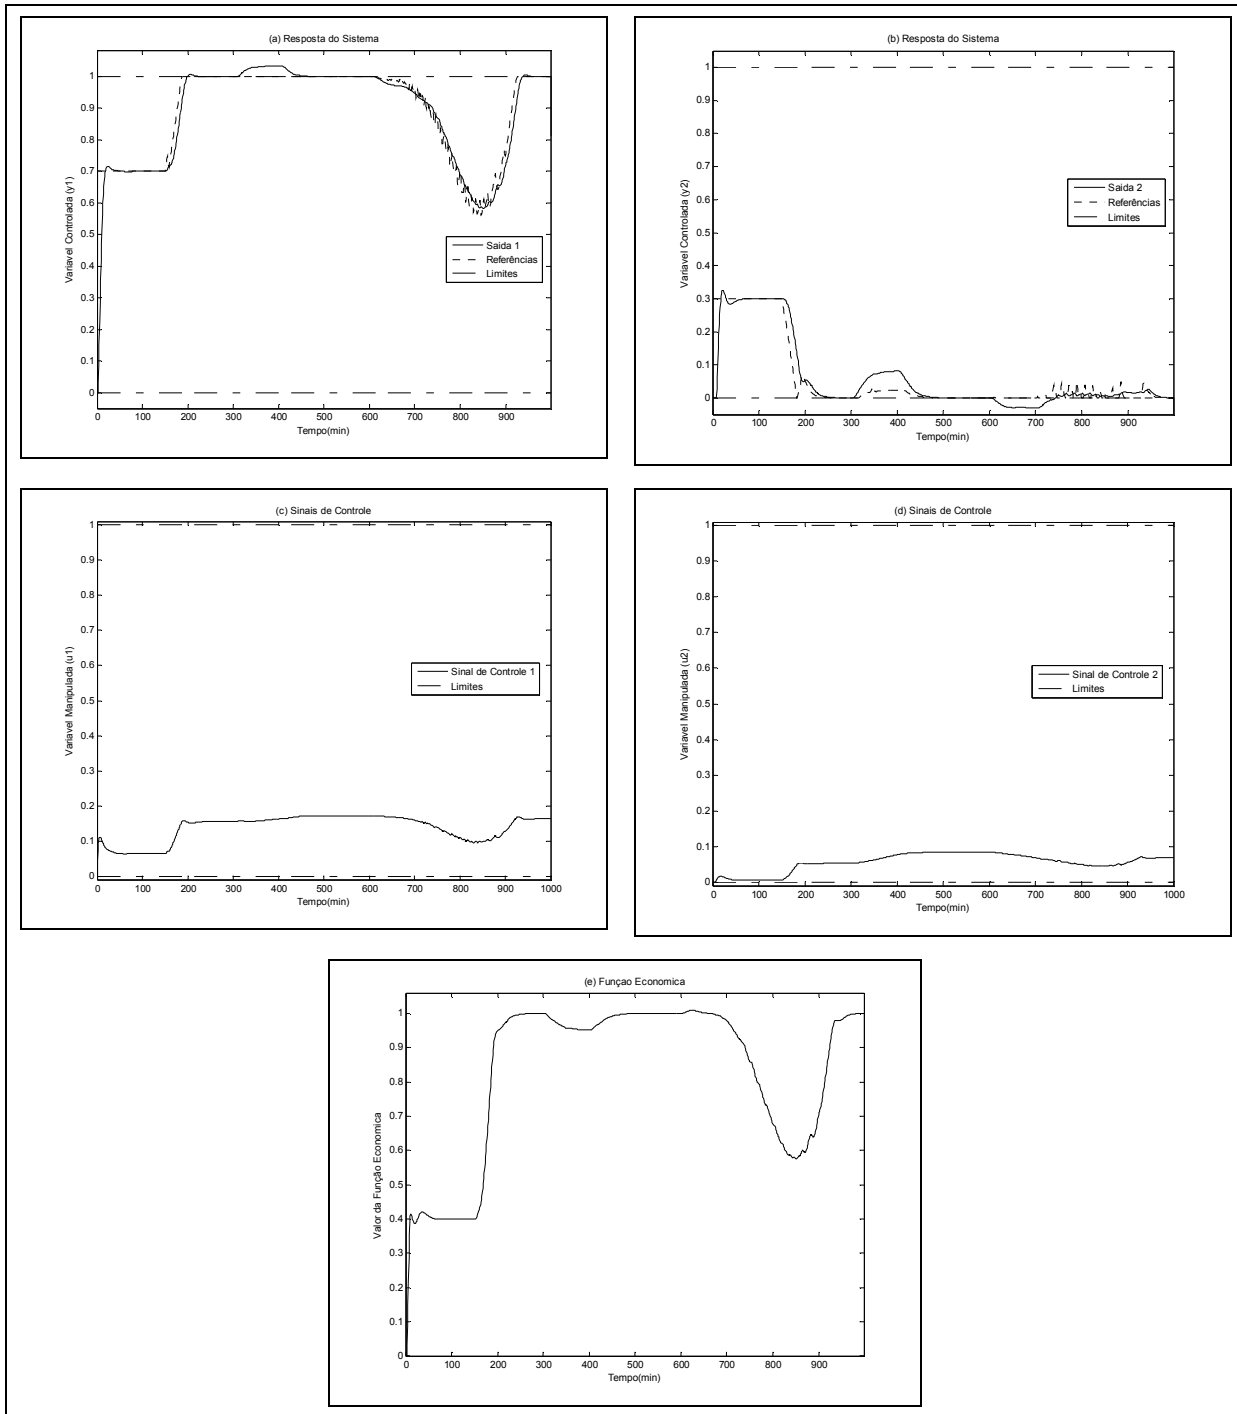


Figura 4.18 - Respostas obtidas para a Função objetivo  $\phi = \text{maximizar } (y_1 - y_2)$  com perturbação na variável  $y_1$  para estrutura em duas camada



**4.2.2.5 Objetivo 5:  $\phi$ =maximizar  $(y_1 - y_2)$  com ruído**

Para verificar a robustez do sistema (otimização+controle), foi inserido um ruído do tipo gaussiano, com variância de 0.01 e média zero, sobre a saída  $y_1$ . Utiliza-se, para tanto, o mesmo objetivo econômico analisado anteriormente, e aqui representado na Equação (4.8).

$$\phi = \text{maximizar } (y_1 - y_2) \quad (4.8)$$

Os resultados podem ser observados na Figura 4.19. É possível observar que apesar do ruído inserido, o sistema foi capaz de corresponder aos critérios da função objetivo, maximizando  $y_1$  e minimizando  $y_2$ .

Em nenhum momento a referência ultrapassou os limites do sistema máximos e mínimos, impostos sobre a camada de otimização.

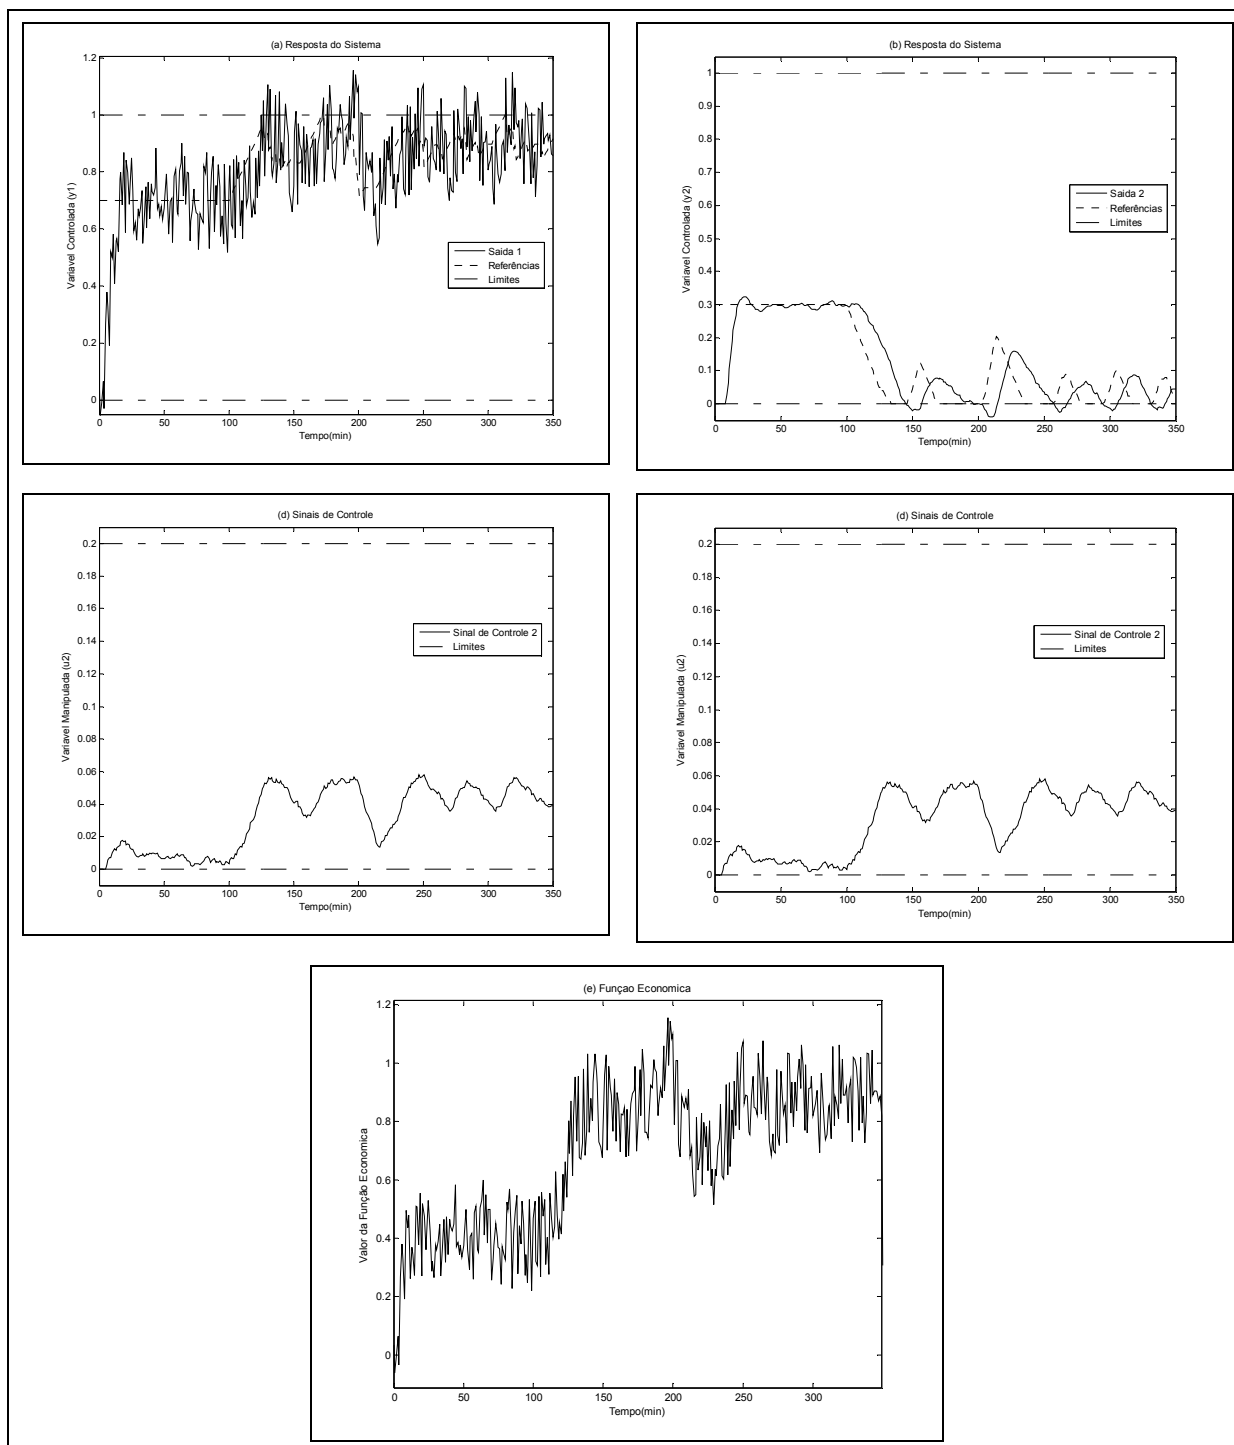


Figura 4.19 - Respostas obtidas para a Função objetivo  $\phi = \text{maximizar } (y_1 - y_2)$  com ruído na variável  $y_1$  para estrutura em duas camada

**4.2.2.6 Objetivo 6:  $\phi = \text{maximizar } (y_1 - y_1^2 + y_2 - y_2^2)$** 

Nesta simulação, utilizou-se a função objetivo econômica conforme a Equação (4.9), que corresponde a um função econômica não linear. Esta função não possui sentido físico prático, e foi apenas utilizada para verificar o comportamento do modelo de otimização em duas camadas, quando submetido a uma função não-linear.

$$\phi = \text{maximizar } (y_1 - y_1^2 + y_2 - y_2^2) \quad (4.9)$$

Os resultados podem ser observados na Figura 4.20. É possível perceber que a referência ( $y_{set}$ ) calculada na camada de otimização, não é estável, oscilando entre os valores máximos e mínimos permitidos. Como consequência, as variáveis controladas  $y_1$  e  $y_2$  oscilam buscando acompanhar os sinais de referência.

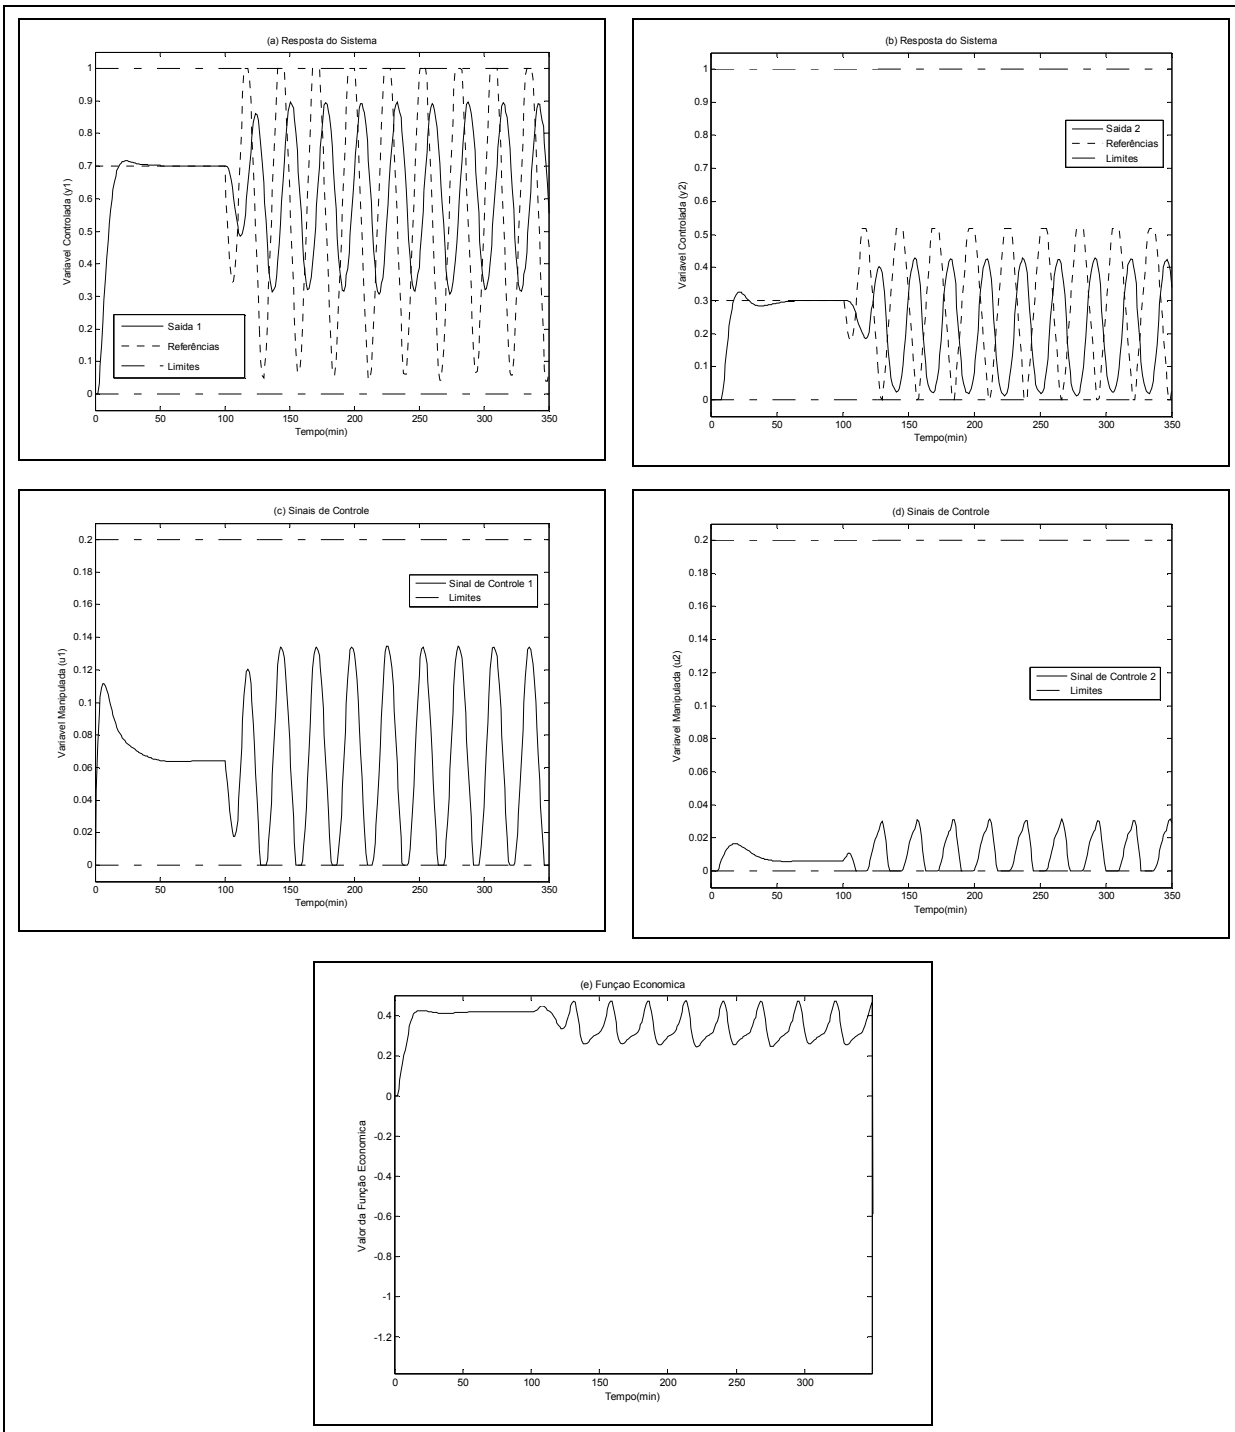


Figura 4.20 - Respostas obtidas para a Função objetivo  $\phi = \text{maximizar } (y_1 - y_1^2 + y_2 - y_2^2)$  para estrutura em duas camadas

Em uma tentativa de se solucionar os problemas de oscilação, os parâmetros de ajuste da camada de controle foram alterados, de modo a se obter uma movimentação mais

suave das ações de controle. As modificações ocorreram sobre o parâmetro  $\lambda$ , que passou a assumir o valor de  $\lambda=[50, 60]$ .

Também foram limitadas as ações da camada de otimização que diferem dos anteriores valores de  $\Delta y_{set}^{\max}$  e  $\Delta y_{set}^{\min}$ , assumindo agora 0.01 e  $-0.01$  respectivamente.

Os resultados são mostrados na Figura 4.21. O sistema apresentou uma oscilação de amplitude menor, porém não foi possível atingir um ponto de estabilização.

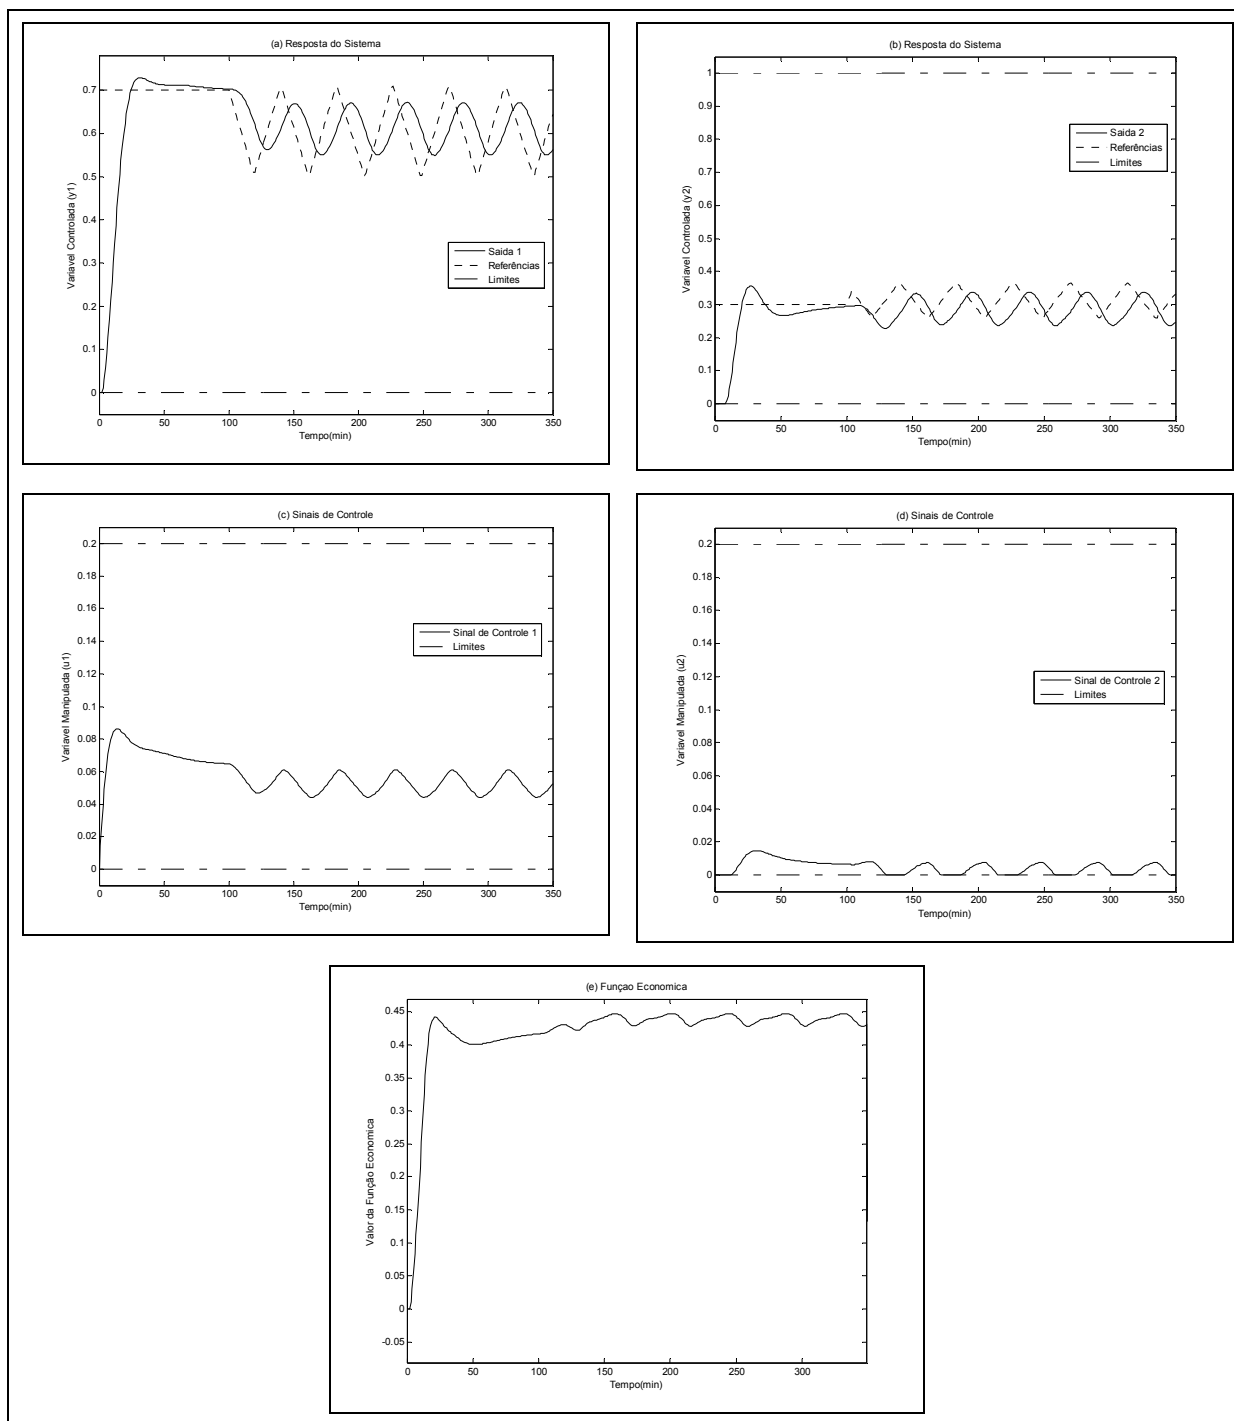


Figura 4.21 - Respostas obtidas para a Função objetivo  $\phi = \text{maximizar } (y_1 - y_1^2 + y_2 - y_2^2)$  para estrutura em duas camada, com modificações dos ajustes

### 4.2.3 OTIMIZAÇÃO EM UMA CAMADA

Após a avaliação do método de otimização em duas camadas na coluna de destilação Wood-Berry, uma segunda abordagem de otimização, conhecida como otimização em camada única também foi analisada.

Neste método, a função objetivo econômica é adicionada à função objetivo utilizada pelo controlador QDMC, conforme a metodologia apresentada no capítulo 3.

Para a simulação da otimização em uma camada, os limites impostos ao sistema, como também o ajuste do controlador e da camada de otimização foram definidos conforme a Tabela 4.9, Tabela 4.10, Tabela 4.11, e Tabela 4.12.

Variáveis do Processo	Valor Inicial	Valor Máximo	Valor Mínimo
Variável Controlada y1	0	1	0
Variável Controlada y2	0	1	0
Variável Manipulada u1	0	0,2	0
Variável Manipulada u2	0	0,2	0

Tabela 4.9 - Limites máximos e mínimos das variáveis manipuladas e controladas, para otimização em uma camada

Parâmetro	Valor
Np	120
Nu	2
Ny	25
diagonal W [y1; y2]	[1; 0,8]
diagonal λ [y1; y2]	[25; 30]
[W1 W2 W3]	[1 1 1]

Tabela 4.10 - Parâmetros de Ajuste do Controlador e da Otimização em uma camada

Parâmetro	$\Delta y_{set}^{\max}$	$\Delta y_{set}^{\min}$
Saída y1	0,1	-0,1
Saída y2	0,1	-0,1

Tabela 4.11 - Movimentos máximos e mínimos das ações de otimização em uma camada

Parâmetro	$\Delta u^{\max}$	$\Delta u^{\min}$
Entrada u1	0,1	-0,1
Entrada u2	0,1	-0,1

Tabela 4.12 - Movimentos máximos e mínimos das ações de Controle para otimização em uma camada

As simulações seguiram os mesmos procedimentos adotados na análise da otimização em duas camadas, e os mesmos objetivos econômicos. Foram simuladas, portanto, funções lineares e não-lineares, além da verificação do comportamento do sistema frente a perturbações e ruídos.

Como as funções econômicas utilizadas nas simulações das duas metodologias de otimização são as mesmas, foi possível realizar comparações entre as duas abordagens conforme será apresentado.

#### 4.2.3.1 Objetivo 1: $\phi = \text{maximizar } (y_1 - y_2)$

A primeira análise é realizada com a utilização de uma função objetivo econômica que consiste na maximização da variável controlada  $y_1$  e da minimização da variável controlada  $y_2$ , novamente representada na Equação (4.10).

$$\phi = \text{maximizar } (y_1 - y_2) \quad (4.10)$$

As respostas apresentadas na Figura 4.22, mostram o desempenho do otimizador em uma camada quando submetido à função econômica apresentada. É possível perceber que a referência movimenta-se de maneira a se obter máximo da função econômica, porém, de modo mais suave que o apresentado pela otimização em duas camadas. Como consequência, as variáveis controladas também apresentam uma movimentação mais suave, com menos oscilação na aproximação do valor determinado pela referência.

O sistema não apresentou erro de estado estacionário, como também, sobre-sinal, e todos os limites foram respeitados.



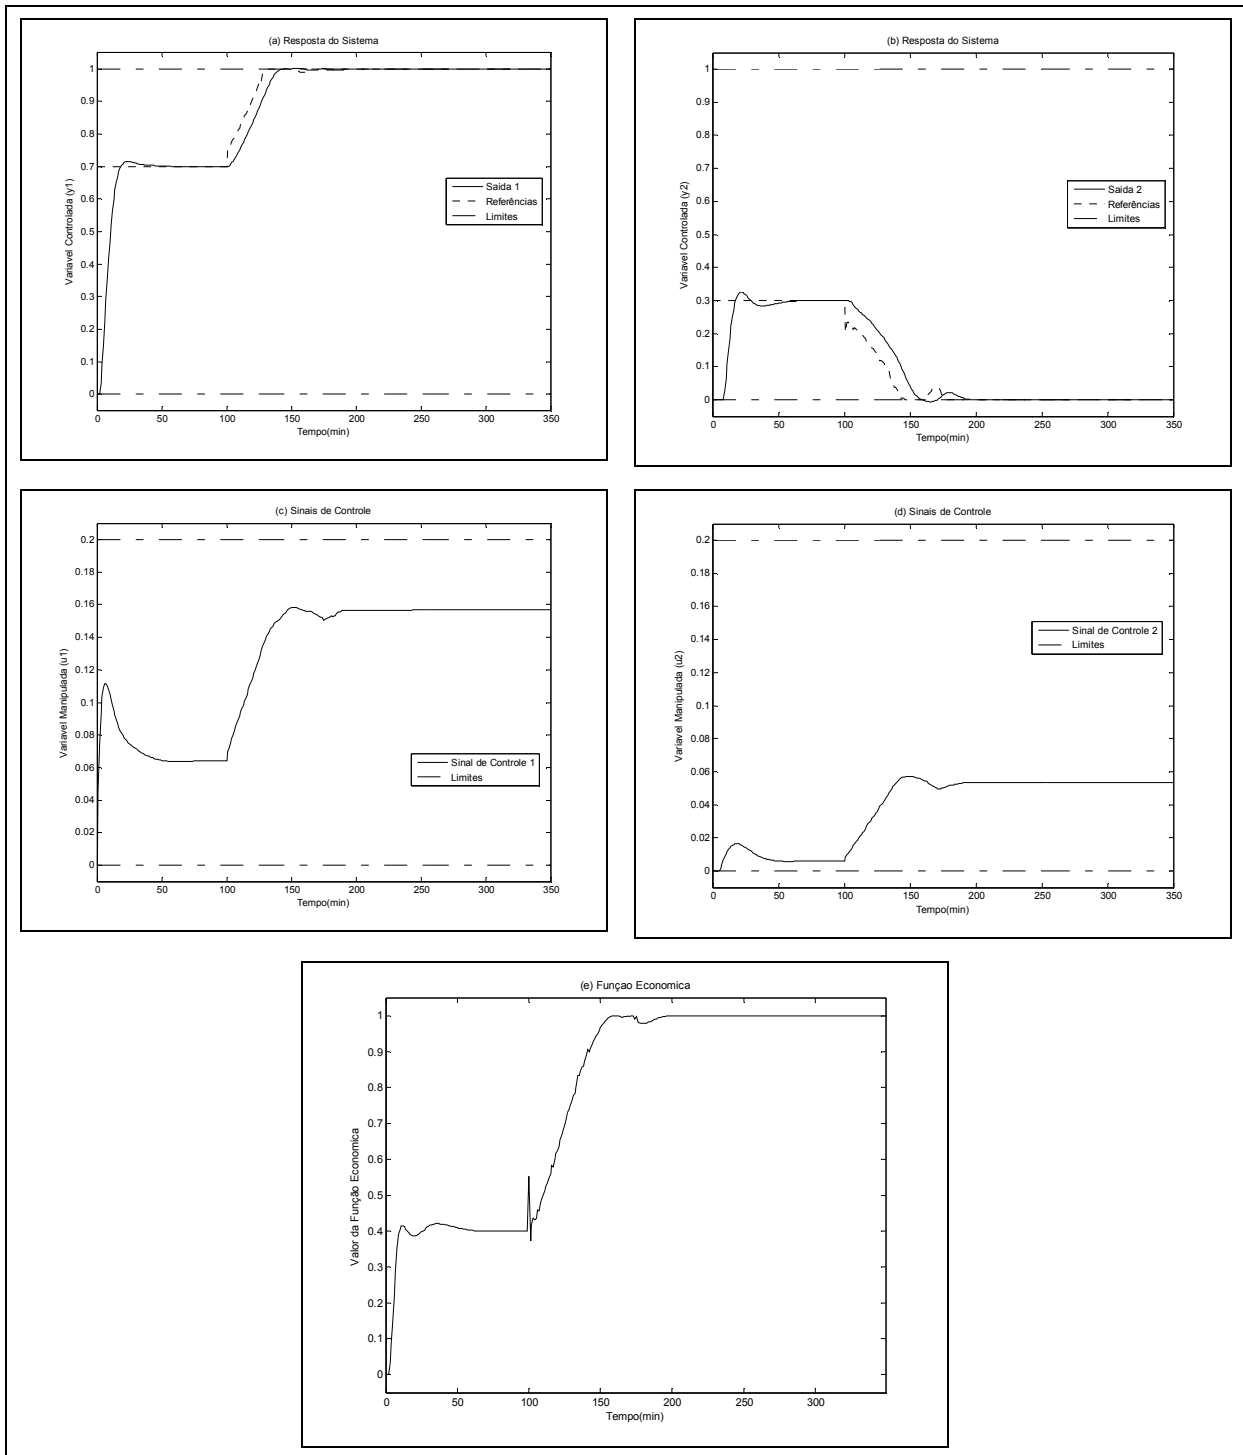


Figura 4.22 - Respostas obtidas para a Função objetivo  $\phi = \text{maximizar } (y_1 - y_2)$  para estrutura em uma camada

**4.2.3.2 Objetivo 2:  $\phi = \text{minimizar } (y_2 - 5u_1)$** 

Como mencionado anteriormente, esta segunda simulação tem como objetivo minimizar uma saída e maximizar uma entrada. Esta função econômica é novamente representada na Equação (4.11).

$$\phi = \text{minimizar } (y_2 - 5u_1) \quad (4.11)$$

Os resultados obtidos são apresentados na Figura 4.23. É possível perceber que a otimização em uma camada interpretou corretamente o objetivo da função econômica. As condições operacionais máximas foram atingidas sem violar as restrições de nenhuma das variáveis.

Com a otimização em uma camada, a referência se movimentou, como no caso anterior, de maneira mais suave que o apresentado pela otimização em duas camadas. As respostas das saídas foram bastante semelhantes entre as duas metodologias de otimização, basicamente apresentado os mesmos valores de sobre-sinal e erro do estado estacionário.

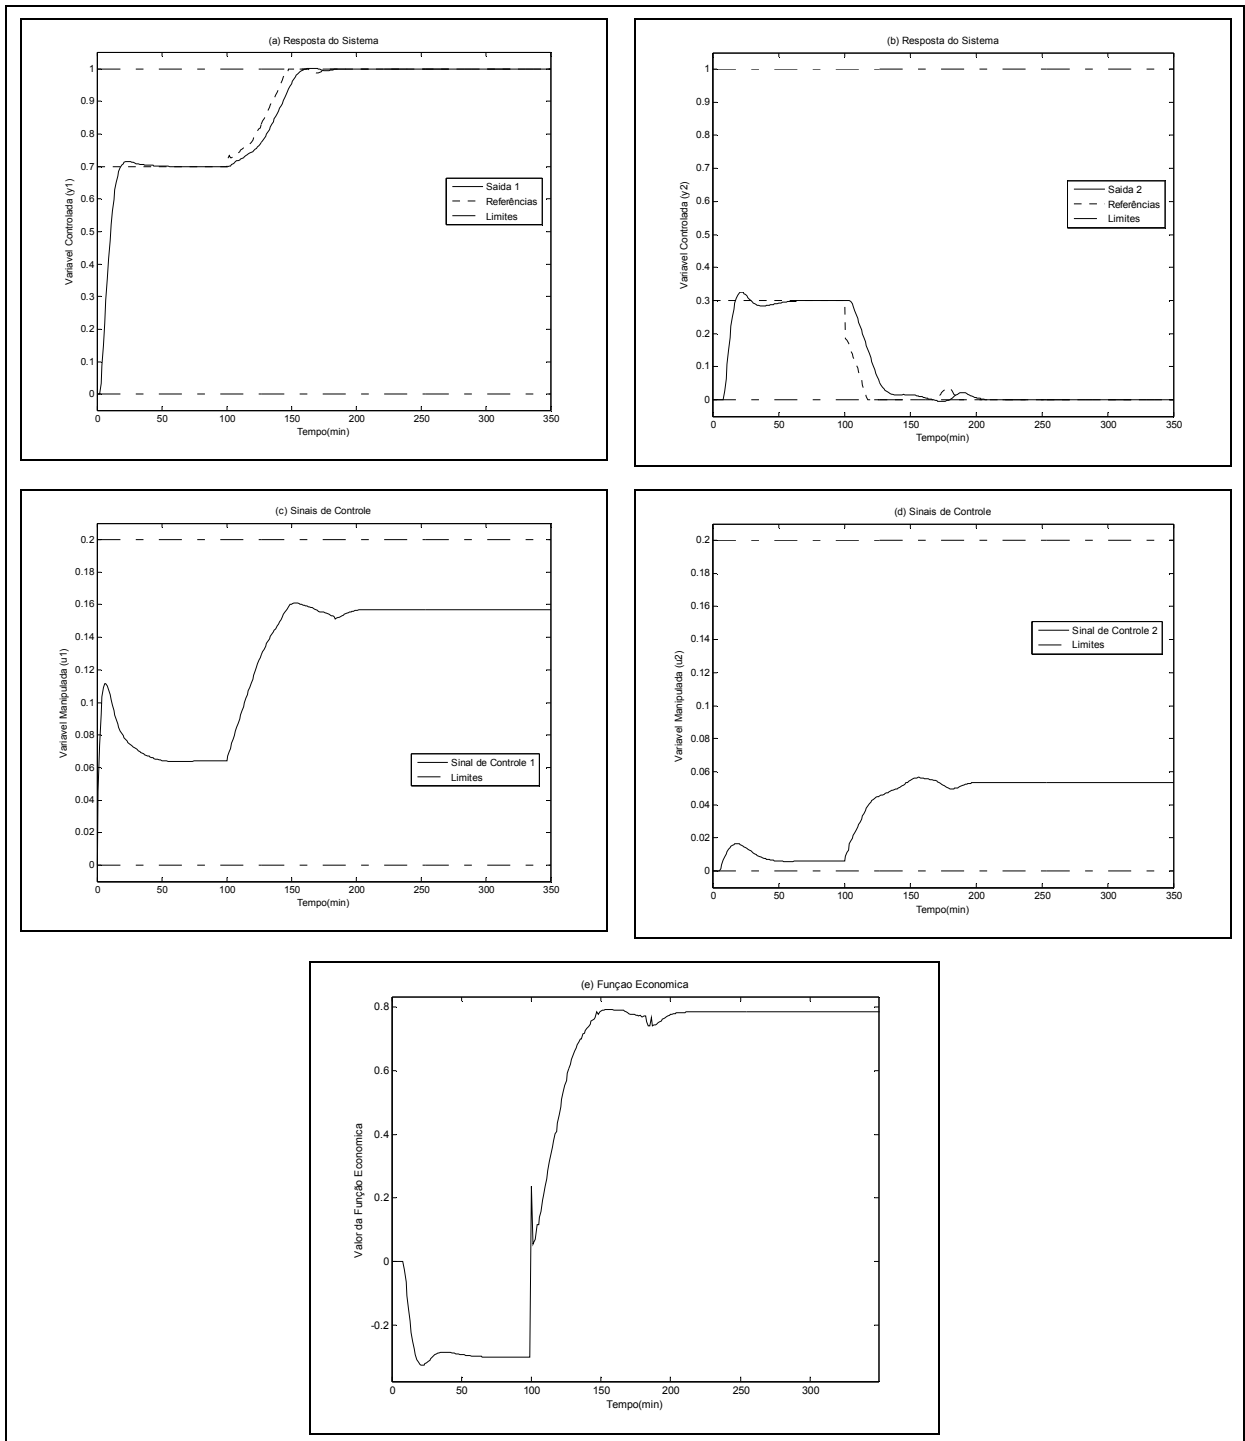


Figura 4.23 - Respostas obtidas para a Função objetivo  $\phi = \text{minimizar } (y_2 - 5u_1)$  para estrutura em uma camada

### 4.2.3.3 Objetivo 3: $\phi = \text{maximizar } (2y_1 - y_2)$

O objetivo desta simulação é maximizar  $y_1$  e minimizar  $y_2$ , considerando um peso maior à variável  $y_1$ , conforme novamente representado na Equação (4.12). Neste caso, o sistema é submetido a uma maior limitação das variáveis manipuladas, conforme utilizado anteriormente e apresentado na Tabela 4.13, de modo que não seja possível levar ambas as saídas até os seus limites.

$$\phi = \text{maximizar } (2y_1 - y_2) \quad (4.12)$$

Variáveis do Processo	Valor Inicial	Valor Máximo	Valor Mínimo
Variável Controlada $y_1$	0	1	0
Variável Controlada $y_2$	0	1	0
Variável Manipulada $u_1$	0	0,1	0
Variável Manipulada $u_2$	0	0,1	0

Tabela 4.13 - Limites máximos e mínimos das variáveis manipuladas e controladas, com modificação dos limites máximos para otimização em uma camada

Os resultados obtidos podem ser observados na Figura 4.24. Analisando as respostas do sistema é possível perceber que a variável  $y_2$  estabilizou em um valor diferente do seu limite mínimo, devido à limitação da variável manipulada  $u_1$ , e da sua menor influência no objetivo econômico. Além disso, a variável  $y_2$  se movimentou de maneira mais suave até o ponto do máximo operacional ( $\phi$ ), ao contrário da otimização em duas camadas, na qual esta variável teve uma movimentação brusca. A variável manipulada  $y_1$  foi maximizada, devido ao fato de possuir uma maior influência na função econômica.

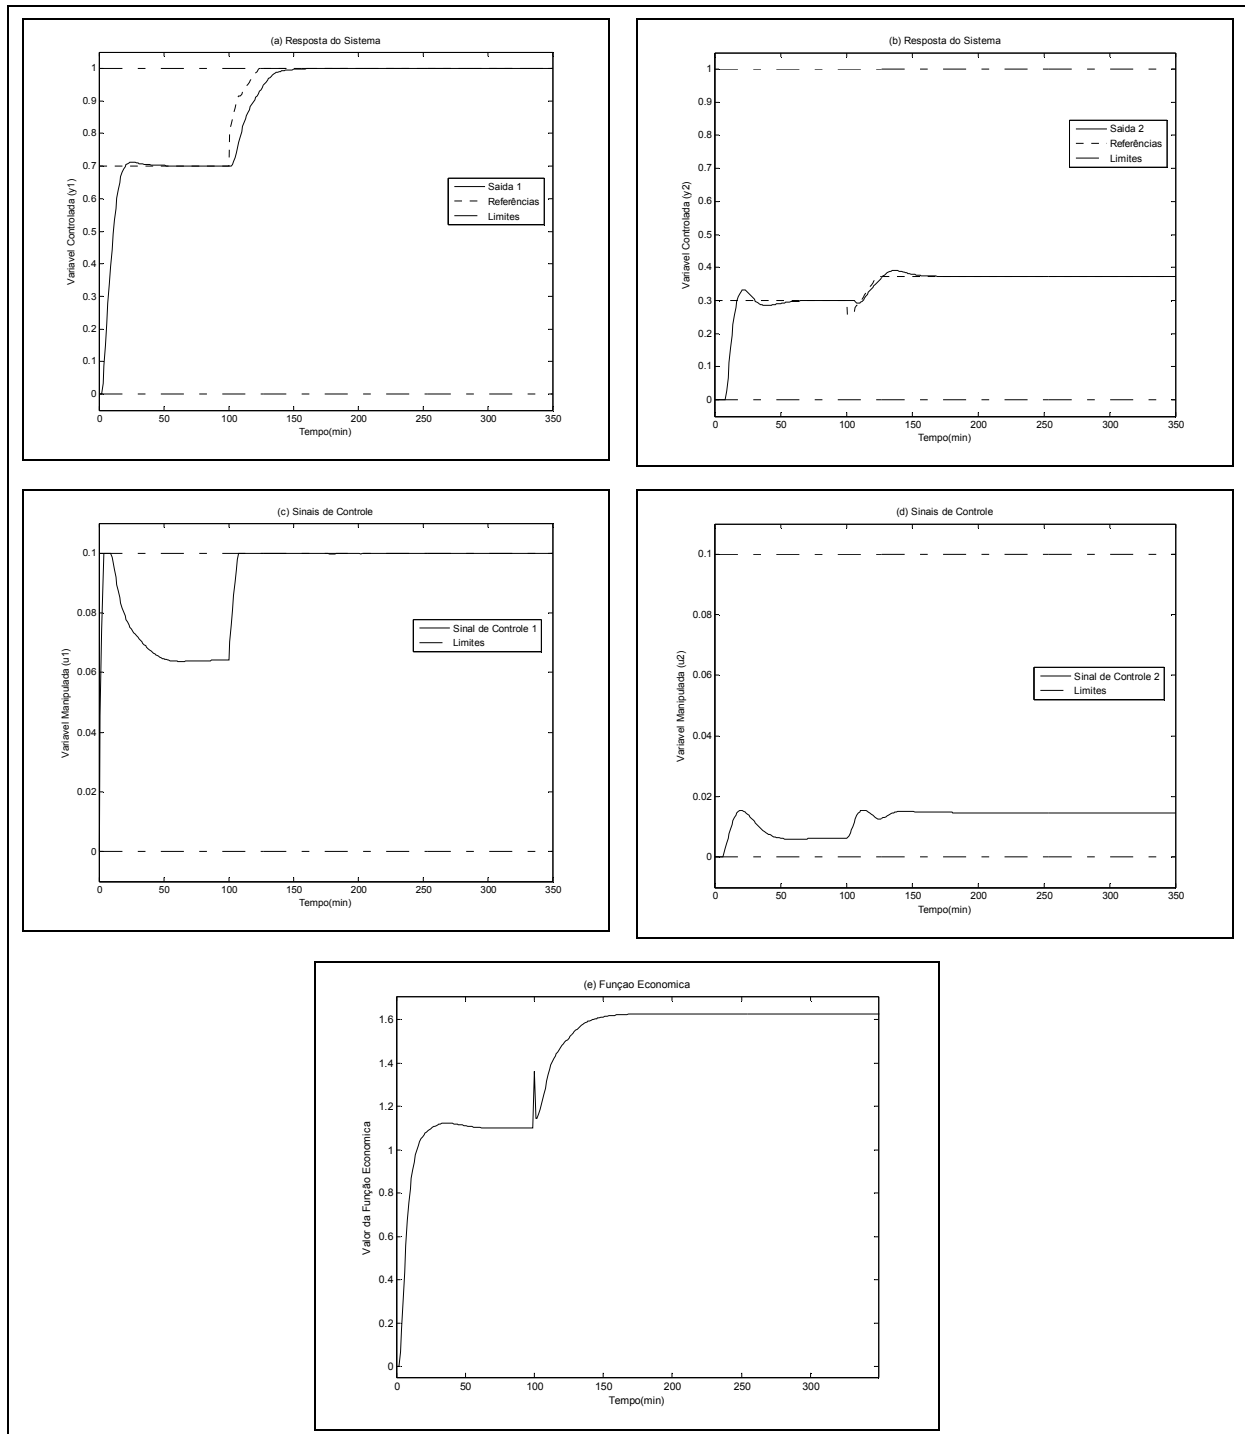


Figura 4.24 - Respostas obtidas para a Função objetivo  $\phi = \text{maximizar } (2y_1 - y_2)$  com diminuição do limite máximo das variáveis manipuladas para estrutura em uma camada

#### 4.2.3.4 Objetivo 4: $\phi = \text{maximizar } (y_1 - y_2)$ com perturbação

Nesta simulação, buscou-se verificar se a otimização em uma camada é capaz de levar o sistema para o seu máximo operacional, definido pela Equação (4.14), mesmo quando submetida a mesma seqüência de perturbações utilizada anteriormente, como apresentado pelas Equações (4.13) e Figura 4.25e Figura 4.26.

$$\begin{bmatrix} y_1(s) \\ y_2(s) \end{bmatrix} = \begin{bmatrix} \frac{12,8e^{-s}}{16,7s+1} & \frac{-18,9e^{-3s}}{21,0s+1} \\ \frac{6,6e^{-7s}}{10,9s+1} & \frac{-19,4e^{-3s}}{14,4s+1} \end{bmatrix} * \begin{bmatrix} u_1(s) \\ u_2(s) \end{bmatrix} + \begin{bmatrix} \frac{3,8e^{-8,1s}}{14,9s+1} \\ \frac{4,9e^{-3,4s}}{13,2s+1} \end{bmatrix} * p(s) \quad (4.13)$$




Figura 4.25 - Alterações nos valores de  $p(s)$  – Otimização em uma camada




Figura 4.26 – Influência da perturbação sobre  $y_1$  e  $y_2$  – Otimização em uma camada

$$\phi = \text{maximizar } (y_1 - y_2) \quad (4.14)$$

A Figura 4.27 mostra os resultados obtidos, que foram bastante diferentes às respostas apresentadas pela otimização em duas camadas.

É possível verificar que, a cada mudança no valor de amplitude da perturbação, os limites são ultrapassados e, conseqüentemente, a camada de otimização manipula os valores de referência trazendo as saídas para dentro de suas regiões de operação, para então se voltar novamente ao objetivo econômico. As respostas foram mais suaves e não apresentaram as grandes oscilações ocorridas na otimização em duas camadas.

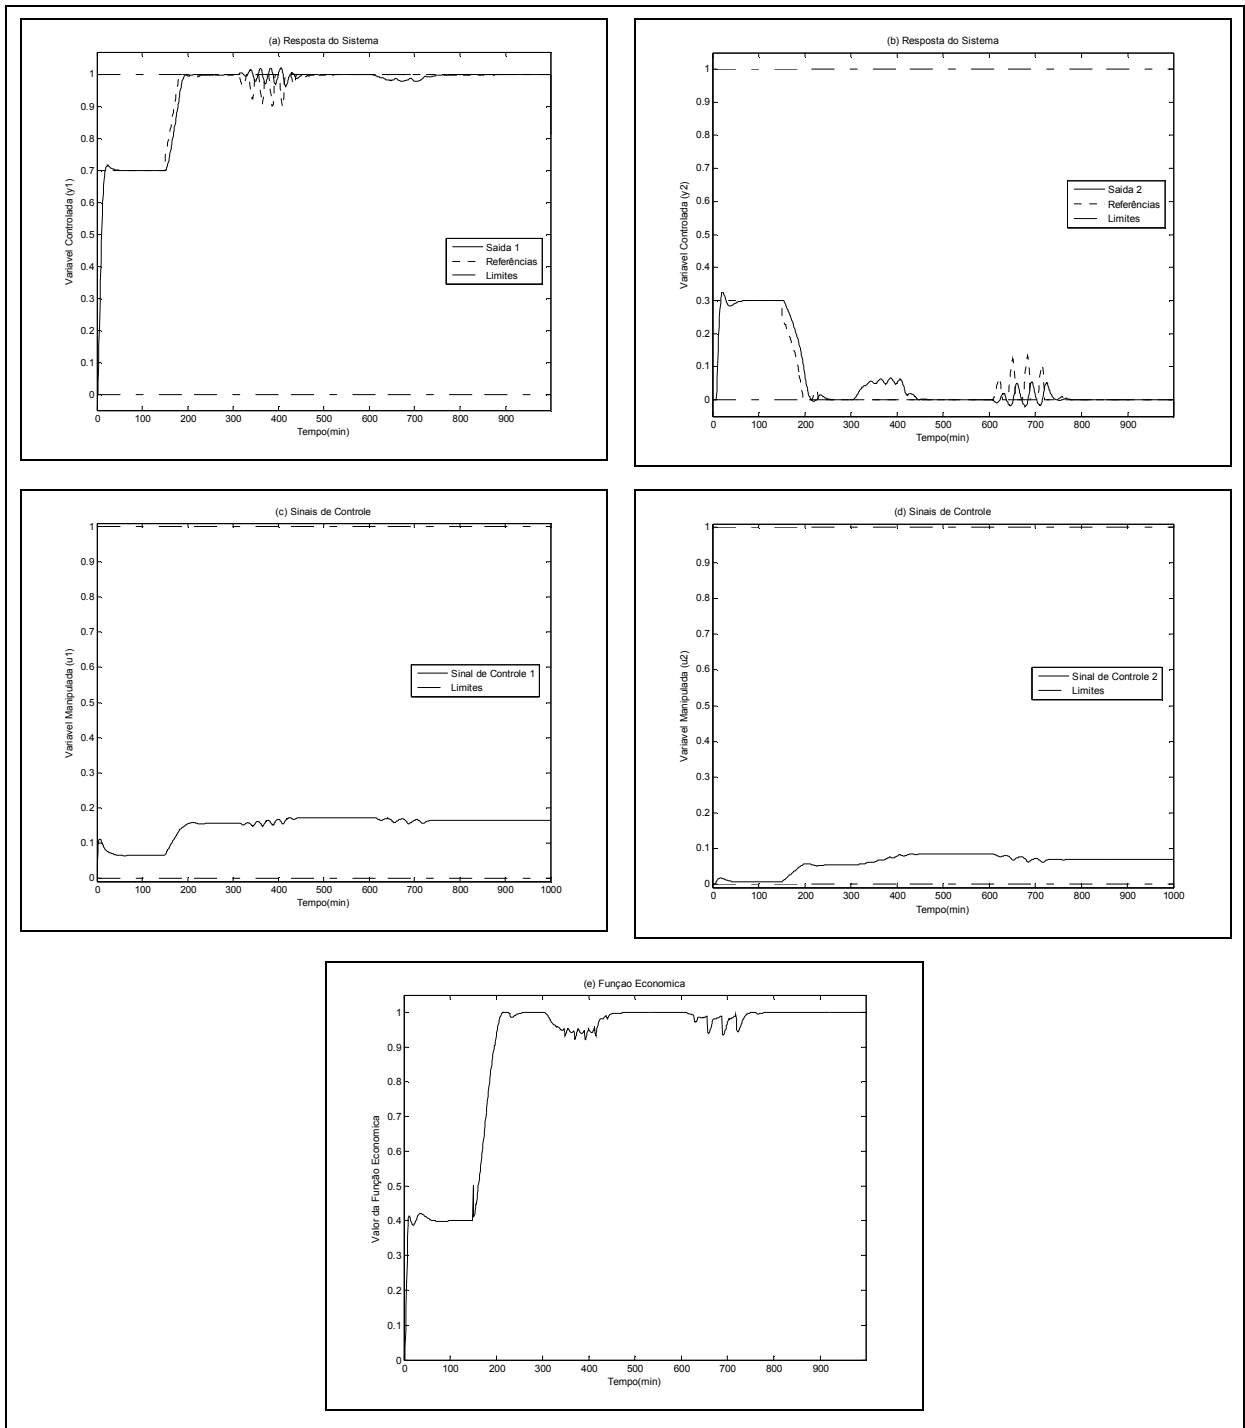


Figura 4.27 - Respostas obtidas para a Função objetivo  $\phi = \text{maximizar } (y_1 - y_2)$  com perturbação na variável  $y_1$  para estrutura em uma camada

**4.2.3.5 Objetivo 5:  $\phi$ =maximizar  $(y_1 - y_2)$  com ruído**

O mesmo ruído do tipo gaussiano com variância de 0.01 e média zero, inserido sobre a saída  $y_1$  na otimização em duas camadas, foi adicionado na otimização em uma camada para análise de seu comportamento.

A função objetivo econômica utilizada nesta simulação é novamente representada na Equação (4.15).

$$\phi = \text{maximizar } (y_1 - y_2) \quad (4.15)$$

Os resultados podem ser observados na Figura 4.28. É possível verificar que apesar do nível de ruído, a otimização em uma camada foi capaz de conduzir o sistema ao máximo operacional. A saída  $y_2$  teve um comportamento um pouco menos oscilatório que o apresentado pela otimização em duas camadas. Os limites operacionais impostos para os sinais de referência e para as variáveis manipuladas não foram violados.



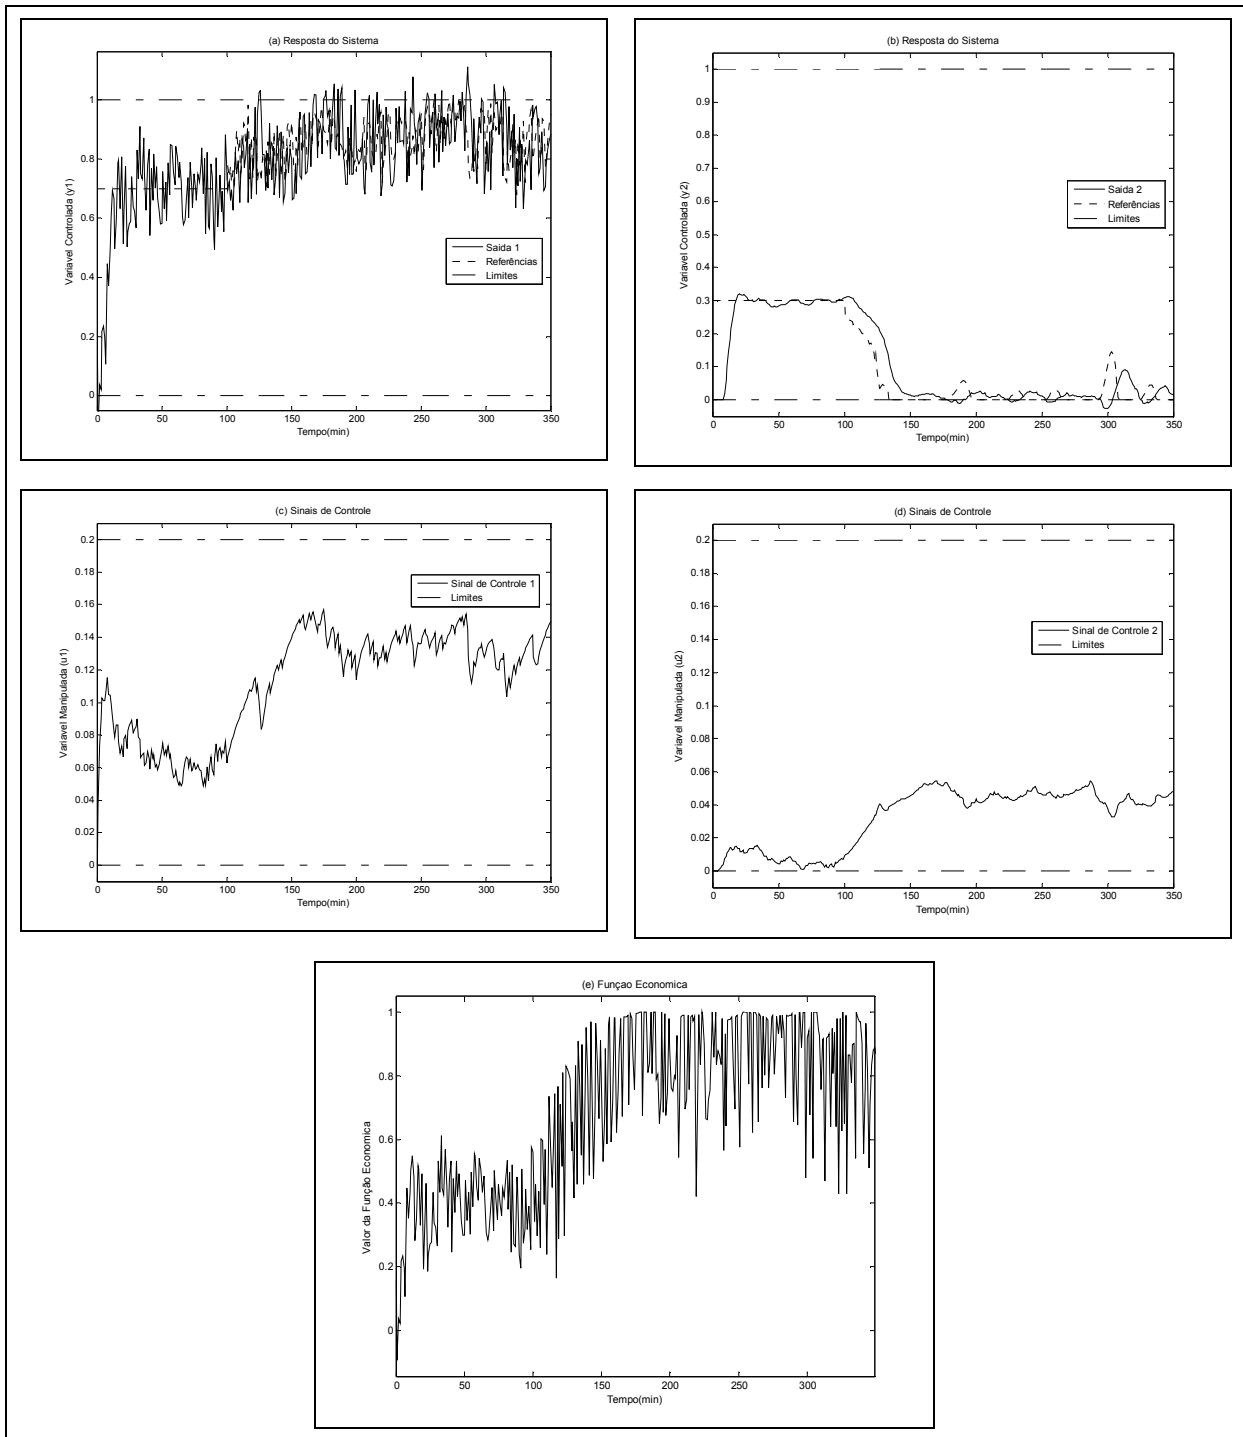


Figura 4.28 - Respostas obtidas para a Função objetivo  $\phi = \text{maximizar } (y_1 - y_2)$  com ruído na variável  $y_1$  para estrutura em uma camada

**4.2.3.6 Objetivo 6:  $\phi = \text{maximizar } (y_1 - y_1^2 + y_2 - y_2^2)$** 

O objetivo desta simulação é a avaliação da metodologia de otimização em uma camada com a maximização de uma função econômica não-linear, novamente apresentada na Equação (4.16). Conforme exposto anteriormente, esta função econômica não representa um aspecto prático deste processo, mas é utilizada apenas para avaliação da metodologia na condição de não linearidade da função objetivo.

$$\phi = \text{maximizar } (y_1 - y_1^2 + y_2 - y_2^2) \quad (4.16)$$

Nesta simulação, os valores de referência inicial foram alterados de 0,8 e 0,2 para  $y_1$  e  $y_2$  respectivamente.

Os resultados são apresentados na Figura 4.29. Ao contrário do verificado com a metodologia de otimização em duas camadas, a otimização em uma camada foi capaz de estabilizar o sistema em um ponto de representação do máximo operacional. As variáveis controladas se deslocaram para os valores de referência ( $y_{set}$ ) sem apresentar erro de estado estacionário, como também, sobre-sinal.

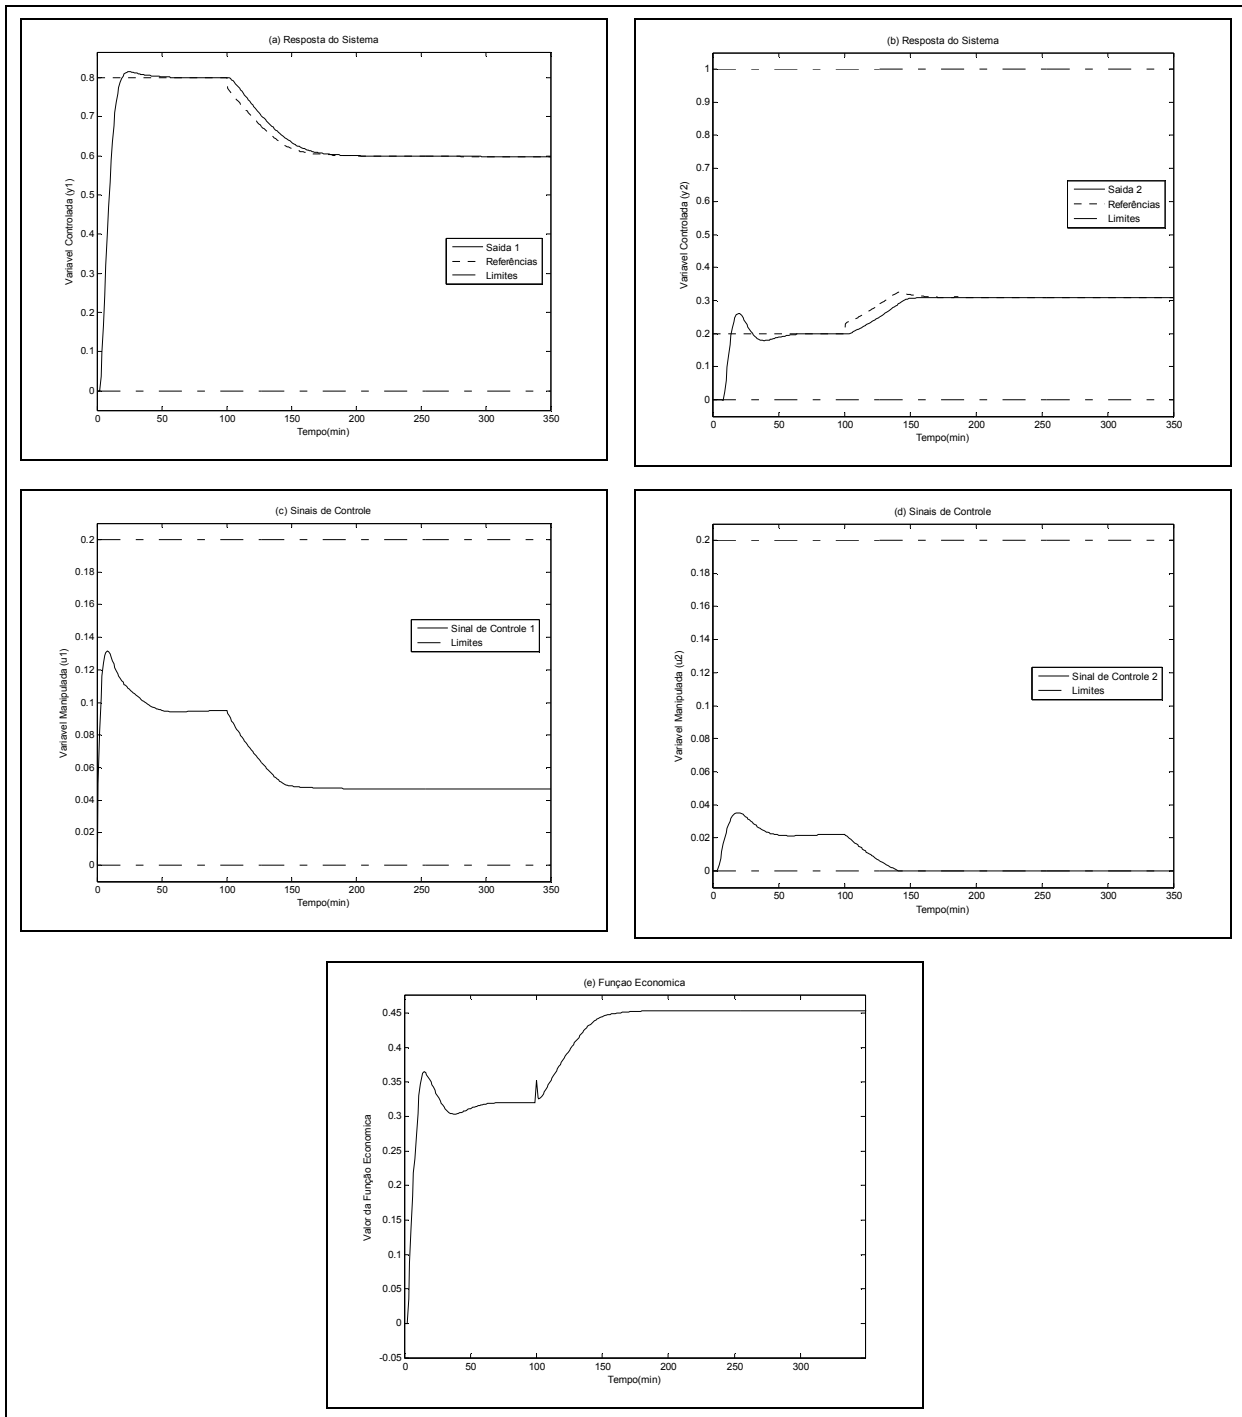


Figura 4.29 Respostas obtidas para a Função objetivo  $\phi = \text{maximizar } (y_1 - y_1^2 + y_2 - y_2^2)$  para estrutura em uma camada

#### 4.2.4 CONCLUSÃO

Realizou-se, para a coluna de destilação Wood-Berry, três etapas de simulação distintas.

A primeira simulação empregou o controlador preditivo QDMC para conduzir as saídas do sistema a valores de referência pré-determinados, analisando-se desta forma, aspectos relacionados ao tempo de resposta, sobre-sinal e erro de estado estacionário. Também foram realizadas simulações com inserção de ruídos e perturbações, constatando-se que o QDMC foi eficiente nas diversas situações apresentadas.

As demais simulações apresentadas consideraram critérios de otimização para a busca do ótimo operacional. As duas abordagens utilizadas foram otimização em duas camadas, e otimização em uma camada.

A otimização em duas camadas demonstrou eficiência nos casos de utilização de funções econômicas lineares, e apresentou robustez frente a ruídos, como também comportamento satisfatório no aumento das restrições dos limites das variáveis manipuladas. Os resultados apresentados mostraram que a otimização em duas camadas não apresentou bom desempenho com a utilização de uma determinada função econômica não linear, pois os valores de referência calculados na camada de otimização apresentaram oscilação, não sendo, portanto, possível atingir, com esta metodologia, estabilização sobre um ponto que representasse o máximo econômico.

Os mesmos testes efetuados com a abordagem de otimização em duas camadas foram aplicados para avaliação da metodologia de otimização em uma camada. Os resultados obtidos foram bastante semelhantes entre as duas técnicas de otimização, porém, a otimização em uma camada demonstrou capacidade de trabalhar com a determinada função econômica não linear empregada, estabilizando o sistema em um ponto de representação do máximo operacional. Quando também da inclusão de perturbações a otimização em uma camada apresentou um resultado superior, onde a resposta teve uma oscilação de amplitude menor, em comparação a otimização em duas camadas,

### 4.3 CRAQUEAMENTO CATALÍTICO EM LEITO FLUIDIZADO

A unidade de Craqueamento Catalítico em Leito Fluidizado tem como função transformar moléculas pesadas de hidrocarbonetos em moléculas mais leves de alto valor agregado, como gasolina e GLP, que são os derivados de petróleo de maior valor econômico (Zanin, 2001).

As simulações do processo FCC foram realizadas utilizando o modelo apresentado no trabalho de Prosdóssimo (2003) que teve como fonte inicial o trabalho de Moro e Odloak (1995).

Prosdóssimo (2003) define as variáveis controladas do FCC, que precisam ser mantidas dentro de determinadas faixas de valores, devido a restrições operacionais ou por questão de segurança, como:

- Temperatura de saída do *riser* ( $Trx$ );
- Inventário do catalisador no vaso separador ( $Hra$ );
- Pressão de sucção do compressor de gás úmido ( $Psuc$ );
- Temperatura de fase densa do segundo estágio do regenerador ( $Trg2$ );
- Pressão diferencial entre o vaso separador e regenerador ( $DPr$ );

As variáveis manipuladas são definidas como apresentado a seguir (PROSDÓSSIMO, 2003):

- Abertura da válvula  $TCV$ : é utilizada para controlar a temperatura do *riser* ( $Trx$ ) através do controle da circulação do catalisador regenerado para este;
- Abertura da válvula  $LCV$ : controla o inventário de catalisador no vaso separador ( $Hra$ );
- Abertura da válvula  $PCV$ : controla a pressão de sucção do compressor de gás úmido ( $Psuc$ );
- Vazão de ar para o regenerador ( $Rai$ ): tem como função controlar a temperatura de fase densa do segundo estágio do regenerador ( $Trg2$ );
- Abertura da válvula  $PdCV$ : controla o diferencial de pressão entre o vaso separador e o regenerador ( $DPr$ ).

A Figura 4.30 mostra a representação da unidade de FCC e as variáveis manipuladas pelo controlador QDMC.

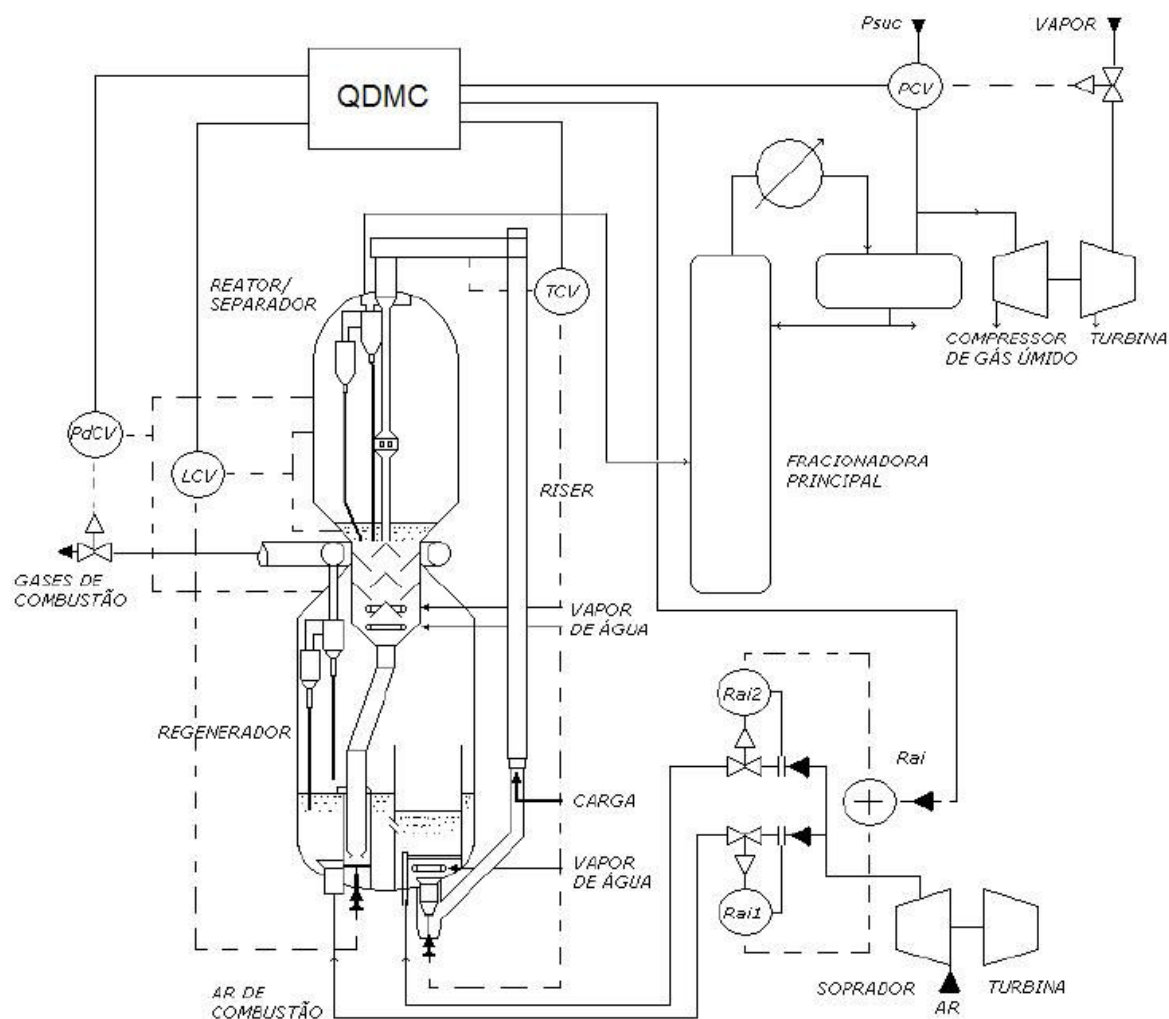


Figura 4.30 - Controlador QDMC ligado ao Modelo de Simulação

O controlador preditivo QDMC calcula diretamente as ações de controle das variáveis manipuladas *TCV* e *Rai*. As demais variáveis são manipuladas através de controle regulatório composto por controladores PI (Proporcional+Integral). Neste caso, o controlador preditivo é responsável por calcular o sinal de referência para os PI's.

Os sinais de referência calculados pelo QDMC são definidos como:

- *setHra*: sinal de referência enviado para o PI-1, o qual é responsável pela manipulação da válvula *LCV*;
- *setPsuc*: sinal de referência enviado para o PI-2, o qual é responsável pela manipulação da válvula *PCV*;

- *setDPr*: sinal de referência enviado para o PI-3, o qual é responsável pela manipulação da válvula *PdCV*.

A Figura 4.31, ilustra a arquitetura do sistema de controle composto pelo controlador preditivo e pelos controladores PI.

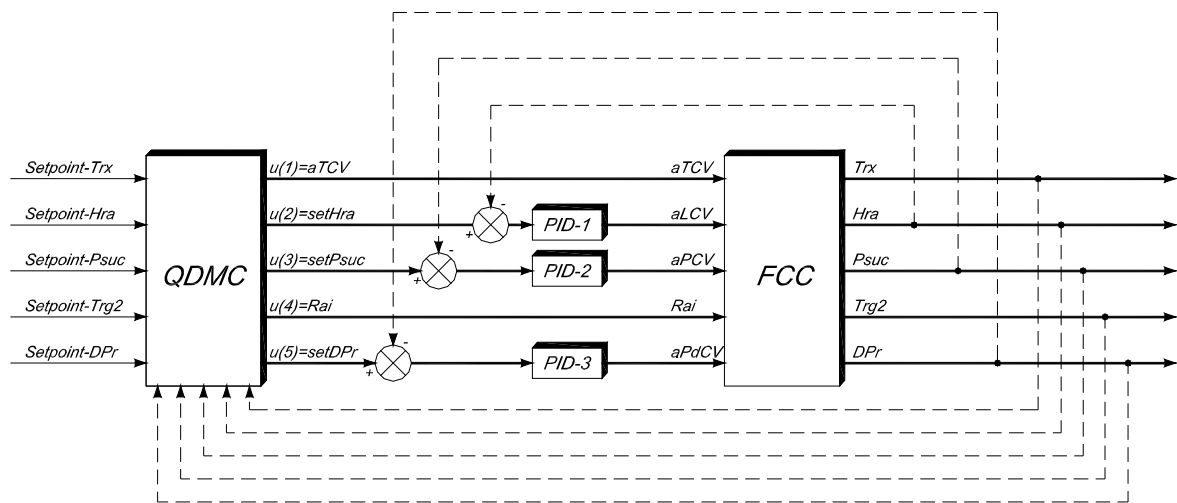


Figura 4.31 – Arquitetura do sistema de controle

O valores das constantes de sintonia  $K_p$  (ganho proporcional),  $T_i$  (tempo integral) e o  $H$  (passo de Integração) dos controladores PI, foram definidos conforme Melo Jr. (2003), os quais são apresentados na Tabela 4.14.

Variável Controlada	$H$	$K_p$	$T_i$
Inventário de catalisador no reator - Hra (PI-1)	0,16	-0,04	0,2
Pressão no compressor de gás úmido - Psuc (PI-2)	0,01	-0,8	0,16
Diferencial de pressão reator/regenador - DPr (PI-3)	0,15	-0,5	0,33

Tabela 4.14 - Constantes de sintonia dos controladores PI

Maiores detalhes sobre o processo a unidade de FCC podem ser encontrados em Moro e Odloak (1995), Prosdóssimo (2003), Melo Jr. (2003), Gentilin (2004) e Zanin (2001).

### 4.3.1 CONTROLE PREDITIVO QDMC

A primeira etapa de simulação consiste no ajuste do controlador preditivo QDMC desenvolvido para o controle da unidade de Craqueamento Catalítico em Leito Fluidizado.

O processo de sintonia tem como objetivo verificar o ajuste do controlador QDMC, quando submetido a situações diversas de operação, de modo a se analisar o tempo de resposta, sobre sinal e erro de estado estacionário das variáveis, além da robustez frente a perturbações e ruídos.

Os limites das variáveis do processo da unidade de FCC foram definidos como Zanin (2001) e Melo (2003) e são demonstrados conforme Tabela 4.15. Os parâmetros de ajuste do controlador, foram definidos conforme a, Tabela 4.16, e Tabela 4.17.

Variáveis do Processo	Unidade	Valor Inicial	Valor Máximo	Valor Mínimo
Variável Controlada <i>Trx</i>	C°	542.2	545	530
Variável Controlada <i>Hra</i>	ton	90	100	80
Variável Controlada <i>Psuc</i>	kgf/cm <sup>2</sup>	1	1,1	0,9
Variável Controlada <i>Trg2</i>	C°	700,9	708	698
Variável Controlada <i>DPr</i>	kgf/cm <sup>2</sup>	0,65	0,7	0,6
Variável Manipulada <i>TCV</i>	%	82	98	45
Variável Manipulada <i>LCV</i>	%	63	100	0
Variável Manipulada <i>PCV</i>	%	74	0.95	0
Variável Manipulada <i>Rai</i>	ton/h	221	240	180
Variável Manipulada <i>PdCV</i>	%	73	100	0

Tabela 4.15 - Limites máximos e mínimos das variáveis manipuladas e controladas para unidade de FCC

Parâmetro	Valor
<i>Np</i>	150
<i>Nu</i>	2
<i>Ny</i>	25
diagonal <i>W [Trx; Hra; Psuc; Trg2; DPr]</i>	[ 5; 3,5; 19; 0,30; 20]
diagonal <i>λ [Trx; Hra; Psuc; Trg2; DPr]</i>	[ 0,50; 0,40; 4; 0,20; 4,2]

Tabela 4.16 - Parâmetros de ajuste do controlador QDMC para a unidade de FCC

Como mencionado anteriormente, os valores das variáveis de ajuste do controlador QDMC foram obtidos de forma heurística, após análises de diversas simulações, as quais foram escolhidos os ajustes que obtiveram melhores resultados.



<b>Parâmetro</b>	<b>Unidade</b>	$\Delta u^{\max}$	$\Delta u^{\min}$
<i>TCV</i>	%	0,016	-0.0370
<i>setHra</i>	ton	1	-1
<i>setPsuc:</i>	Kgf/cm <sup>2</sup>	0,018	-0.002
<i>Rai</i>	ton/h	1,9	-4.1
<i>setDPr</i>	Kgf/cm <sup>2</sup>	0,005	-0.005

Tabela 4.17 – Movimentos máximos e mínimos das ações de Controle

A unidade de Craqueamento Catalítico em Leito Fluidizado foi submetida a uma seqüência de variações nos valores de referência, com o objetivo de se avaliar as respostas do sistema quando submetido a este tipo de requisição, como também observar a interação entre as variáveis.

As variações nos valores de referência das variáveis controladas utilizadas na unidade de FCC são apresentadas a seguir:

- Temperatura da saída do *riser* (*Trx*).  
Referência inicial: 540° C  
Tempo de 30 minutos: 543° C  
Tempo de 120 minutos: 545° C
- Inventário de catalisador no vaso separador (*Hra*).  
Referência inicial: 90 ton  
Tempo de 80 minutos: 92 ton
- Pressão de sucção do compressor de gás úmido (*Psuc*).  
Referência inicial: 1 kgf/cm<sup>2</sup>  
Tempo de 70 minutos para 0,97 kgf/cm<sup>2</sup>
- Temperatura da fase densa do segundo estágio do regenerador (*Trg2*).  
Referência inicial: 700° C  
Tempo de 30 minutos: 702° C  
Tempo de 120 minutos: 704°
- Pressão diferencial entre o vaso separador e o regenerador (*DPr*).  
Referência inicial: 0,65 kgf/cm<sup>2</sup>  
Tempo de 150 minutos: 0,70 kgf/cm<sup>2</sup>

As respostas da simulação são apresentadas na Figura 4.32, Figura 4.33 e Figura 4.34. Analisando os resultados obtidos, é possível observar o forte acoplamento entre as variáveis do processo, pois quando ocorre uma mudança no valor de referência em uma das variáveis, surge uma oscilação nas demais. Com a atuação do controlador QDMC, a oscilação é compensada, e as saídas condicionadas aos seus respectivos valores de referência.

Com análise das figuras, é possível perceber que nenhuma das variáveis controladas apresentou erro de estado estacionário. Observa-se também que algumas saídas obtiveram um tempo de resposta e de acomodação melhor que outras, além de uma compensação mais rápida das oscilações. Este comportamento é passível de ser modificado através de ajustes nos valores de  $\lambda$  e  $W$ , que podem ser configurados de forma a atribuir maior relevância a uma determinada variável em detrimento de outra, como também podem ser ajustados para obtenção de uma maior robustez contra oscilações, porém com penalização do tempo de resposta.

As válvulas *LCV* e *PdCV*, responsáveis pelo controle de *Hra* e *DPr* respectivamente, apresentam oscilações na ordem da 3<sup>o</sup> casa decimal, e, desta forma, não são sentidas na prática pelos atuadores (PROSDÓSSIMO, 2003).

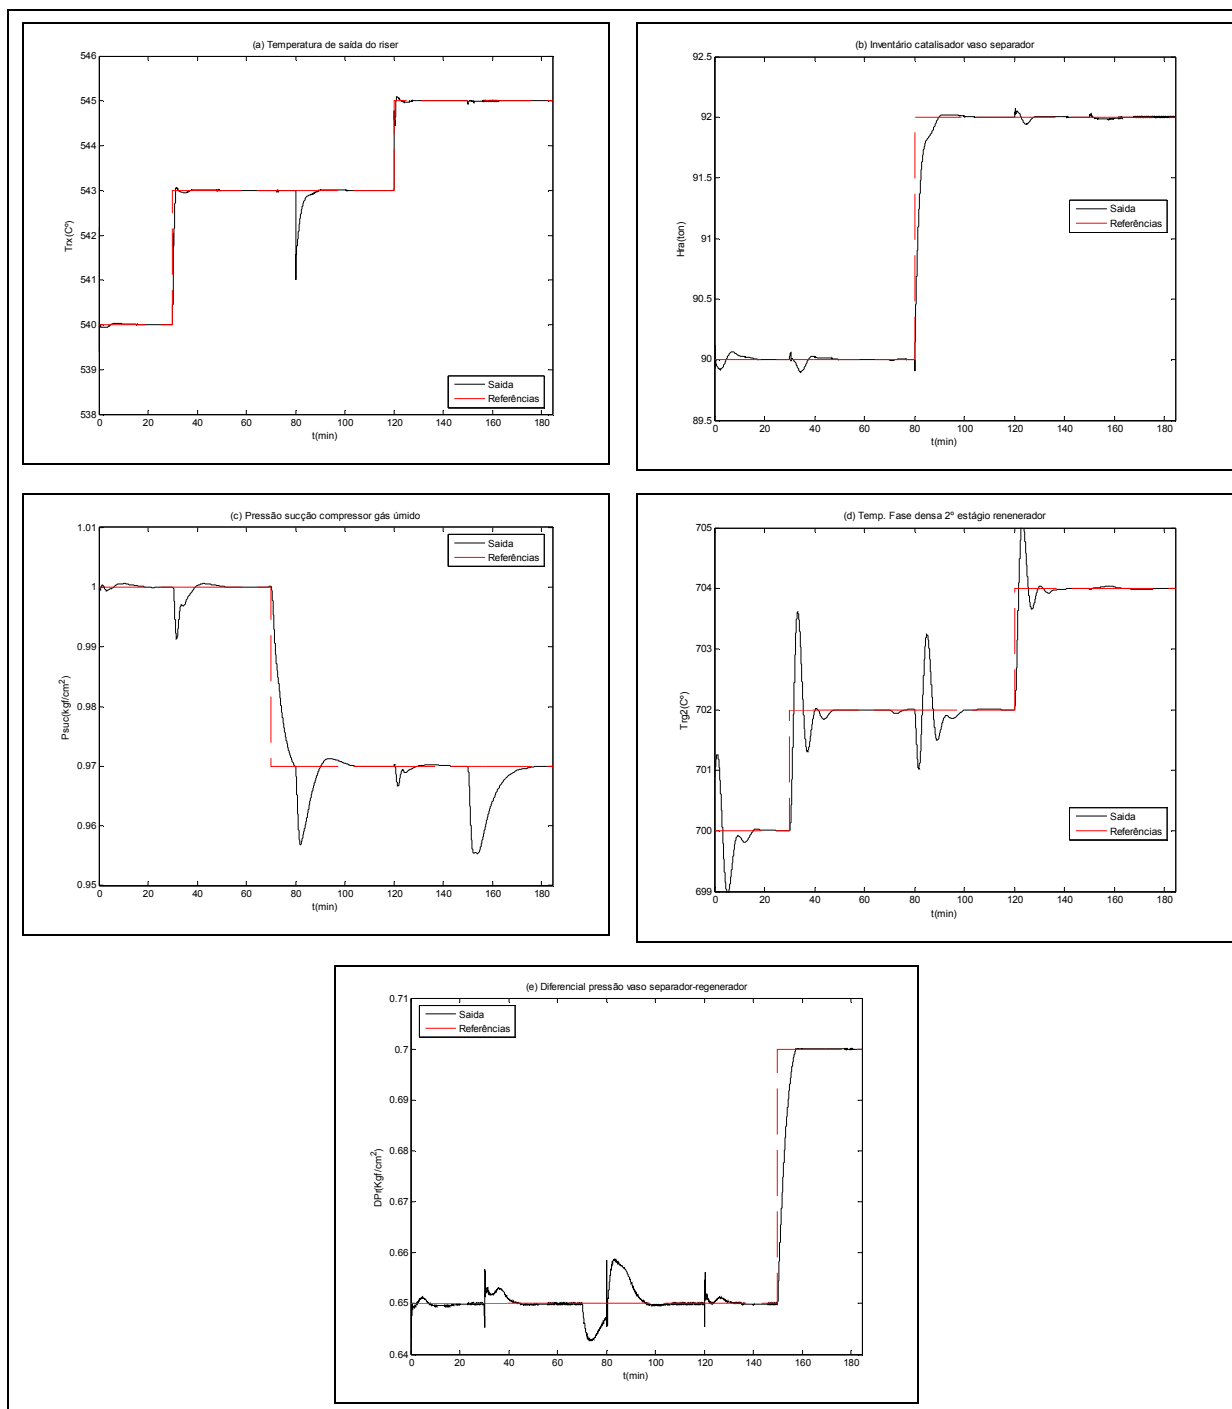


Figura 4.32 – Saídas do FCC - Seqüência de degraus aplicados às saídas da unidade

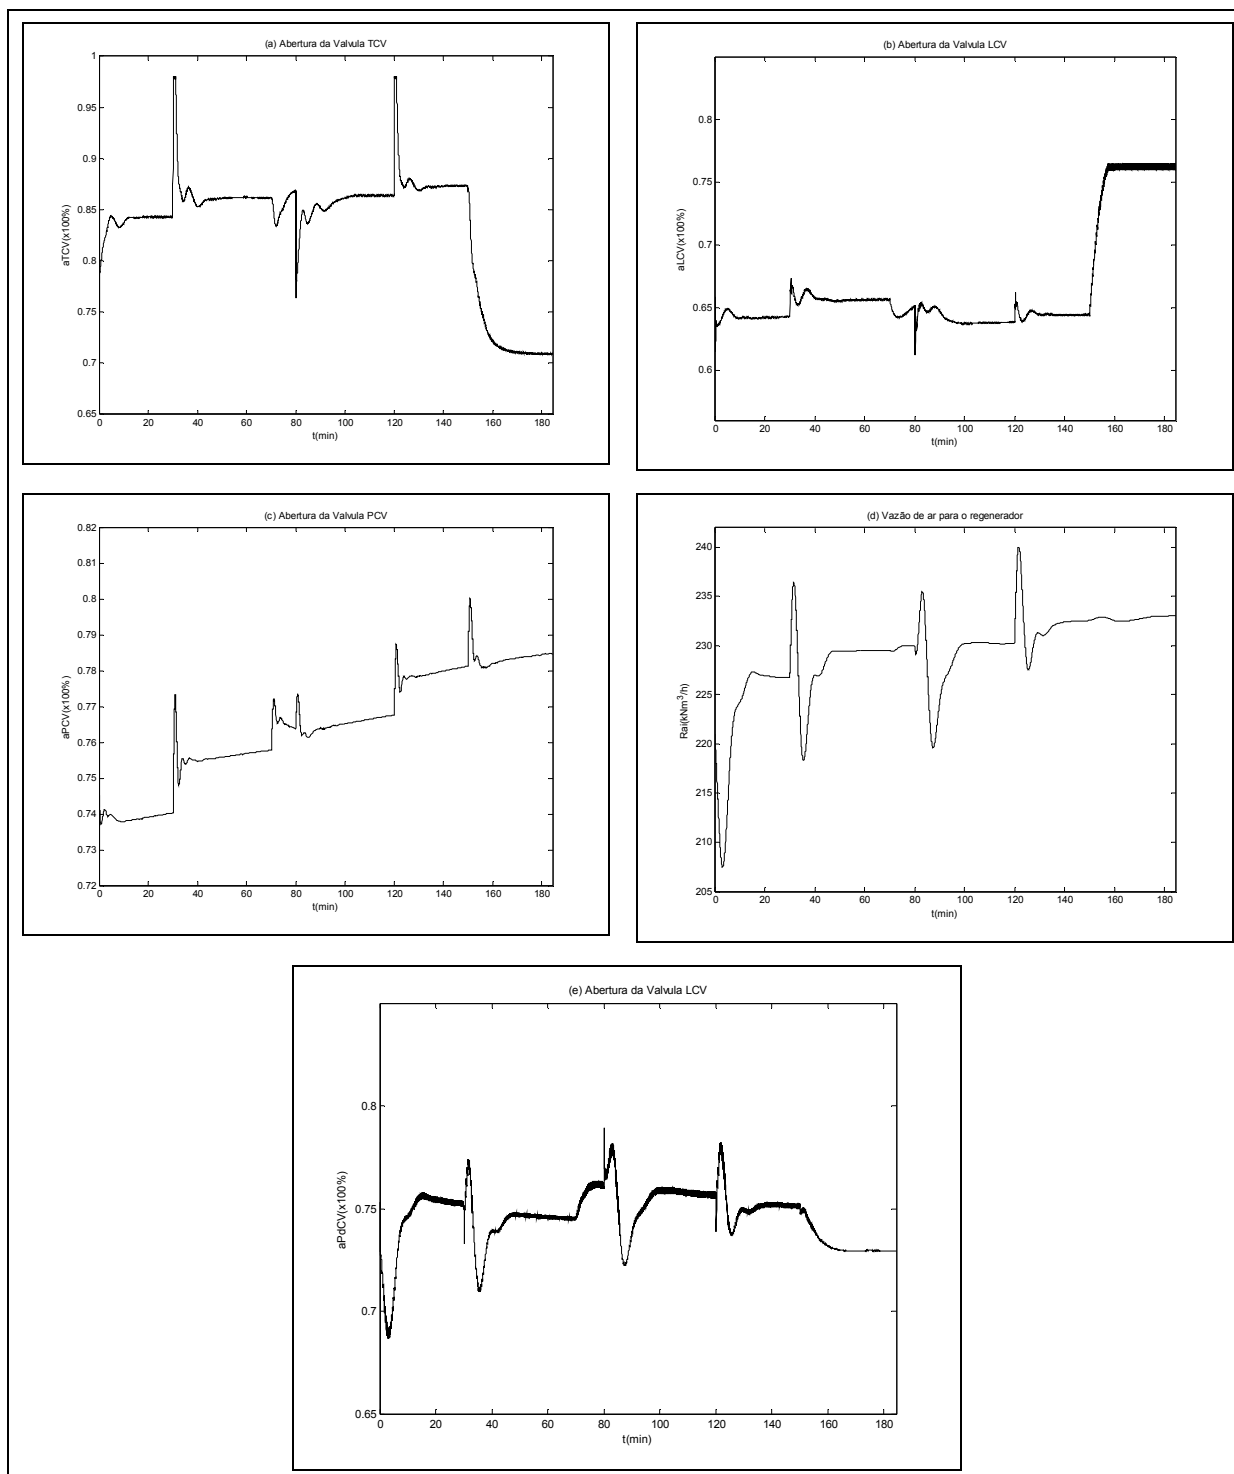


Figura 4.33 – Entradas do FCC - Sequência de degraus aplicados às saídas da unidade

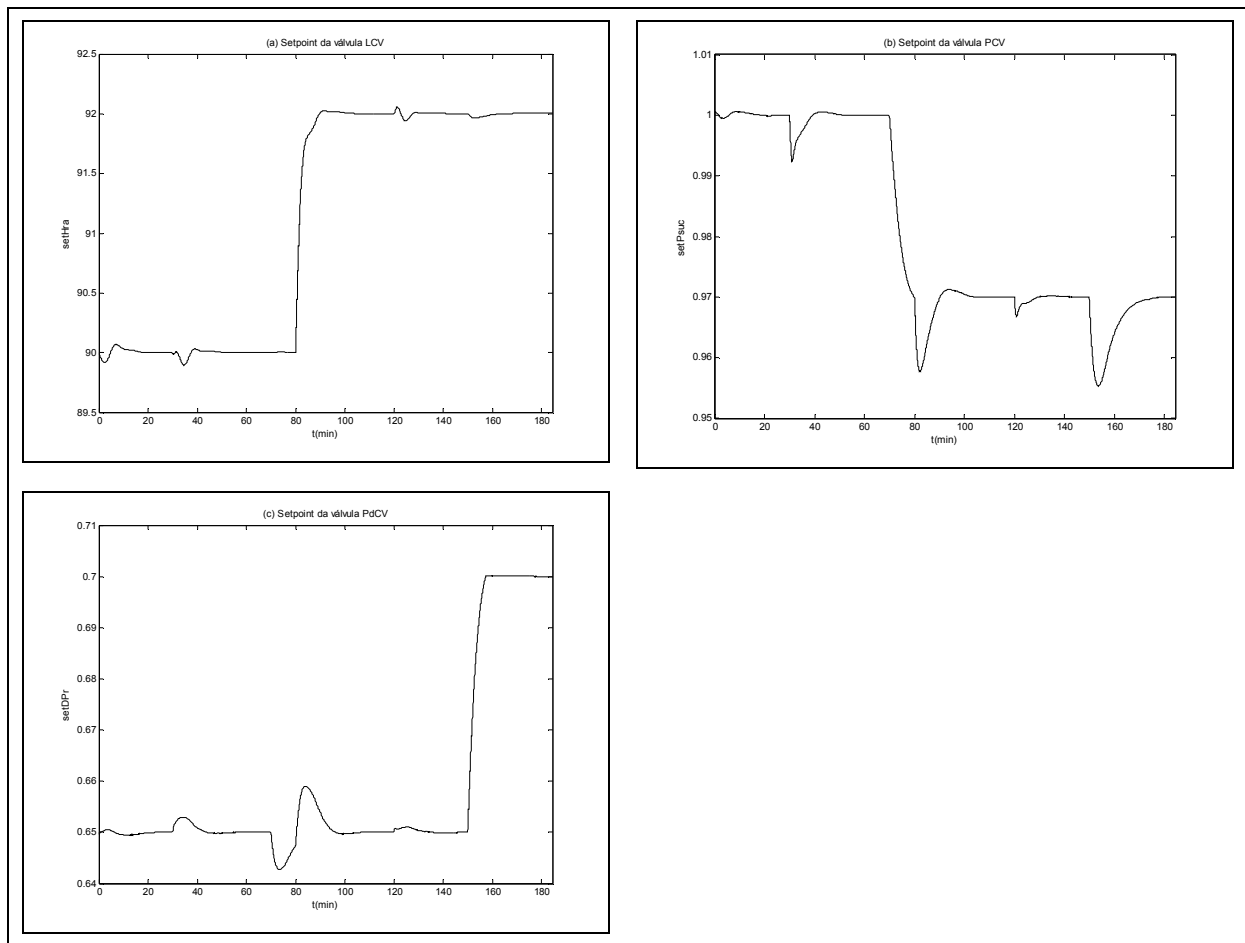


Figura 4.34 – Entradas dos PI's - Seqüência de degraus aplicados as saídas da unidade

Para verificar o comportamento do sistema de controle QDMC frente a perturbações externas, realizaram-se modificações bruscas em duas variáveis não controladas da unidade de FCC, sendo estas, a vazão da Carga ( $R_{tf}$ ) e a temperatura da carga ( $T_{fp}$ ). As perturbações e o respectivo tempo de ocorrência são apresentadas na Figura 4.35.




Figura 4.35 – Perturbações - Variáveis não controladas  $Rf$  e  $Tfp$

Para esta verificação, as referências das saídas foram mantidas constantes como apresentado abaixo:

- Temperatura da saída do *riser* ( $Trx$ ).  
Referência: 540° C
- Inventário de catalisador no vaso separador ( $Hra$ ).  
Referência: 90 ton
- Pressão de sucção do compressor de gás úmido ( $Psuc$ ).  
Referência: 1 kgf/cm<sup>2</sup>
- Temperatura da fase densa do segundo estágio do regenerador ( $Trg2$ ).  
Referência: 700° C
- Pressão diferencial entre o vaso separador e o regenerador ( $DPr$ ).  
Referência: 0,65 kgf/cm<sup>2</sup>

Os resultados obtidos são apresentados na Figura 4.36, Figura 4.37 e Figura 4.38. É possível perceber os efeitos ocasionados pelas perturbações nas entradas e saídas da unidade de FCC, como também nos valores de referência enviados a cada controlador PI.

A cada alteração na amplitude das perturbações, o QDMC modificou os valores das variáveis manipuladas, procurando manter as saídas sobre os respectivos valores de referência. Os erros de estado estacionário são de baixa magnitude, e todas as variáveis ficaram dentro de suas faixas de valores permitidos.

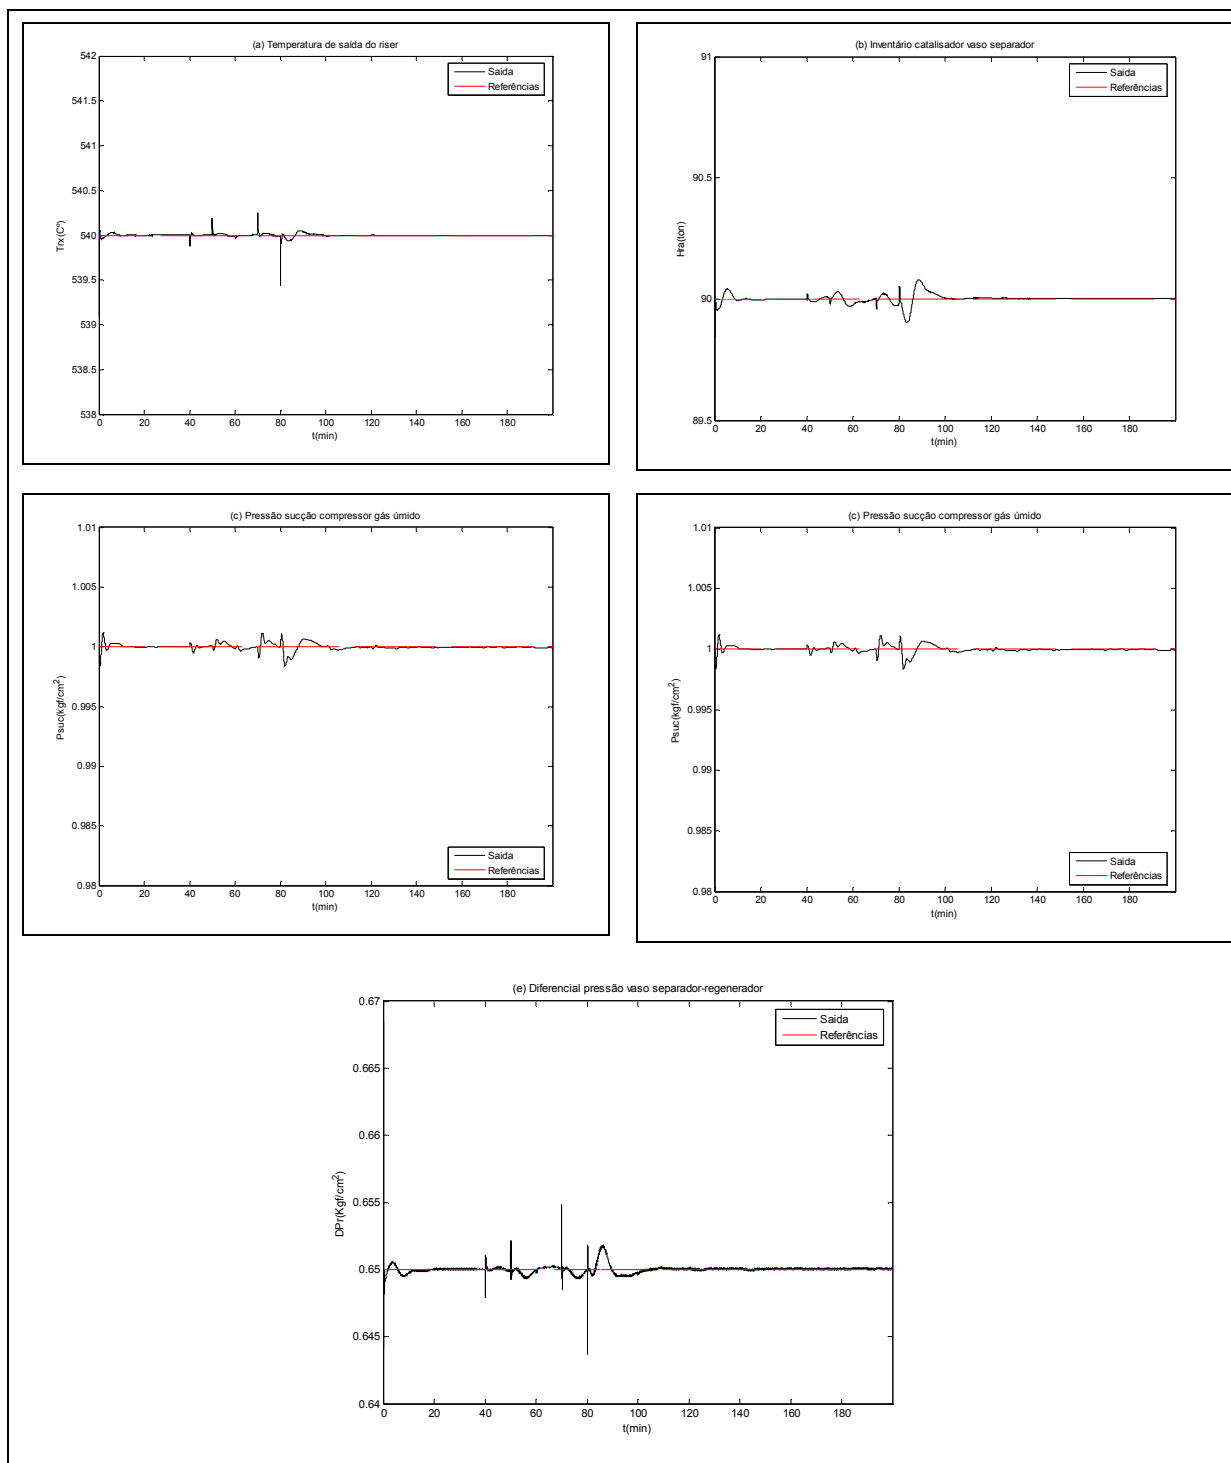


Figura 4.36 – Saídas do FCC – Com perturbações não controladas

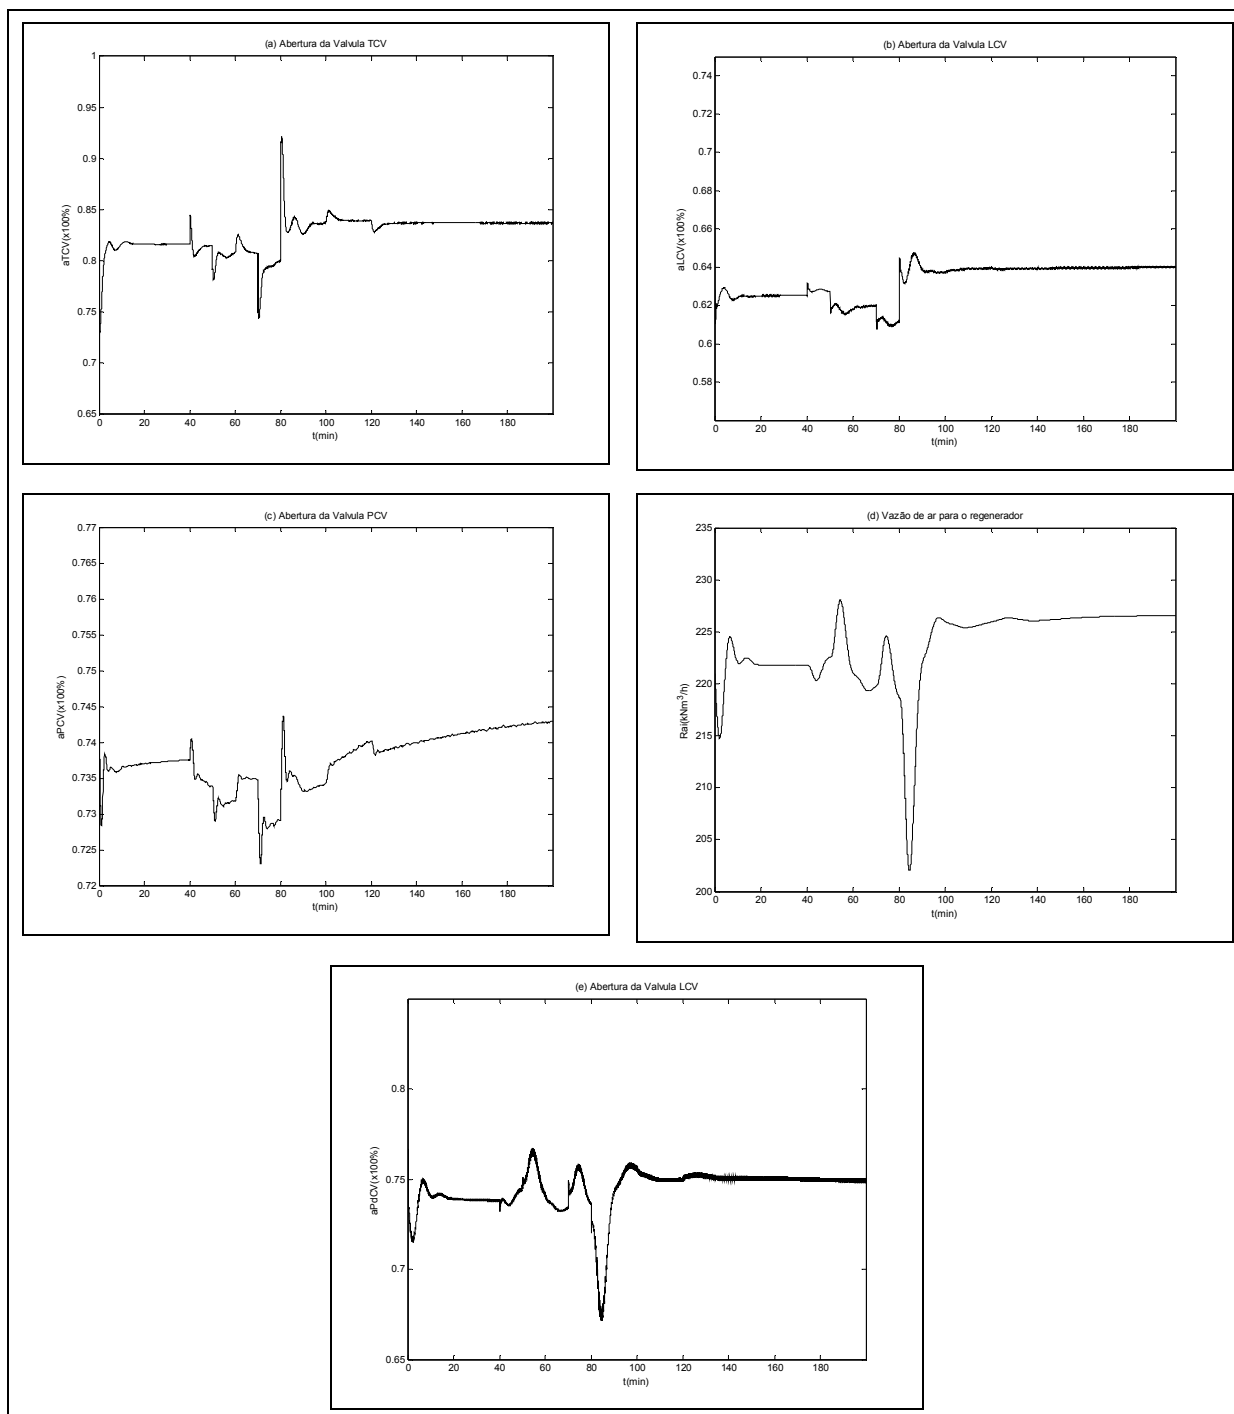


Figura 4.37 – Entradas do FCC - Com perturbações não controladas






Figura 4.38 – Entradas dos PI's - Com perturbações não controladas

Para verificar o desempenho do sistema de controle QDMC frente a ruídos de medição, foi inserido sobre a variável controlada  $Trx$ , um ruído de amplitude variável entre  $[+0,02\%$  e  $-0,02\%$ ] de seu valor de saída.

Para esta simulação, foram utilizados os valores de referência apresentados abaixo:

- Temperatura da saída do *riser* ( $Trx$ ).  
Referência inicial:  $540^{\circ}\text{C}$   
Tempo de 30 minutos:  $543^{\circ}\text{C}$
- Inventário de catalisador no vaso separador ( $Hra$ ).  
Referência: 90 ton
- Pressão de sucção do compressor de gás úmido ( $Psuc$ ).  
Referência:  $1\text{ kgf/cm}^2$
- Temperatura da fase densa do segundo estágio do regenerador ( $Trg2$ ).

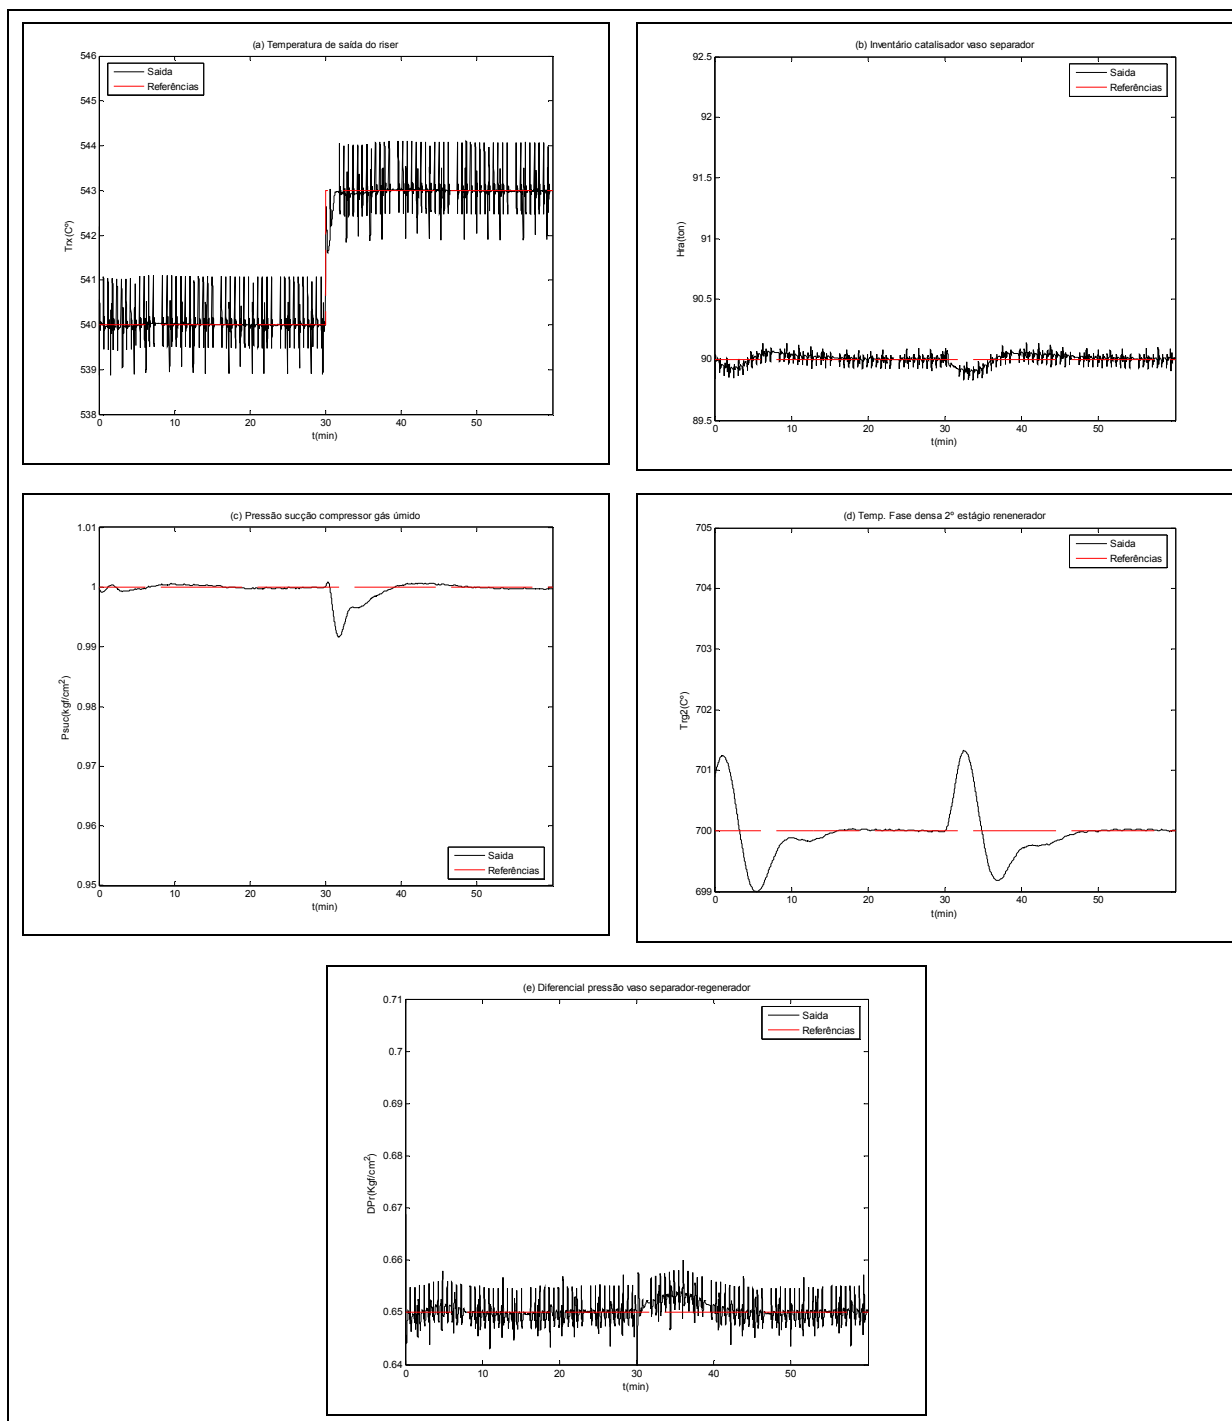
Referência: 700° C

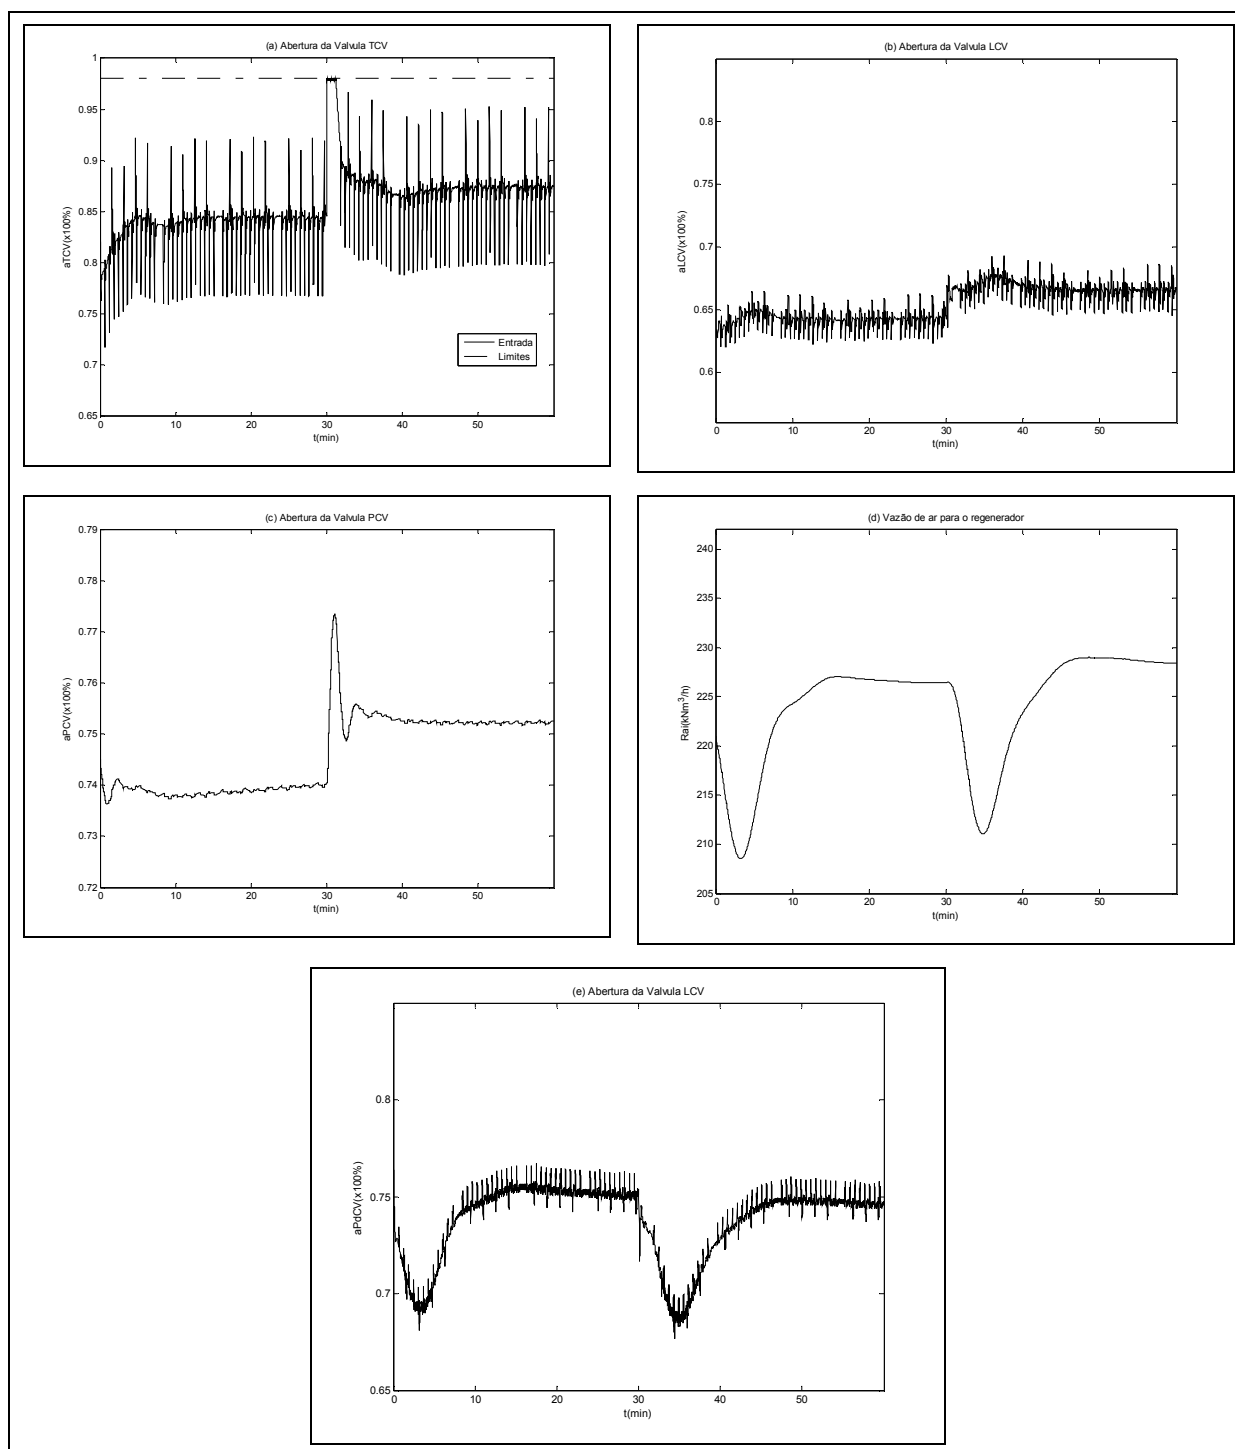
- Pressão diferencial entre o vaso separador e o regenerador ( $DP_r$ ).

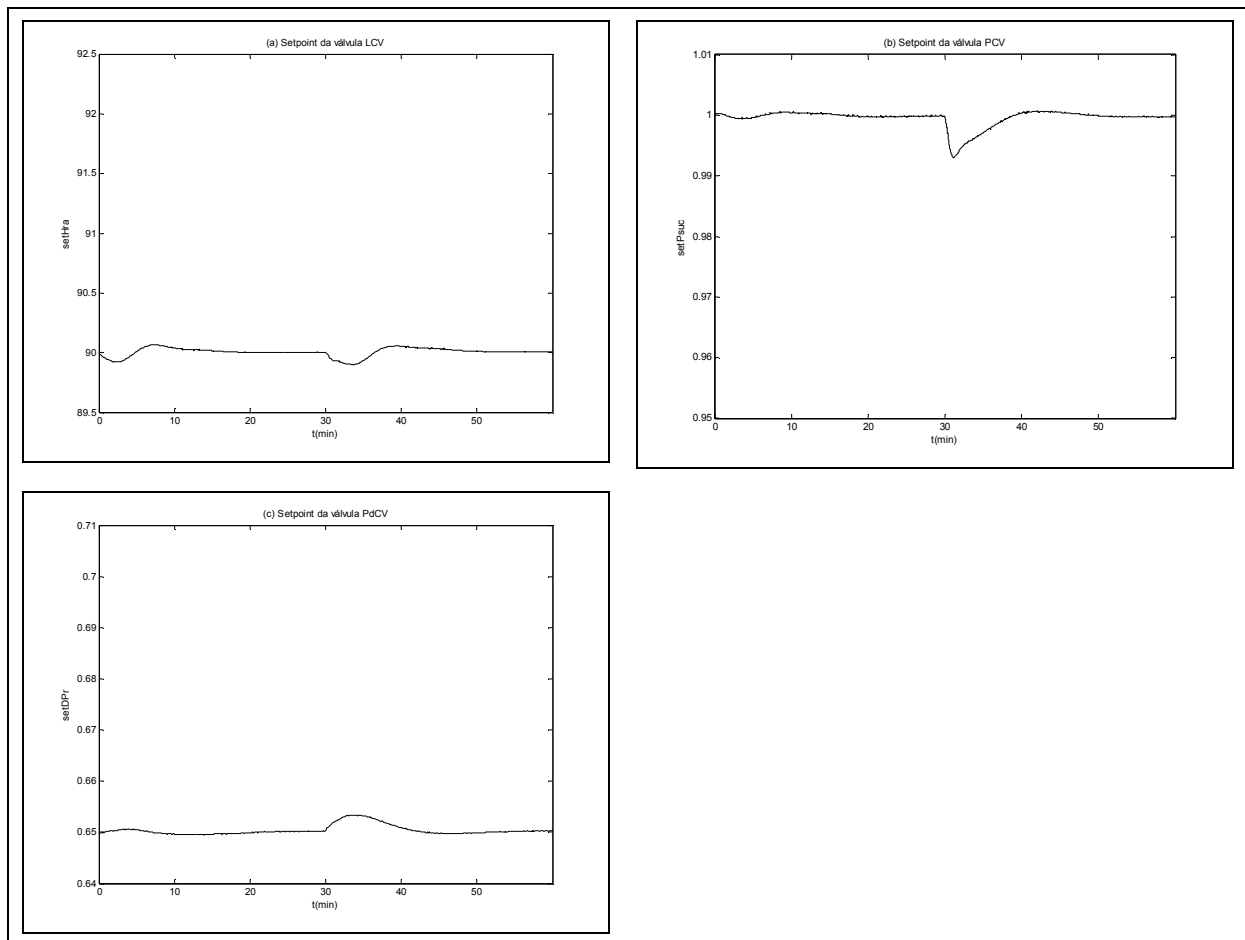
Referência: 0,65 kgf/cm<sup>2</sup>

Os efeitos ocasionados pela inserção do ruído podem ser observados na Figura 4.39, Figura 4.40 e Figura 4.41. Mesmo com o ruído inserido, as saídas do processo mantiveram-se sobre os respectivos sinais de referência.

A mudança no valor do sinal de referência de  $Trx$  no tempo de 30 minutos, ocasionou uma abertura máxima da válvula  $TCV$ , que, apesar do nível de ruído, manteve-se dentro das restrições impostas para os valores de entrada do sistema.

Figura 4.39 – Saídas do FCC – Com ruído de medição na variável  $Tr_x$

Figura 4.40 – Entradas do FCC - Com ruído de medição na variável  $Trx$

Figura 4.41 – Entradas dos PI's - Com ruído de medição na variável  $Trx$ 

Com os resultados das simulações apresentados, verifica-se que o controlador preditivo QDMC apresentou desempenho satisfatório no controle da unidade de Craqueamento Catalítico em Leito Fluidizado, sob diferentes condições de operação como variação dos sinais de referência, e inserção de ruídos e perturbações.

### 4.3.2 OTIMIZAÇÃO EM DUAS CAMADAS

Após verificada a eficiência do controlador preditivo QDMC no controle da unidade de FCC, analisou-se o desempenho do sistema quando da inserção de critérios de otimização. A primeira análise realizou-se com a abordagem de otimização em duas camadas.

Dentre os diversos produtos resultantes do processo de craqueamento catalítico, tais como gasolina, gás liquefeito (GLP), óleo leve de reciclo (LCO ou *Light Cycle Oil*) e óleo decantado (OD), utilizou-se como objetivo econômico nas simulações do FCC, a

maximização do GLP, cuja formulação matemática de rendimento é apresentada em Zanin (2001) e exposta abaixo:

**Rendimento de GLP:**

$$GLPV - F_1(1 - F_2) = 0 \quad (4.17)$$

sendo:  $GLPV$  rendimento volumétrico do gás liquefeito de petróleo em relação à carga da unidade;  $F_1$  e  $F_2$  variáveis auxiliares, definidas como:

$$\begin{aligned} F_1 + 27,198427 - 7,128543 \cdot \ln FSF - 0,555905 \cdot CONV V \\ + 2,56093 \cdot 10^{-7} \cdot CONV V^4 + 9,963736 \cdot 10^{-8} \cdot FSF^4 \\ - 0,008509 \cdot CONV V \cdot FSF = 0 \end{aligned} \quad (4.18)$$

$$\begin{aligned} F_2 + 0,5972 - 0,015746 \cdot FSF - \frac{14,107127}{FSF} + 1,16 \cdot 10^{-4} \cdot FSF^2 + \\ 3,3024438 \cdot 10^{-6} \left( \frac{CONV V \cdot Trx}{FSF} \right)^2 - 0,00279 \cdot \frac{CONV V \cdot Trx}{FSF} = 0 \end{aligned} \quad (4.19)$$

onde  $FSF$  é o fator de caracterização da carga, dado como:

$$FSF - \frac{75 - 0,065 \cdot PEMVF - 0,9 \cdot S + 0,6 \cdot PA - 0,26 \cdot \frac{PA}{D60}}{1 + 0,0000808 \cdot TNB} = 0 \quad (4.20)$$

onde  $PEMVF$ ,  $S$ ,  $PA$ ,  $D60$ ,  $TNB$ , são propriedades da carga.

Neste trabalho, apenas gás-óleo é considerado como carga da unidade de FCC, e suas propriedades são definidas conforme Tabela 4.18.

Propriedade	Símbolo	Unidade	Valor
Densidade 60/60°F	D60		0,94
Ponto de anilina	PA	°F	210
Teor de Enxofre	S	% massa	0,3
Teor de nitrogênio básico	TNB	ppm	900
Ponto de ebulição	PEMVF	°F	850

Tabela 4.18 – Propriedades típicas do Gás-óleo

$CONVV$  é a conversão volumétrica da carga nos produtos: gás, GLP, gasolina e coque, definido como:

$$\begin{aligned}
 & CONVV + 0,019164.FSF.(1 + 0,021289919.SEV) + \frac{64,866937}{FSF} & (4.21) \\
 & .(1 + 0,01248132.SEV) - 1,14585.SEV + 0,000997.SEV^2 \\
 & - 3,32486.10^{-6}.SEV^3 = 0
 \end{aligned}$$

Sendo  $SEV$  a severidade calculada conforme formulação máxima:

$$SEV - \frac{100.A_{est}}{1 + A_{est}} = 0 \quad (4.22)$$

$$A_{est} - \frac{2,5.10^5.catoil_{est}^{0,65}}{R_f^{0,35}} e^{\frac{-Ecr}{RGAS(Trx+273.15)}} = 0 \quad (4.23)$$

Onde  $catoil_{est}$  é a estimativa da relação entre as vazões mássicas de catalisador regenerado e carga (relação catalisador/óleo) definida como:

$$catoil_{est} - 2,761 \frac{(Trx - Tfp)}{(Trg2 - Trx)} - 1,805 = 0 \quad (4.24)$$

onde  $Ecr$  e  $RGAS$  são constantes do processo da unidade de FCC.

Como demonstrado pela formulação, o rendimento de GLP (Equação (4.17)) depende das variáveis  $Trx$  e  $Trg2$  (Equação (4.24)) que são controladas pelo QDMC. Outras

variáveis que também interferem no rendimento de GLP são  $Tfp$  e  $Rtf$  (temperaturas e vazão da carga respectivamente), que são variáveis não controladas e consideradas nas simulações como perturbações.

Os valores iniciais e os limites impostos à unidade de Craqueamento Catalítico foram utilizados conforme a Tabela 4.15. Os parâmetros de ajuste do QDMC foram mantidos conforme a Tabela 4.16. Os limites impostos das ações de controle e de otimização foram definidos conforme a Tabela 4.19 e Tabela 4.20.

Parâmetro	Unidade	$\Delta y_{set}^{max}$	$\Delta y_{set}^{min}$
$Trx$	C°	0,05	-0,1
$Hra$	ton	0,1	-0,1
$Psuc$	Kgf/cm <sup>2</sup>	0,001	-0,001
$Trg2$	C°	0,08	-0,02
$DPr$	Kgf/cm <sup>2</sup>	0,0005	-0,0005

Tabela 4.19 – Movimentos máximos e mínimos das ações de otimização

Parâmetro	Unidade	$\Delta u^{max}$	$\Delta u^{min}$
$TCV$	%	0,016	-0.0370
$setHra$	ton	1	-1
$setPsuc$ :	Kgf/cm <sup>2</sup>	0,018	-0.002
$Raí$	ton/h	1,9	-4.1
$setDPr$	Kgf/cm <sup>2</sup>	0,005	-0.005

Tabela 4.20 – Movimentos máximos e mínimos das ações de Controle utilizados na otimização

As simulações foram iniciadas com somente a camada de controle ativa, que foi responsável por conduzir as saídas do sistema aos valores de referências iniciais. Depois de decorridos 20 minutos, a camada de otimização foi também ativada, levando o sistema para o ponto ótimo conforme definido pelo objetivo econômico.

Os valores das referências iniciais utilizados nesta simulação são apresentados abaixo:

- Temperatura da saída do riser ( $Trx$ ).

Referência inicial: 540° C



- Inventário de catalisador no vaso separador (*Hra*).  
Referência: 90 ton
- Pressão de sucção do compressor de gás úmido (*Psuc*).  
Referência: 1 kgf/cm<sup>2</sup>
- Temperatura da fase densa do segundo estágio do regenerador (*Trg2*).  
Referência: 700° C
- Pressão diferencial entre o vaso separador e o regenerador (*DPr*).  
Referência: 0,65 kgf/cm<sup>2</sup>

#### 4.3.2.1 Maximização de GLP

Os resultados da unidade de FCC, para a maximização de GLP, o qual o seu rendimento é obtido pela Equação (4.17), podem ser observados na Figura 4.42, Figura 4.43, Figura 4.44, e Figura 4.45.

Apesar da otimização em duas camadas ter maximizado a produção de GLP, conforme pode ser observado na Figura 4.45, o sistema não conseguiu encontrar um ponto de estabilização. A oscilação da produção de GLP foi ocasionada pela instabilidade da variável *Trg2*, que possui um tempo de resposta lenta e é de difícil controle. Analisando a Figura 4.42d, é possível perceber que a referência movimentou-se até o limite inferior, mas o sistema de controle não consegue impedir que *Trg2* ultrapasse este limite. Ao perceber a violação desta restrição, a camada de otimização manipula a referência de modo a trazer a saída para dentro dos limites, mas devido à lentidão da resposta de *Trg2*, a referência do sinal cresce consideravelmente, voltando a possuir valores menores apenas após a saída ter voltado para dentro dos limites. A repetição deste comportamento é o que ocasiona a oscilação no sistema.

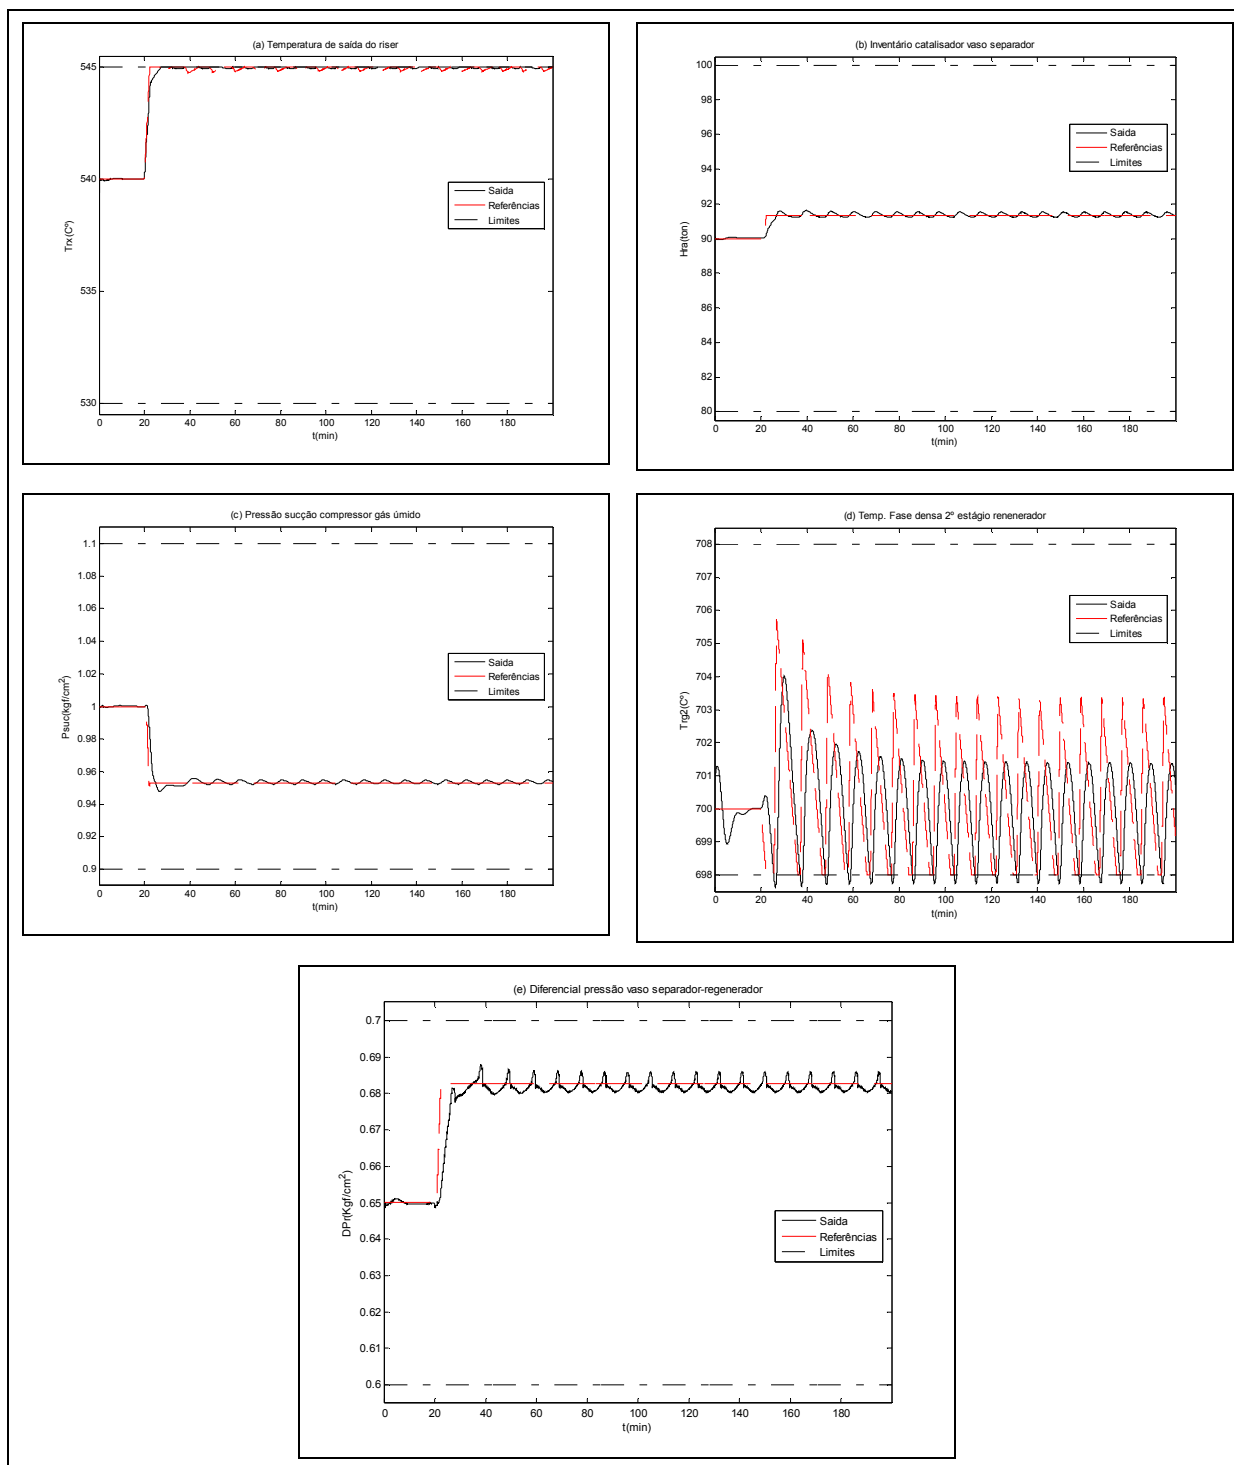


Figura 4.42 – Saídas do FCC – Otimização em duas camadas

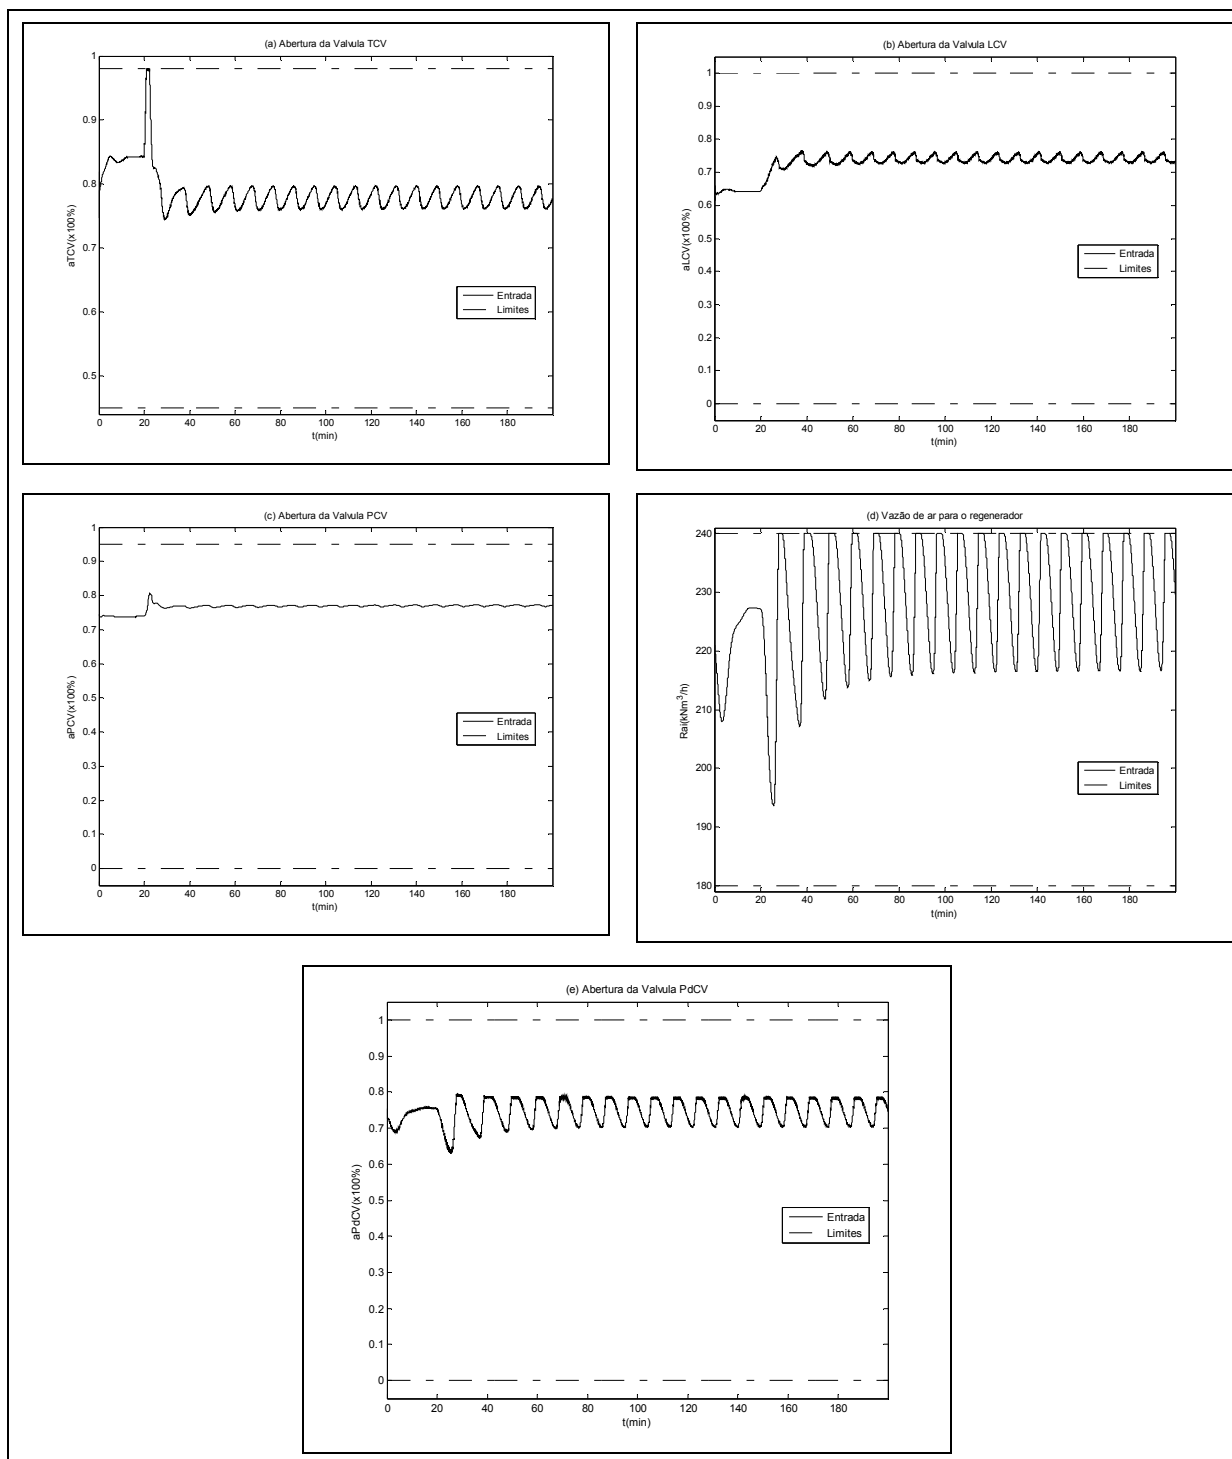


Figura 4.43 – Entradas do FCC - Otimização em duas camadas

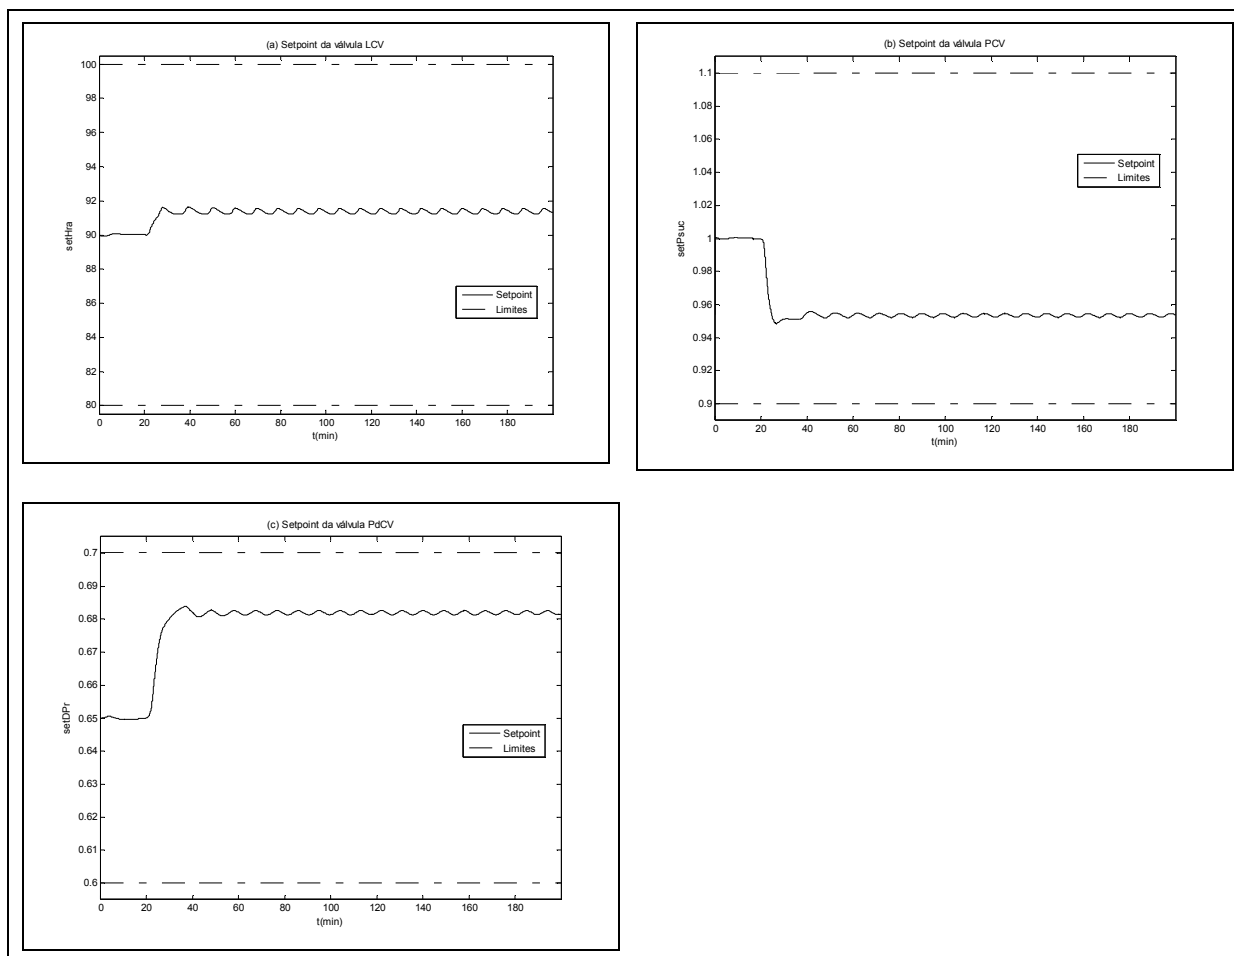


Figura 4.44 – Entradas dos PI's - Otimização em duas camadas




Figura 4.45 – Produção de GLP - Otimização em duas camadas

Devido à dificuldade de se manter a saída Trg2 dentro dos limites operacionais, a otimização em duas camadas apresentou um comportamento oscilatório, o que torna esta

abordagem inviável para maximização de GLP com a utilização deste modelo de unidade de Craqueamento Catalítico em Leito Fluidizado.

### 4.3.3 OTIMIZAÇÃO EM UMA CAMADA

A segunda abordagem de otimização utilizada na unidade de Craqueamento Catalítico em Leito Fluidizado, é a otimização em uma camada, que, conforme definido no Capítulo 3, dentro função objetivo do controlador QDMC, é inserida a função econômica objetivo da planta de FCC, havendo desta forma um único cálculo, no qual são determinados os acréscimos dos valores das entradas do processo ( $\Delta u$ ) e os acréscimos dos valores de referência para as saídas ( $\Delta y_{set}$ ).

Os limites operacionais do processo, utilizados na otimização em uma camada, foram os mesmos apresentados anteriormente na Tabela 4.15.

Para análise da otimização em uma camada, também utilizou-se como objetivo econômico, a maximização da produção de GLP.

Os parâmetros de ajuste do controlador QDMC e da otimização são apresentados na Tabela 4.21.

Parâmetro	Valor
Np	150
Nu	2
Ny	25
diagonal $W$ [Trx; Hra; Psuc; Trg2; DPr]	[ 5; 3,5; 19; 0,30; 20]
diagonal $\lambda$ [Trx; Hra; Psuc; Trg2; DPr]	[ 0,50; 0,40; 4; 0,20; 4,2]
[W1; W2; W3];	[ 1; 1; 1]

Tabela 4.21 - Parâmetros de Ajuste do Controlador e da Otimização em uma camada para a unidade de FCC

#### 4.3.3.1 Maximização de GLP

Os resultados obtidos para a maximização do GLP são apresentados na Figura 4.46, Figura 4.47 e Figura 4.48. É possível perceber que a otimização em uma camada foi capaz de conduzir o sistema para o máximo operacional, sem violar as restrições impostas no processo.

A temperatura do *riser* (Figura 4.46-a) é rapidamente maximizada, após ativada a otimização no tempo de 20 minutos, até o seu limite máximo (545 C°). As demais saídas, nos instantes iniciais, movimentaram-se de modo a permitir um maior velocidade de otimização

de  $Trx$ , devido a sua grande influência na maximização de GLP. Quando  $Trx$  atinge seu valor máximo,  $Trg2$  movimenta-se até o seu limite inferior, ponto no qual é máxima a produção de GLP.

As influências dos valores de  $Trx$  e  $Trg2$  na função objetivo podem ser observadas na Figura 4.49. A partir do instante em que foi acionado o otimizador, a produção de GLP passou de  $124,8\text{m}^3/\text{h}$  para uma produção de aproximadamente  $129,3\text{m}^3/\text{h}$  até o instante 25 min, quando  $Trx$  atingiu seu valor máximo. A partir de então,  $Trg2$  passa a influenciar a função objetivo, aumentando a produção para  $131,1\text{m}^3/\text{h}$ , resultando em um acréscimo total de aproximadamente 5%.

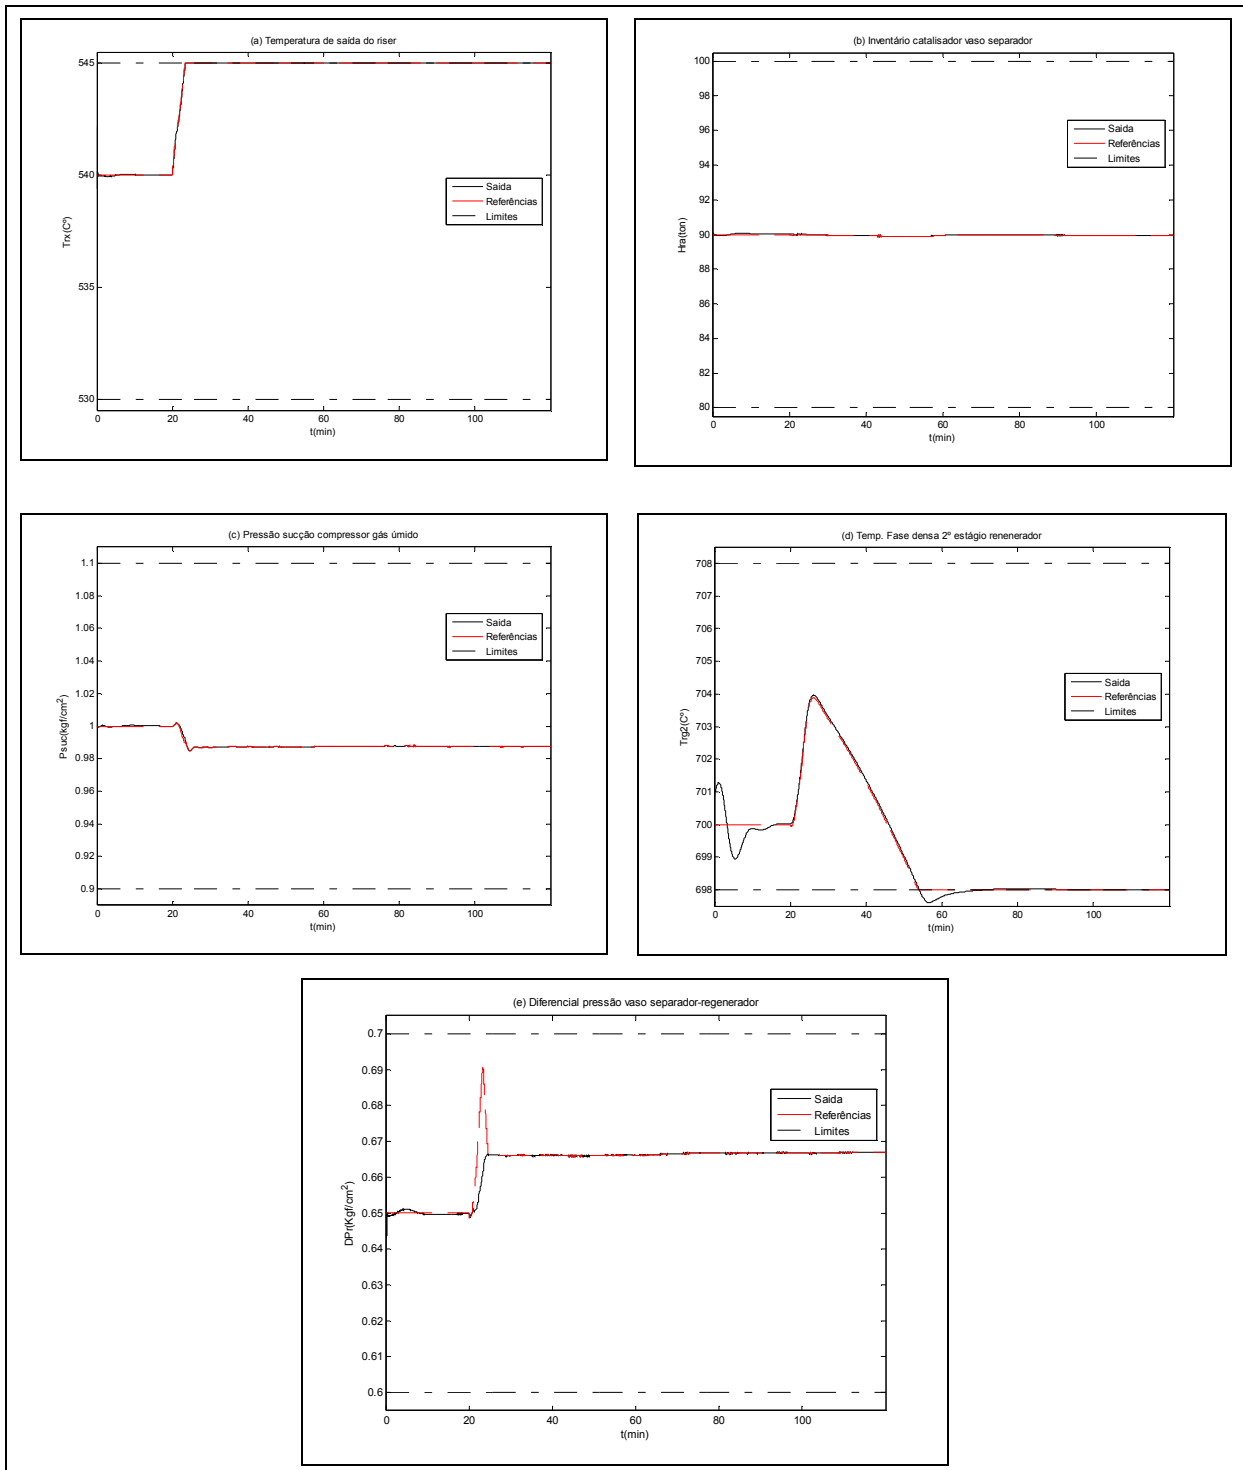


Figura 4.46 – Saídas do FCC – Otimização em uma camadas

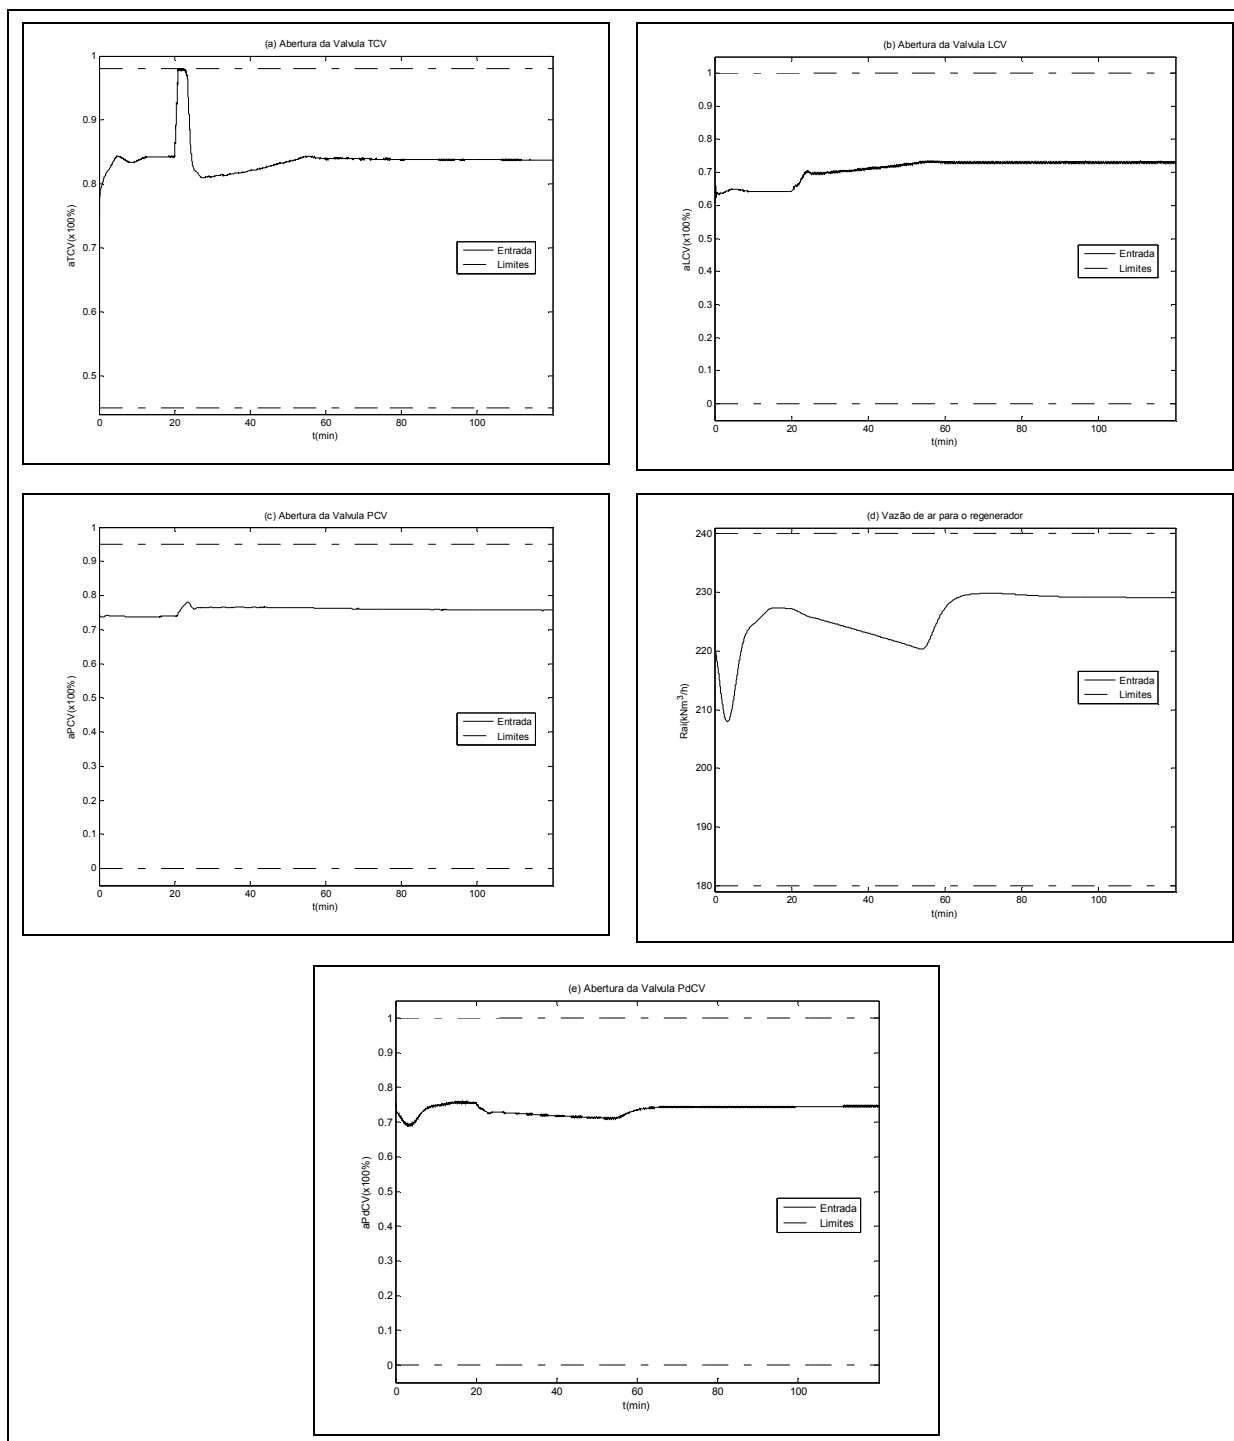


Figura 4.47 – Entradas do FCC - Otimização em uma camada






Figura 4.48 – Entradas dos PI's - Otimização em uma camada




Figura 4.49 – Produção de GLP - Otimização em uma camada

Devido à integração entre a função econômica do QDMC e a função econômica do processo, a otimização em uma camada permitiu que o sistema apresentasse um

comportamento estável, diferente do comportamento oscilatório ocorrido na otimização em duas camadas.

#### **4.3.3.2 Maximização de GLP – Com aumento da restrição de TCV**

Nesta simulação realizou-se uma modificação no valor do limite superior de abertura da válvula *TCV*, que teve seu valor reduzido de 98% para 85%. O objetivo desta simulação é verificar o comportamento das demais variáveis do processo quando a variável *TCV*, responsável direta pela manipulação de *Trx* e que tem forte influência sobre a produção de GLP, não é capaz de por si só levar *Trx* até seu limite máximo.

Os demais limites permaneceram os mesmos expostos na Tabela 4.15.

Observando a variável *TCV*, Figura 4.51a, verifica-se que esta atingiu rapidamente o seu limite máximo após ativada a otimização no tempo de 20 minutos.

A Figura 4.50, mostra as saídas da unidade de FCC, nas quais é possível perceber que houve um aumento do valor da variável *DPr* e uma diminuição do valor de *Psuc* em relação a simulação anterior. Estes comportamentos se justificam devido à limitação de *TCV*, como esta variável não foi capaz de conduzir *Trx* ao limite máximo, *DPr* e *Psuc* movimentaram-se de modo a influenciar a maximização do valor de *Trx*.

A Figura 4.53 mostra a produção de GLP, que teve a resposta semelhante a obtida na simulação anterior.

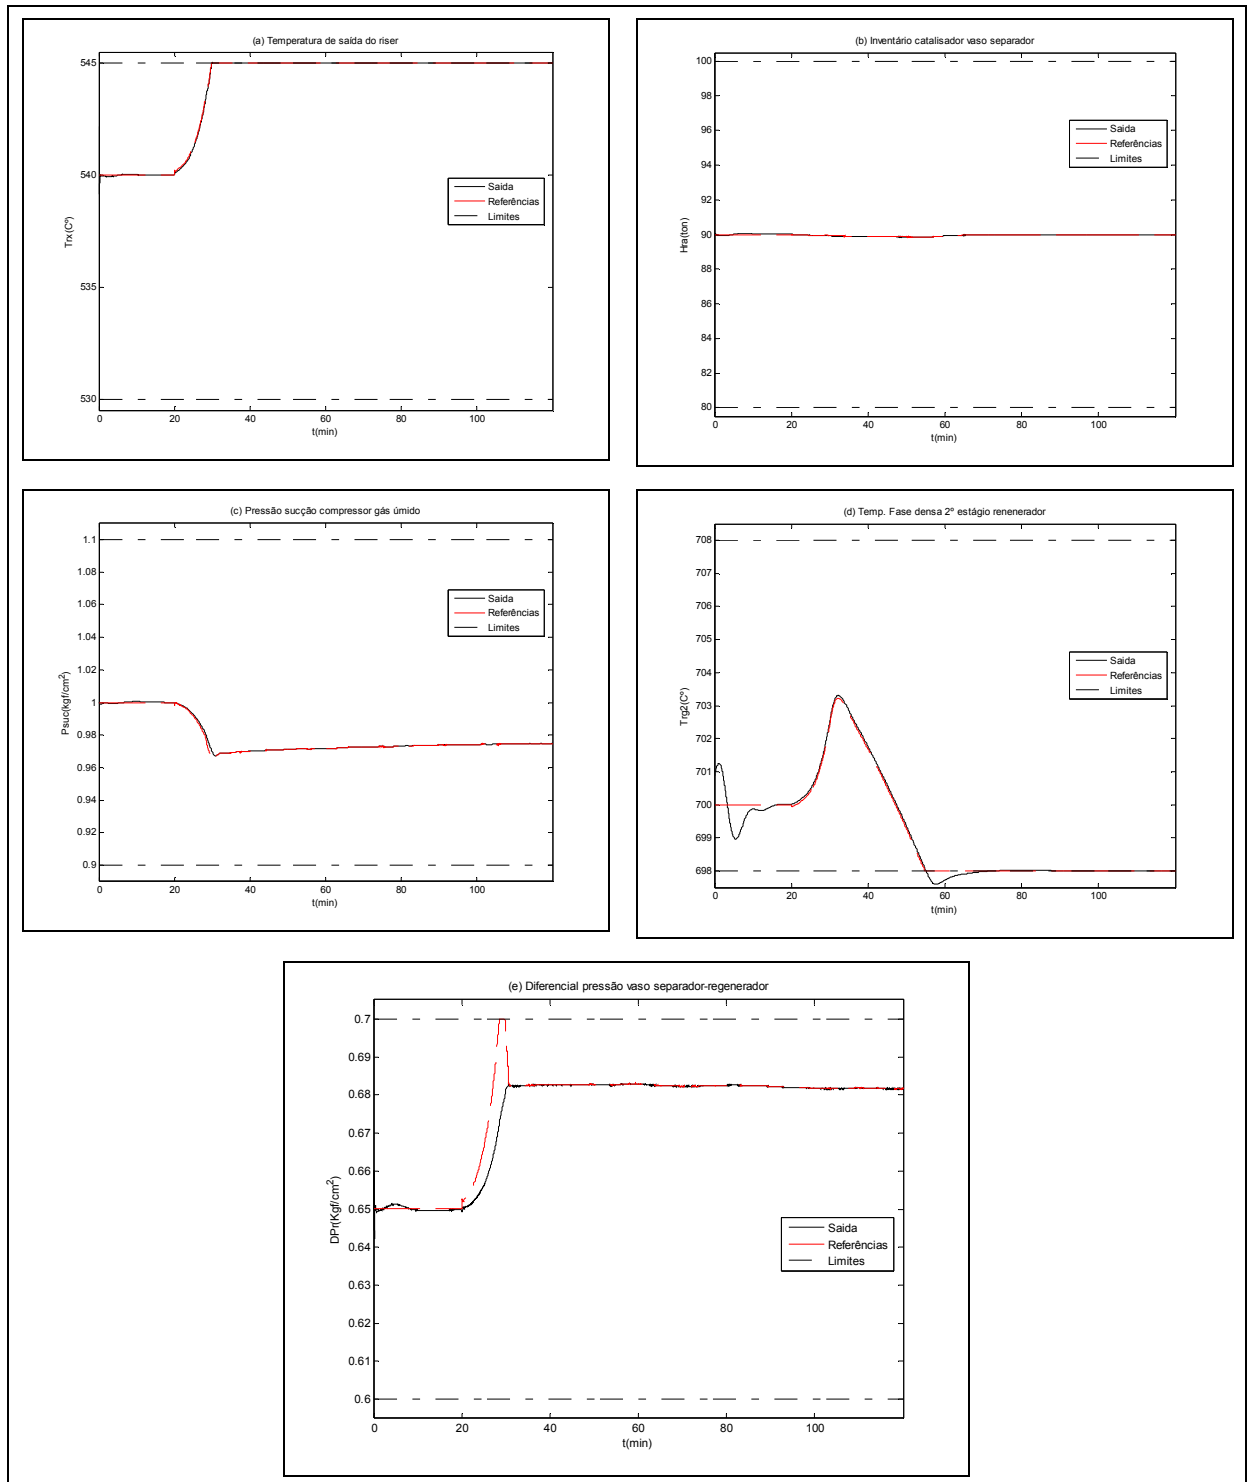


Figura 4.50 – Saídas do FCC – Otimização em uma camadas, com diminuição do limite superior de  $TCV$

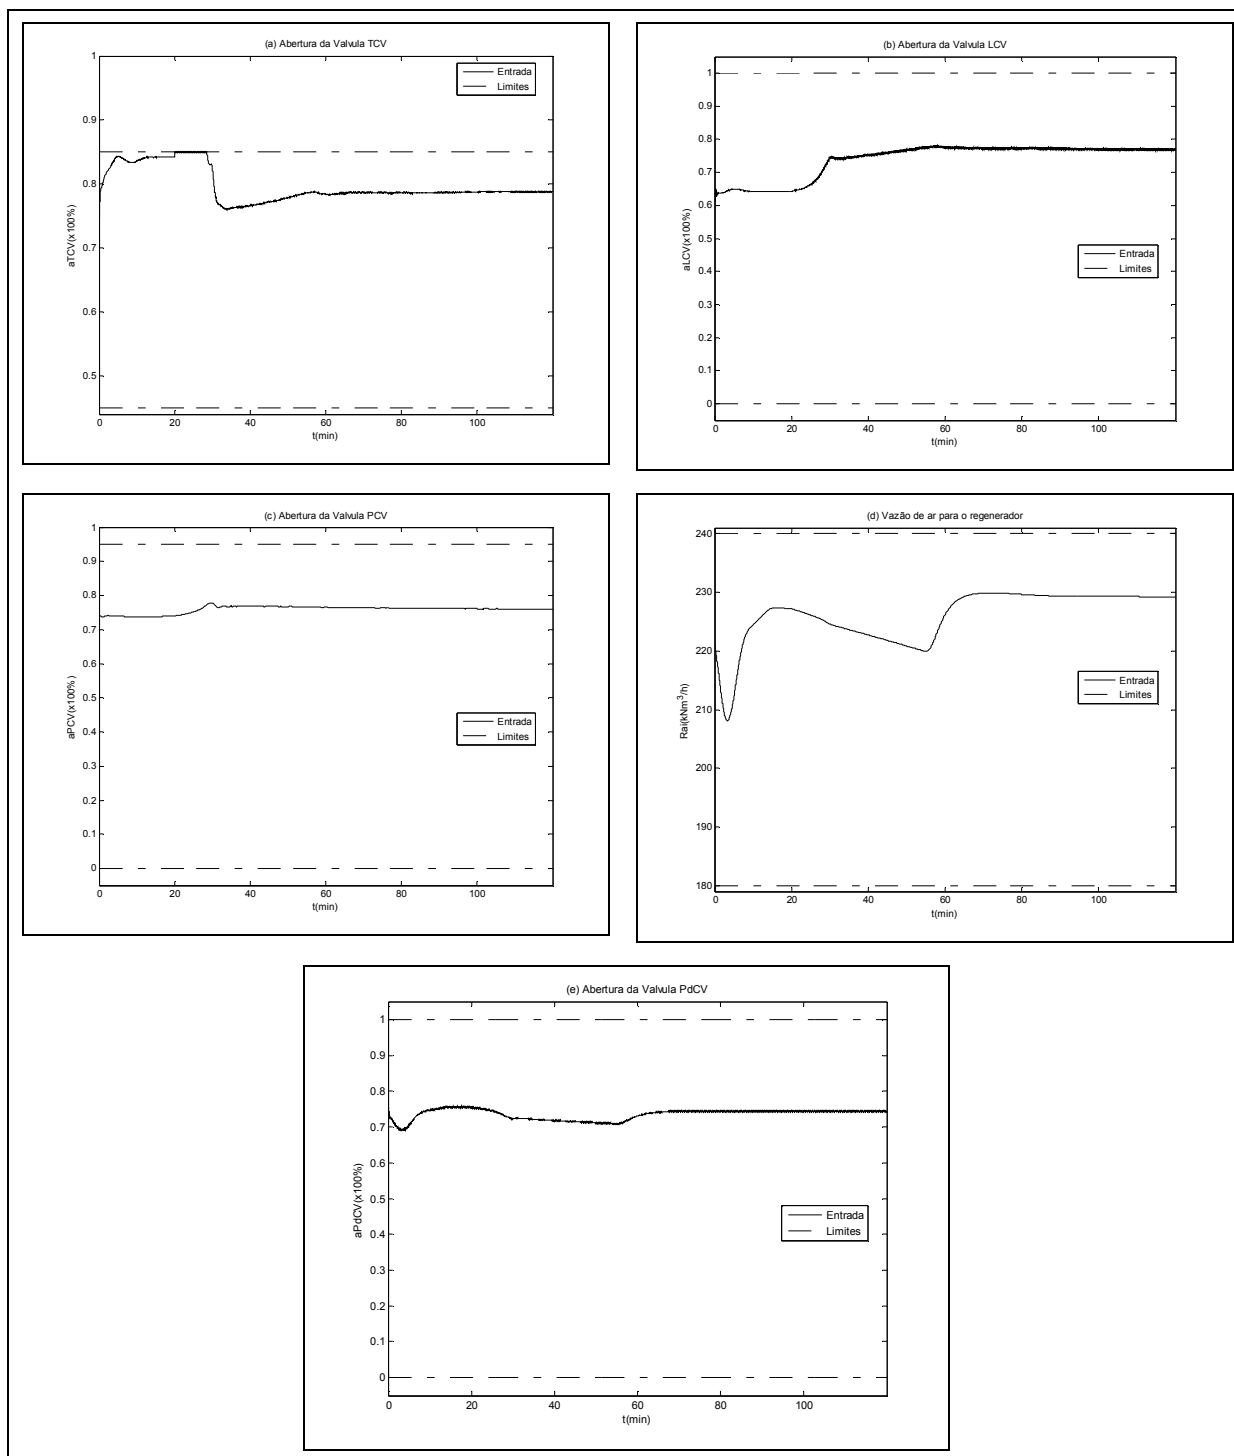


Figura 4.51 – Entradas do FCC - Otimização em uma camada, com diminuição do limite superior de TCV




Figura 4.52 – Entradas dos PI's - Otimização em uma camada, com diminuição do limite superior de *TCV*




Figura 4.53 – Produção de GLP - Otimização em uma camada, com diminuição do limite superior de *TCV*

### 4.3.3.3 Maximização de GLP – Com perturbação

Para verificar a robustez da otimização em uma camada foram inseridas perturbações ao sistema. As perturbações foram introduzidas com modificações nas variáveis externas, vazão da carga ( $R_{tf}$ ) e a temperatura da carga ( $T_{fp}$ ), que possuem influência sobre o comportamento do sistema.

O comportamento das perturbações inseridas ao longo do tempo podem ser observadas na Figura 4.54.

Os limites operacionais foram mantidos conforme a simulação anterior, a qual foi mantida a limitação de 85% na variável TCV.




Figura 4.54 – Otimização em uma camada - perturbações.

O comportamento do sistema, com a introdução das perturbações, podem ser verificados na Figura 4.55, Figura 4.56 e Figura 4.57. Mesmo com as perturbações, o sistema manteve-se dentro dos seus limites operacionais.

A variável manipulada  $TCV$ , Figura 4.56a, teve sua abertura máxima atingida em duas ocasiões, a primeira delas para maximizar o valor de  $Trx$ , e a segunda, para compensar os efeitos das perturbações.

A variável  $Trg2$ , devido às perturbações, apresentou oscilação ao atingir seu limite inferior, porém, após alguns instantes estabilizou-se sem ultrapassar os limites da referência ( $y_{set}$ ).

A Figura 4.58 mostra que a produção de GLP teve seu valor maximizado. É possível observar também que houve oscilações no valor da produção de acordo com as mudanças nas

amplitudes das perturbações, mostrando estas perturbações têm influência direta na produção de GLP.

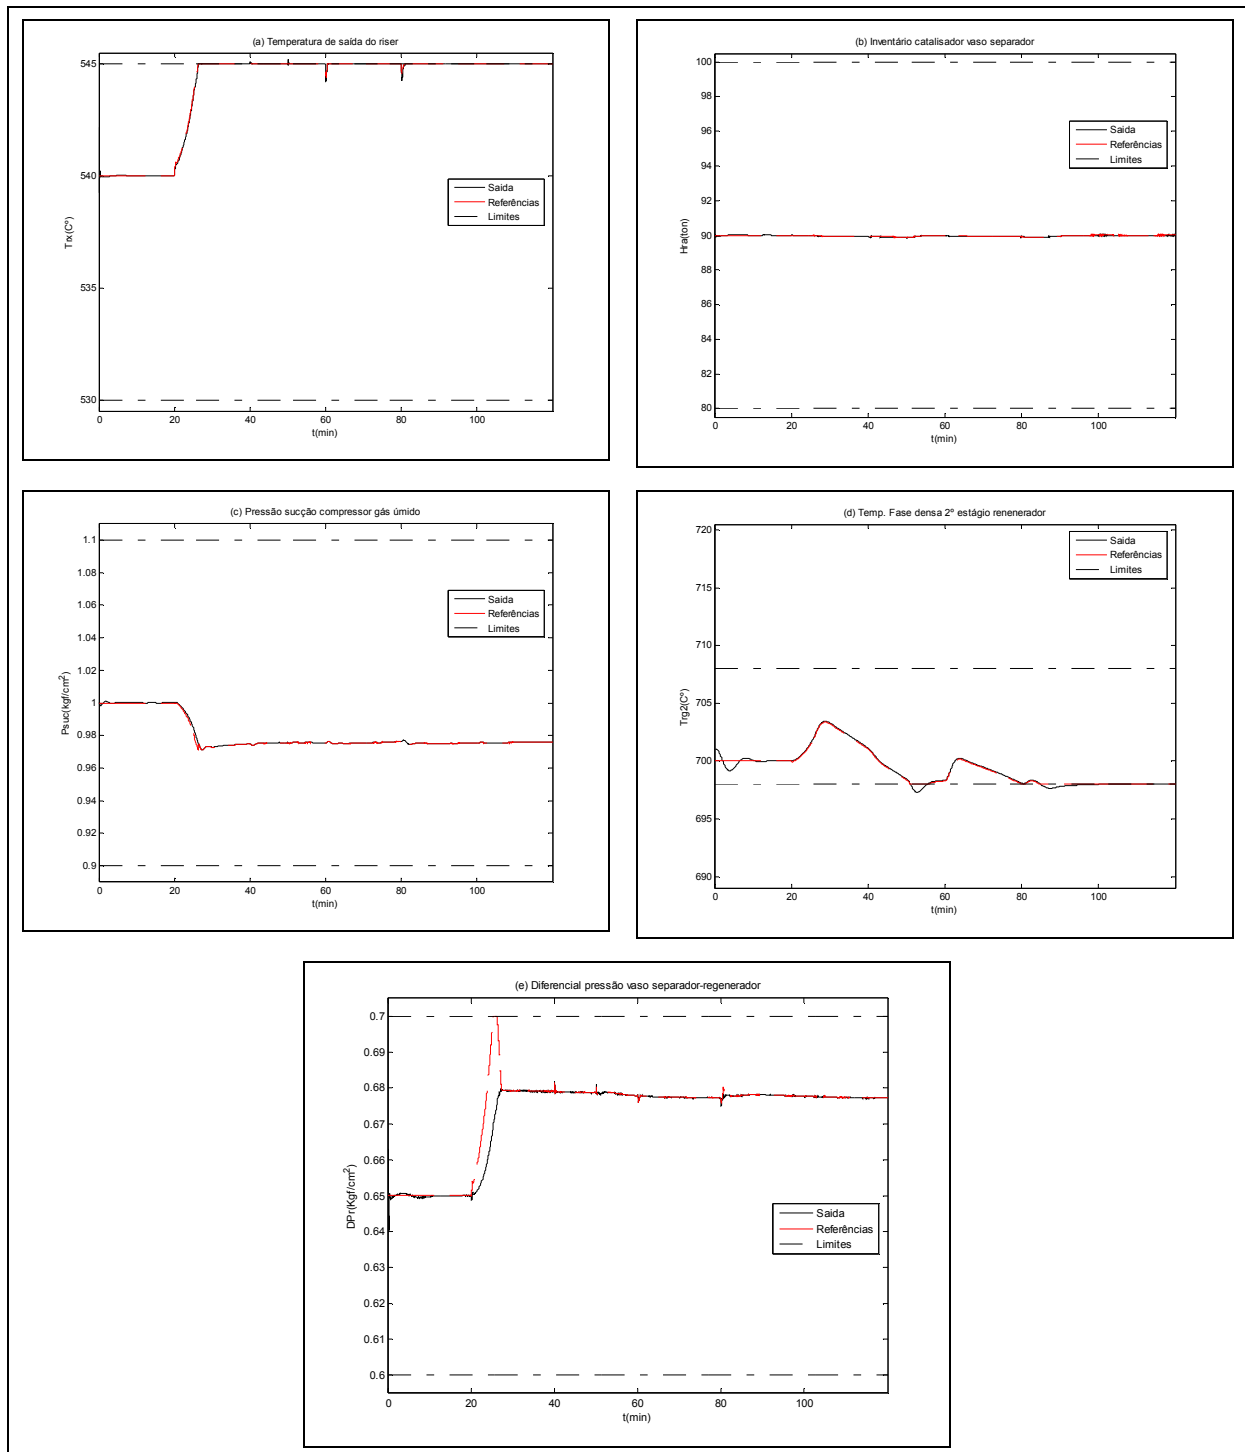


Figura 4.55 – Saídas do FCC – Otimização em uma camadas, com perturbação

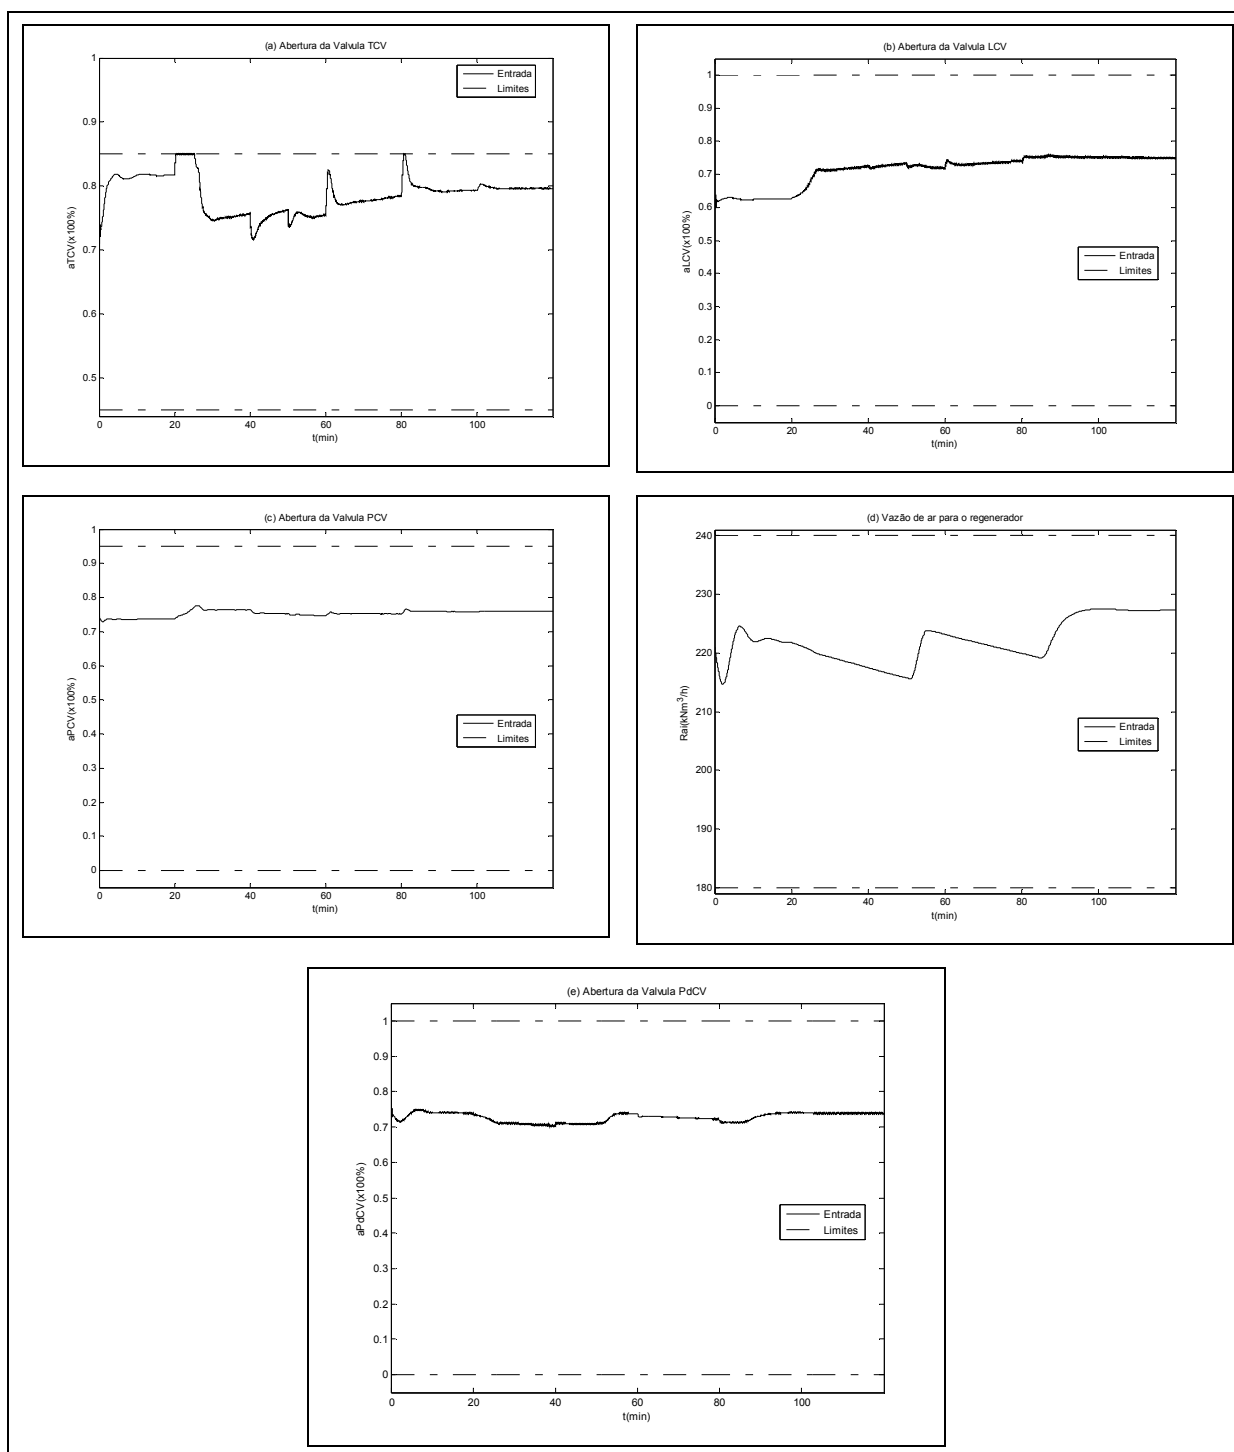


Figura 4.56 – Entradas do FCC - Otimização em uma camada, com perturbação






Figura 4.57 – Entradas dos PI's - Otimização em uma camada, com perturbação




Figura 4.58 – Produção de GLP - Otimização em uma camada, com perturbação

#### 4.3.3.4 Maximização de GLP – Com ruído

Uma outra análise foi realizada com a inserção de um ruído de medição sobre a variável  $Trx$ , de amplitude variável entre [+0,02% e -0,02%] de seu valor de saída, com o objetivo de verificar se o sistema é capaz de maximizar a produção de GLP, mesmo quando submetido a interferências deste tipo.

Os limites operacionais foram mantidos conforme a Tabela 4.15.

Os resultados obtidos nesta simulação são apresentados na Figura 4.59, Figura 4.60, e Figura 4.61. É possível perceber, analisando a Figura 4.59, que  $Trx$  e  $Trg2$  movimentam-se de modo a maximizar a produção de GLP.

A Figura 4.59a mostra que mesmo com o ruído intenso, o valor de referência ( $y_{set}$ ) da variável  $Trx$  não ultrapassou o limite imposto. O mesmo acontece com  $TCV$  (Figura 4.60a), variável responsável pela manipulação de  $Trx$ , que em nenhum momento violou as restrições.

A produção de GLP é mostrada na Figura 4.62.

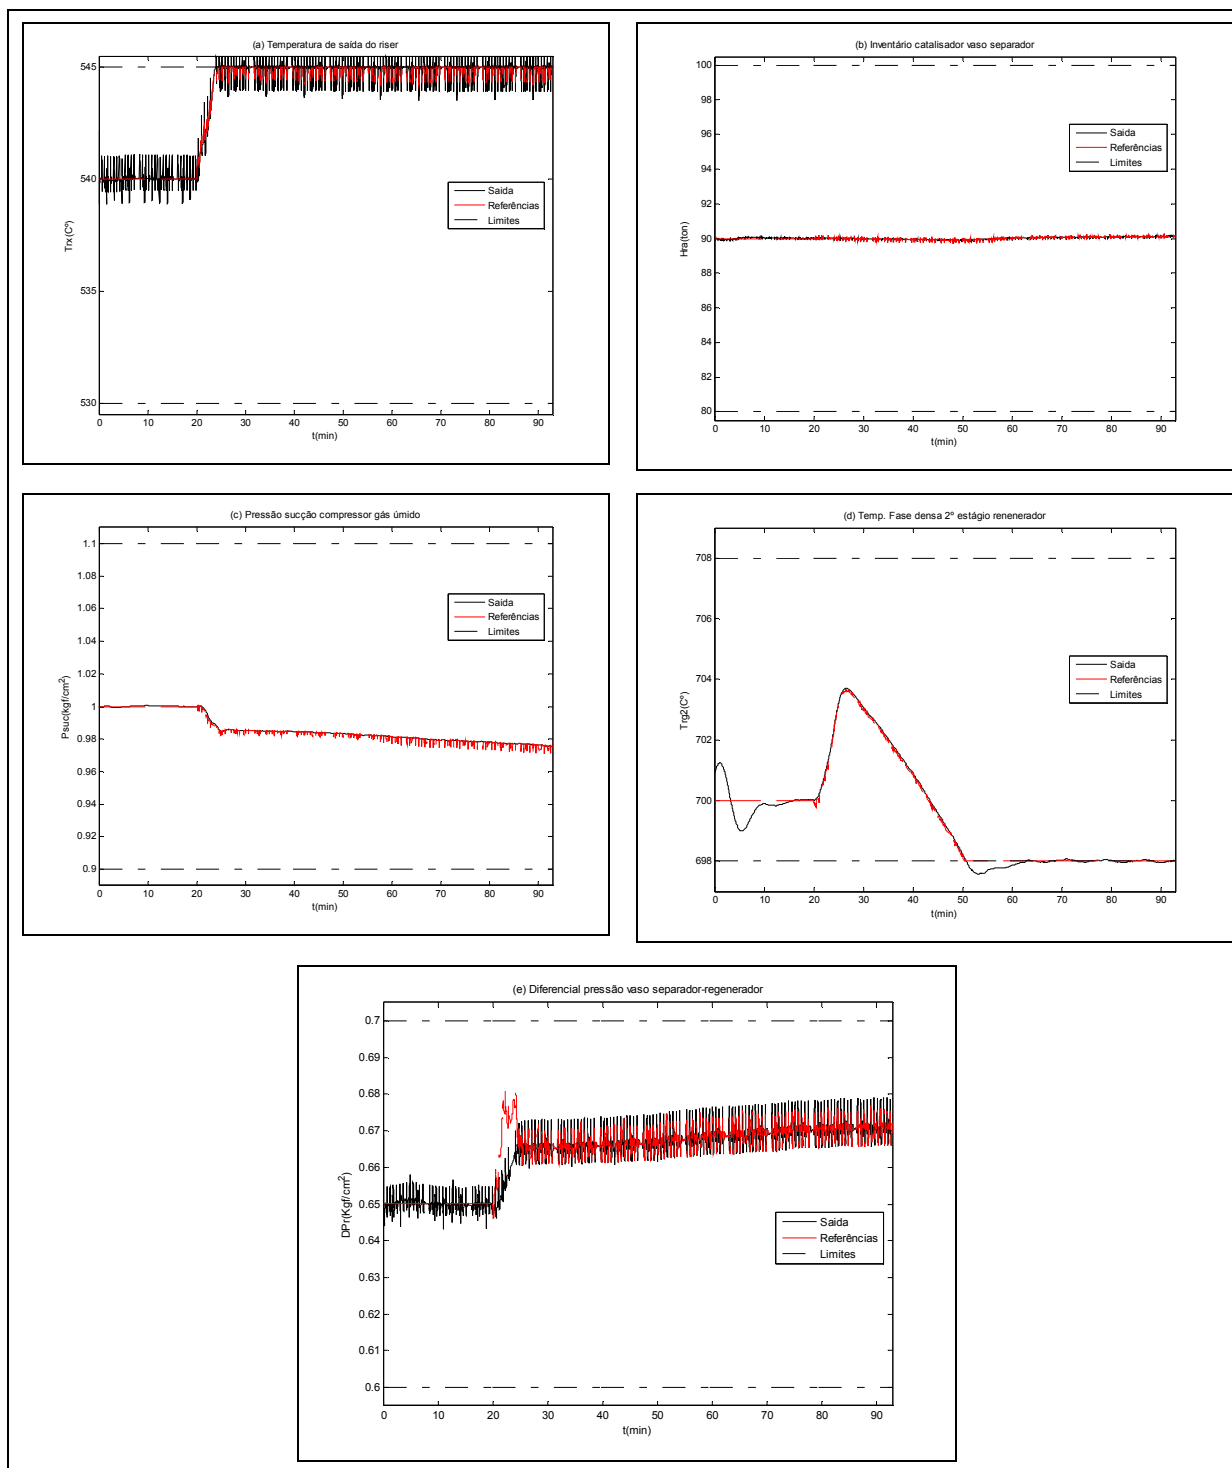


Figura 4.59 – Saídas do FCC – Otimização em uma camadas, com ruído

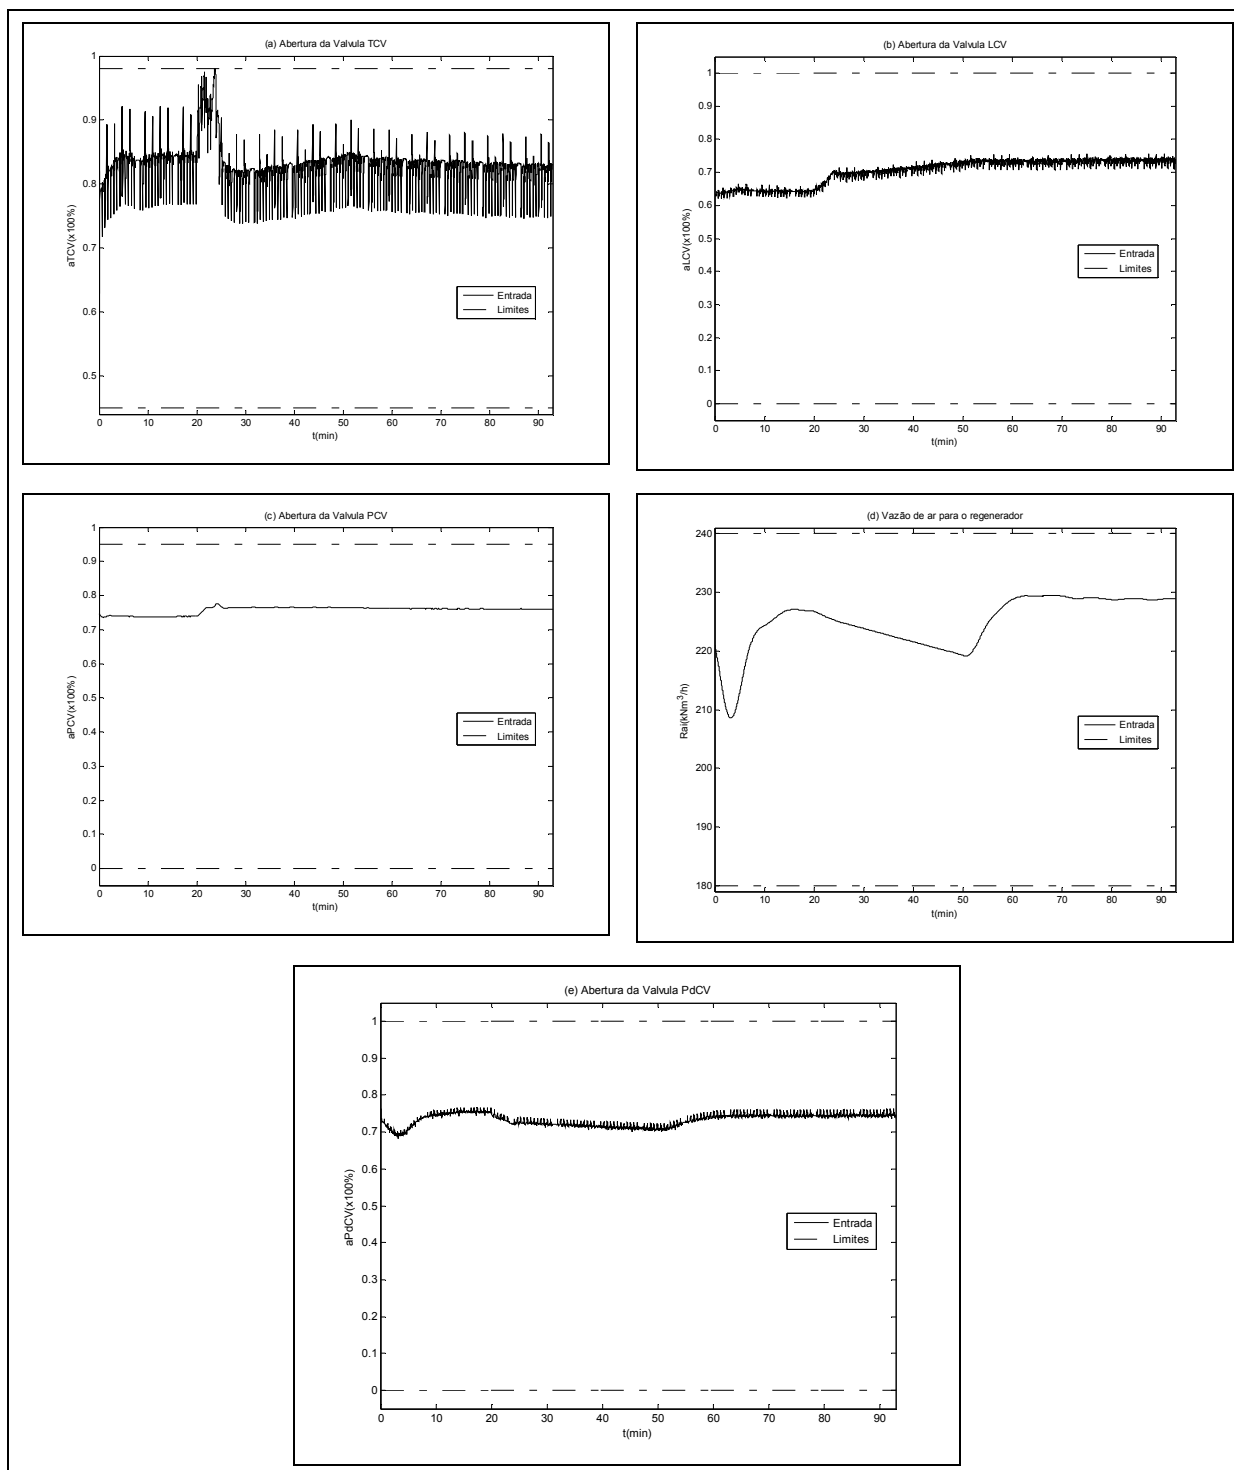


Figura 4.60 – Entradas do FCC - Otimização em uma camada, com ruído




Figura 4.61 – Entradas dos PI's - Otimização em uma camada, com ruído




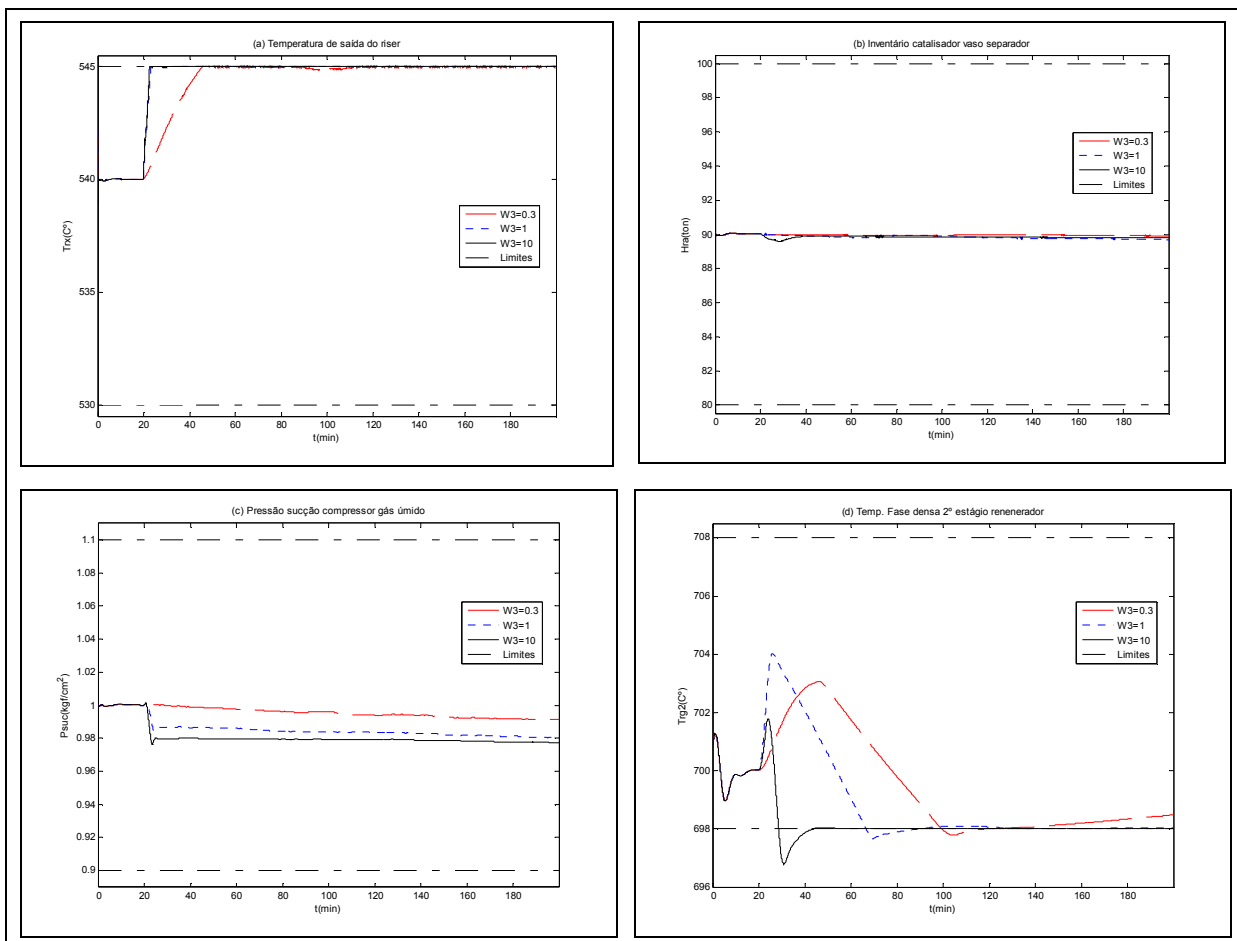
Figura 4.62 – Produção de GLP - Otimização em uma camada, com ruído

### 4.3.3.5 Análise da influência de $W3$

A otimização em uma camada possui  $W1$ ,  $W2$  e  $W3$  como parâmetros de ajuste. Como demonstrado no capítulo 3, os dois primeiros parâmetros estão relacionados com o sistema de controle, o terceiro termo refere-se a camada de otimização. Para efeito de análise foram realizadas simulações variando somente o parâmetro  $W3$ , de forma a não interferir nos termos responsáveis pelo controle.

O sistema foi simulado com o objetivo de maximização do GLP, com três valores distintos de  $W3$ , sendo estes 0.3, 1 e 10. Os demais parâmetros permaneceram inalterados conforme a Tabela 4.21.

Os resultados desta simulação podem ser verificados na Figura 4.63. Como pode ser verificado nos resultados obtidos,  $W3$  é responsável pela velocidade em que o sistema atinge o máximo operacional. Analisando a saída  $Trg2$  (Figura 4.63d), é possível observar que quando maior o valor de  $W3$ , menor o tempo em que a saída atinge o seu limite mínimo, conseqüentemente, maior o sobre-sinal ocorrido.






Figura 4.63 – Saídas do FCC – Otimização em uma camadas, análise da influência de W3

#### 4.3.4 CONCLUSÃO

No controle da Unidade de Craqueamento Catalítico em Leito Fluidizado, o controlador preditivo QDMC demonstrou-se eficiente. Foram realizados testes com ruídos e perturbações, nos quais o QDMC demonstrou possuir robustez para compensar estes tipos de distúrbios. Também foram realizadas mudanças sucessivas nos valores das referências, sendo que o sistema de controle foi capaz de manter as variáveis sobre os sinais de referência, sem erros de estado estacionário e sem violar as restrições impostas para o processo.

Com os testes realizados, é possível concluir que a otimização em duas camadas não é eficiente para a maximização da produção de GLP na unidade de FCC com o modelo utilizado. Ao contrário do aconteceu na coluna de Wood-Berry, quando a otimização só não foi capaz de atingir o máximo operacional na utilização de uma função econômica não-linear, no processo de FCC a otimização em duas camadas não foi eficiente por não possuir uma forte integração entre a camada de otimização e a camada de controle, o que acarretou uma oscilação da variável  $Trg2$ , que é uma variável de extrema dificuldade de controle.

A otimização em uma camada apresentou melhores resultados e foi capaz de conduzir a unidade de FCC para o máximo operacional em diversas condições de operação. Mesmo quando submetido a ruídos, perturbações, e fortes limitações na variável manipulada  $TCV$ , a otimização em uma camada mostrou-se eficiente na maximização da produção de GLP.





#### 5.1 COMENTÁRIOS FINAIS

Diferentes abordagens de controle têm sido estudadas no meio acadêmico e inseridas nas indústrias de processo com desempenho adequado. Da mesma forma, técnicas de otimização têm sido foco de exploração acadêmica e atenção industrial.

A otimização tem como vantagem possibilitar o tratamento simultâneo de uma grande quantidade de variáveis e restrições de difícil visualização, acarretando, desta forma, melhor desempenho das unidades e conseqüente retorno econômico satisfatório.

O principal objetivo deste trabalho foi a apresentação de estudo e avaliação do desempenho de uma classe de controladores preditivos baseados em modelo, conhecida por Controle Quadrático por Matriz Dinâmica, aplicada a processos industriais multivariáveis.

O segundo objetivo deste trabalho foi o estudo e a inserção, paralelamente ao controle preditivo, de duas abordagens distintas de otimização, conhecidas por otimização em duas camadas e otimização em camada única, e posterior comparação de resultados.

Para tais objetivos, foram utilizados dois processos multivariáveis. O primeiro deles, a Coluna de Destilação Wood-Berry, que é um modelo acadêmico clássico para simulação de um sistema de dimensão  $2 \times 2$  e que apresenta acoplamento entre suas variáveis, foi utilizado para uma avaliação inicial das metodologias e empregado para uma exploração de diversos objetivos econômicos a serem atingidos pelas abordagens de otimização. O segundo processo, Craqueamento Catalítico em Leito Fluidizado, por ser um processo com um maior número de variáveis, dimensão  $5 \times 5$ , e por apresentar uma modelagem próxima da existente na indústria de petróleo, com forte interação entre as variáveis e características não lineares, foi utilizado para uma validação final dos estudos realizados.

As simulações apresentadas demonstraram que o controle preditivo por matriz dinâmica apresentou desempenho adequado para o controle dos dois processos utilizados, e flexibilidade de ajuste de parâmetros que possibilitam a manipulação de características de resposta do sistema, como sobre-sinal e velocidade. Além disto, apresentou robustez frente a ruídos e perturbações inseridos nas variáveis. O bom desempenho desta metodologia no

controle de processos multivariáveis complexos é também comprovada pelo número de publicações que relatam algumas de suas aplicações.

Com relação às abordagens de otimização, as simulações efetuadas com a coluna de destilação Wood-Berry demonstraram que ambas as metodologias apresentam bons resultados nos casos de utilização de funções econômicas lineares, e robustez frente a ruídos, como também comportamento satisfatório no aumento das restrições dos limites das variáveis manipuladas. A diferença de resultado entre as metodologias se verifica na simulação que empregou uma determinada função econômica não-linear. A otimização em duas camadas não apresentou desempenho satisfatório, pois, os valores de referência enviados ao controlador pela camada de otimização apresentaram oscilação, portanto não foi possível a estabilização sobre o ponto de máximo econômico. Diferentemente, a otimização em uma camada demonstrou capacidade de estabilização do sistema no máximo operacional, mesmo com a utilização da função econômica não linear. A otimização em uma camada também apresentou um resultado superior, com oscilação de menor amplitude, quando da inserção de perturbações em comparação a otimização em duas camadas.

As simulações efetuadas com o modelo da unidade de Craqueamento Catalítico em Leito Fluidizado, nas quais foi utilizada uma função econômica que representa corretamente aspectos econômicos do processo e visa a maximização da produção de um produto de alto valor agregado, demonstraram novamente um melhor desempenho da otimização em uma camada. Os resultados obtidos com a abordagem em duas camadas não foram satisfatórios, pois, uma variável de difícil controle apresentou oscilações durante todo o período de simulação, não atingindo ponto de estabilização. A otimização em uma camada foi capaz de conduzir o processo ao máximo operacional mesmo nas simulações que envolveram ruídos e perturbações.

Uma característica importante encontrada somente na otimização em uma camada, é o fato da velocidade global de alcance do ponto de máximo operacional poder ser ajustada de acordo com o valor do fator de peso  $W_3$  conforme foi demonstrado. Dependendo da característica do processo, pode-se optar por uma otimização mais lenta ou mais rápida.

Com este conjunto de informações conclui-se que a otimização em uma camada apresenta uma flexibilidade maior de utilização por apresentar bons resultados frente a condições complexas como funções econômicas não lineares e variáveis de difícil controle. A otimização em duas camadas não foi eficiente nestes casos por não possuir uma interação

suficiente entre a camada de otimização e a camada de controle, e, devido a esta situação ser uma característica intrínseca de sua formulação, deve ser utilizada em situações mais restritas.

As contribuições deste trabalho são o estudo do desempenho do controlador preditivo baseado em modelo QDMC aplicado a processos multivariáveis com características complexas, e a comparação de desempenho entre as estruturas de otimização em uma camada e em duas camadas inseridas nos processos simulados.

As metodologias estudadas são abrangentes e podem ser aplicadas a processos com diferentes características e objetivos econômicos distintos, portanto, o estudo e a implementação em simulações acadêmicas possibilitam o avanço e aprimoramento destas metodologias.

## 5.2 TRABALHOS FUTUROS

As sugestões de trabalhos futuros relacionadas a seguir objetivam um complemento aos estudos aqui realizados.

- Comparação das metodologias aqui estudadas com outros métodos de otimização;
- Transformar em variáveis manipuladas as variáveis relacionadas à temperatura ( $T_{fp}$ ) e vazão ( $R_{tf}$ ) da carga da unidade de FCC, que possuem uma relação direta com a maximização de GLP, podendo assim ter seus valores ótimos determinados pelo sistema de otimização.
- Desenvolvimento de programação no caso do algoritmo de otimização não encontrar solução ótima.
- Desenvolvimento de metodologias de auxílio para o ajuste dos parâmetros de sintonia dos controladores preditivos.



## REFERÊNCIAS BIBLIOGRÁFICAS

- ALMEIDA E., ZANIN A. C., ODLOAK D. *Advanced control and optimization of a crude vacuum unit*. XI Congresso Brasileiro de Automática, I Simpósio de Automática Aplicada, pp. 23-28, São Paulo, 1996.
- ALPBAZ, M., KARACAN, S., CABBAR, Y., HAPOGLU, H. *Application of model predictive control and dynamic analysis to a pilot distillation column and experimental verification*. Chemical Engineering Journal, v. 88, pp. 163–174, 2002.
- ARKUN, Y., HOLLETT, J., WILLIAM, M. C., MORARI, M. *Experimental Study of Internal Model Control*, Ind. Eng. Chem. Process Des. Dev., v. 25, pp. 102-108, 1986.
- ASTRÖM, K. J., HÄGGLUND, T. *The future of PID control*. Control Engineering Practice 9, pp. 1163–1175, 2001.
- BASSETT, S., WIJCK, M. V. *Application of predictive control technology at BP's crude oil terminal at Grangemouth*. The Institute of Electrical Engineers, 1999.
- BEAUTYMAN, A. C. *Assessing profitability of real-time optimization*. Hydrocarbon Processing, v. 83, n. 6, pp. 39-42, 2004.
- BESL, H., KOSSMAN, W., CROWE, J. T., CARACOTSIOS, M., *Nontraditional optimization for isom unit improves profits*. Oil & Gas Journal, v. 11, pp. 61-64, 1998.
- BIEGLER, L. T. *Efficient solution of dynamic optimization and NMPC problems*. Progress in Systems and Control Theory, v. 26, 2000.
- CAMACHO, E.F., BORDONS, C., *Model Predictive Control*, Springer, London, 1999.
- CAMACHO, E.F., BORDONS, C. *Control predictivo: pasado, presente y futuro*. Escuela Superior de Ingenieros. Universidad de Sevilla, Sevilla, 2004.
- CHEN, J., RINK, R. E. *Gain-adaptive model-separated predictive control*. Systems, Man and Cybernetics, v.5, pp. 4149-4154, 1995.
- CLARKE<sup>A</sup>, D. W., MOHTADI, C., TUFFS, P. S. *Generalized predictive control - part I. The basic algorithm*. Automatica, n. 23, v. 2, pp. 137-148, 1987.
- CLARKE<sup>B</sup>, D. W., MOHTADI, C., TUFFS, P. S. *Generalized predictive control - part II. Extensions and interpretations*. Automatica, n. 23, v. 2, pp. 149-160, 1987.
- COSTA, C. E. S. *Implementação e teste do controle com otimização em tempo real em um secador tipo leito de jorro*. Dissertação de mestrado, Universidade Federal de São Carlos, São Carlos, 2003.

- 
- CUTLER, C. R., RAMARKER, B. L. *Dynamic matrix control – a computer control algorithm*. V AIChe National Meet, Texas, 1979.
- DE NICOLAO, G., MAGNI, L., SCATTOLINI, R. *Stability and robustness of nonlinear receding horizon control*. Progress in Systems and Control Theory, v. 26, 2000.
- DOUGHERTY, D., COOPER, D. *A practical multiple model adaptive strategy for single-loop MPC*. Control Engineering Practice, v. 11, pp. 141–159, 2003.
- EDGAR, T. F., HIMMELBLAU, D. M. *Optimization of chemical processes*. McGraw-Hill, New York, 1989.
- FLAUS, J.-M. *La Régulation Industrielle – Régulateurs PID*, Prédictifs et Flous, Hermès, Paris, 1994.
- FRALEIGH, L. M. *Optimal sensor and parameter estimation for real time optimization*. Dissertação de mestrado, University of Alberta, Edmonton, 1999.
- GARCÍA, C. E., MORARI, M. *Internal model control 1. A unifying review and some new results*, Ind. Eng. Chem. Process Des. Dev. v. 21: pp. 308-323, 1982.
- GARCIA, C.E., MORARI, M, *Internal Model Control 2: Design Procedure for Multivariable Systems*, Ind. Eng. Chem. Process Des. Dev., v. 24, p. 472-484, 1985.
- GARCÍA, C. E., MORSHEDI, A. M. *Quadratic programming solution of dynamic matrix control (QDMC)*. Chemical Engineering Communications, v. 46, pp. 73-87, 1986.
- GARCIA, C. E., PRETT, M. D., MORARI, M. *Model predictive control: theory and practice – a survey*. Automatica, v. 25, n. 3, pp. 335-348, 1989.
- GENTILIN C. W. J. *Controle Preditivo por Modelo Interno Aplicado a Unidades De Craqueamento Catalítico*. Dissertação de mestrado. Centro Federal de Educação Tecnológica do Paraná, Curitiba, 2004.
- GOODHART, S., NISHIZAWA, J., YANO, K., YADA, H. *Advanced control in cogeneration utility management*. Computing & Control Engineering Journal, pp. 273-282, 2000.
- GOTTFRIED, B. S., WEISMAN, J. *Introduction to optimization theory*. Prentice-Hall, New Jersey, 1973.
- GOUVÊA<sup>A</sup>, M. T., ODLOAK, D. *One-layer real time optimization of LPG production in the FCC unit: procedure advantages and disadvantages*. Computers and Chemical Engineering, v. 22, pp. 191-198, 1998.
- GOUVÊA<sup>B</sup>, M. T., ODLOAK, D. *A new treatment of inconsistent quadratic programs in a SQP based algorithm*. Computers and Chemical Engineering, v. 22, pp. 1623-1651, 1998.

- 
- GROSDIDIER, P., FROISY, B., HAMMANN, M. *The IDCOM-M controller*. Proceedings of the 1988 IFAC workshop on model based process control, pp. 31–36. Oxford: Pergamon Press, 1988.
- HALIM, A. B. *Detection and diagnosis of plant-model mismatch for real-time optimization*. Dissertação de mestrado, University of Alberta, Edmonton, 2003.
- IBARROLA, J. J., SANDOVAL, J. M., GARCÍA-SANZ, M., PINZOLAS, M. *Predictive control of a high temperature–short time pasteurisation process*. Control Engineering Practice, v. 10, pp. 713–725, 2002.
- KAYNAK, O., MELANÇON, P., RAJAGOPALAN, V. *Model predictive heuristic control of a position servo system in robotics*. IEEE Journal of Robotics and Automation, v. RA-3, n.5, 1987.
- KIM, K. B. *On stabilizing receding horizon controls for linear systems*. Computer Science & Electrical Engineering, California Institute of Technology, 2002.
- KRISHNAN, A., KOSANOVICH, K. A., DEWITT, M. R., CREECH, M. B. *Robust model predictive control of an industrial solid phase polymerizer*. Proceedings of the American Control Conference, pp. 3386-3390, 1998.
- KORCHINSKI, W. J., HOFFMAN, T. W., HOFFMAN, D. W. *Tips for control engineers*. Hydrocarbon Processing, v. 77, n. 9, pp. 113-118, 1998.
- KWON, W. H., HAN, S. H. *Receding Horizon Predictive Control*. Prentice Hall, 2003.
- LID, T., STRAND, S. *Real-time optimization of a cat cracker unit*. Computers and Chemical Engineering, v. 21, pp. 887-892, 1997.
- MAYNE, D. Q., MICHALSKA, H. *Receding horizon control of nonlinear systems*. IEEE Transactions on Automatic Control, New York, v. 35, n.7, pp.789–814, 1990.
- MAYNE, D. Q., RAWLINGS, J. B., RAO, C. V., SCOKAERT, P. O. M. *Constrained model predictive control: stability and optimality*. Automática, v. 36, pp. 789-814, 2000.
- MELEIRO, L. A.C. *Projeto e Aplicação de Controladores Baseados em Modelos Lineares, Neurais e Nebulosos*. Tese de doutorado, Universidade Estadual de Campinas, Campinas, São Paulo, 2002.
- MELO JR, W. S. *Controle preditivo generalizado adaptativo aplicado ao processo de craqueamento catalítico*. Dissertação de mestrado, Centro Federal de Educação Tecnológica do Paraná, Curitiba, 2003.
- McCORMICK, R., GAGNÉ, N., STEVEN, S., LAURIER, G., BROWN, M., PIETTE, R. *Real time optimization of fluid catalytic cracking and catalytic polymerization units*. NPRA Computer Conference, National Petroleum Refiners Association, Atlanta, 1996.

- 
- MORSHEDI, A. M., CUTLER, C. R., SKROVANEK, T. A. *Optimal solution of dynamix matrix control with linear programming techniques (LDMC)*. Proc. Am. Control Conf., Boston, pp.199-208, 1985.
- MORO, L. F. L. *Process technology in the petroleum refining industry - current situation and future trends*. Computer and Chemical Engineering, v. 27, pp. 1303-1305, 2003.
- MORO, L. F. L., ODLOAK, D., *Constrained multivariable control of fluid catalytic cracking converters*. Journal of Process Control, v. 5, n.1, pp. 29-39, 1995.
- OCHS, S., ENGELL, S., DRAEGER, A. *Decentralized vs. model predictive control of an industrial glass tube manufacturing process*. Proceedings of the IEEE International Conference on Control Applications, 1998.
- ODLOAK, D., GOUVÊA, M. T. *Control and optimization of a fluid catalytic cracking converter*. XI Congresso Brasileiro de Automática, São Paulo, pp. 1411-1416, 1996.
- OLIVEIRA, L. L., CARRAPIÇO, O. *Multivariable control increases coke unit, refinery throughput*. Hydrocarbon Processing, pp. 77-83, 1998.
- OGATA, K. *Engenharia de Controle Moderno*, 3ª ed., Editora Prentice-Hall do Brasil Ltda, Rio de Janeiro, Brasil, 1998.
- PEDERSEN, C. C., MUDD, D. R., BAILEY, J. K., AYALA, J. S. *Closed loop real time optimization of a hydrocracker complex*. NPRA Computer Conference, National Petroleum Refiners Association, Nashville, 1995.
- PORFÍRIO, C. R. *Implantação de um controlador multimodelos em uma coluna depropanizadora industrial*. Tese de mestrado. Escola Politécnica da Universidade de São Paulo, São Paulo, 2001.
- POTOCNIK, P., GRABEC, I. *Nonlinear model predictive control of a cutting process*. Neurocomputing, v. 43, pp. 107–126, 2002.
- PRETT, D. M., GILLETTE, R. D. *Optimization and constrained multivariable control of a catalytic cracking unit*. Proceedings of the joint automatic control conference, 1980.
- PROSDÓSSIMO, C. *Uma contribuição ao controle preditivo multivariável de unidades de craqueamento catalítico*. Dissertação de mestrado. Centro Federal de Educação Tecnológica do Paraná, Curitiba, 2003.
- QIN, S. J., BADGWELL, T. A. *An overview of nonlinear model predictive control applications*. Progress in Systems and Control Theory, v. 26, 2000.
- QIN, S. J., BADGWELL, T. A. *A survey of industrial model predictive control technology*. Control Engineering Practice, v. 11, pp. 733–764, 2003.



- 
- RABELLO, M. L. P., VILAS BOAS, A. T., PINOTTI, R., ZANIN, A. C., AREAL, O. F. *Implementação de um controlador de processo multivariável nas torres de pré-vaporização e de destilação atmosférica de petróleo*. Revista Petro & Química, ed. 269, 2005.
- RAMOS, C., SENENT, J. S., BLASCO, X., SANCHIS J. *LP-DMC control of a chemical plant with integral behaviour*. 15<sup>th</sup> IFAC Triennial World Congress, Barcelona, 2002.
- RICHALET, J., RAULT, A., TESTUD, J. L., PAPON, J. *Algorithmic control of industrial processes*. Proceedings of the 4th IFAC Symposium on Identification and System Parameter Estimation, pp. 1119-1167, 1976.
- RICHALET, J., RAULT, A., TESTUD, J. L., PAPON, J. *Model predictive heuristic control: applications to industrial processes*. Automatica, v. 14, pp. 413 – 428, 1978.
- ROBERTS, P. D. *A brief overview of model predictive control*. Special Feature in IEE Computing & Control Journal on Model Predictive Control, 1999.
- SAHA, P., KRISHNAN, S. H., RAO, V. S. R., PATWARDHAN, S. C. *Modeling and predictive control of mimo nonlinear systems using wiener-laguerre models*. Chemical Engineering Communications, v. 191, pp. 1083-1119, 2004.
- SÁNCHEZ, J. M. M. *Contribution to model reference adaptive systems from hyperstability theory*. Doctoral these, Univerdidad Politécnica de Catalunya, Barcelona, 1974.
- SÁNCHEZ, J. M. M., RODELLAR, J. *Adaptive predictive control. From the concepts to plant optimization*. Prentice-Hall, Madrid, 1996.
- SCHIAVON JR, A. L. *Estudo de duas estruturas de otimização em tempo real com controle preditivo QDMC*. Dissertação de mestrado, Universidade Federal de São Carlos, São Carlos, 1998.
- SCHIAVON JR, A. L., CORRÊA, R. G. *Applications of an alternative formulation for one layer real time optimization*. Brazilian Journal of Chemical Engineering, v. 17, n. 4-7, 2000.
- SCHLEY, M., PRASAD, V., RUSSO, L. P., BEQUETTE, B. W. *Nonlinear model predictive control of a styrene polymerization reactor*. Progress in Systems and Control Theory, v. 26, 2000.
- SEBORG, D. E., EDGAR, T. F., MELLICHAMP, D. A. *Process dynamics and control*. J. Wiley & Sons, New York, 1989.
- SÖDERSTRÖM, T.; STOICA, P. *System Identification*, Prentice Hall, New York, USA, 1989.
- SOETERBOEK, A.R., *Predictive Control: an unified approach*, Technische Universiteit Delft, 1990.

- 
- SOHLBERG, B. *Supervision and control for industrial processes: using grey box models, predictive control, and fault detection methods*. Springer, London, 1998.
- SORENSEN, R. C., CUTLER, C. R., *LP Integrates economics into dynamic matrix control*. Hydrocarbon Processing, pp.57-65, 1998.
- SORENSEN, P. H., NORGAARD, M., RAVN, O., POULSEN, N. K. *Implementation of neural networks based non-linear predictive control*. Neurocomputing, v. 28, pp. 37-51, 1999.
- TORRICO, B. C., NORMEY-RICO, J. E. *Controle preditivo de sistemas não lineares com atraso*. XV Congresso Brasileiro de Automatica, 2004.
- TOSUKHOWONG, T., LEE, J. M., LEE, J. H., LU, J. *An introduction to a dynamic plant-wide optimization strategy for an integrated plant*, Computers and Chemical Engineering v. 29, pp. 199-208, 2004.
- WALLER, J. B. *Concepts and methodologies in non-linear model predictive control*. Laboratory of Process Control, Abo Akademi University, Finland, 2000.
- WHITE, D. C. *On line optimization: What have we learned?* Hydrocarbon Processing, pp. 55-59, 1998.
- WOOD, R. K. BERRY, M. W. *Terminal composition of a binary distillation column*. Chemical. Engineering Sciences, v. 28, pp. 1707-1717, 1973
- YING, C. M., JOSEPH, B. *Performance and stability analysis of LP-MPC and QP-MPC cascade control systems*. AIChE Journal, v. 45, n. 7, pp. 1521-1534, 1999.
- YOUSFI, C., TOURNIER, R. *Steady-state optimization inside model predictive control*. Proceedings of ACC'91, Boston, pp. 1866–1870, 1991.
- ZANIN, A. C. *Implementação industrial de um otimizador em tempo real*. Tese de doutorado. Universidade de São Paulo, São Paulo, 2001.
- ZHENG, D., HOO, K. A. *System identification and model-based control for distributed parameter systems*. Computers and Chemical Engineering, v. 28, pp. 1361–1375, 2004.

## **RESUMO:**

Este trabalho apresenta um estudo de uma classe de controladores preditivos baseados em modelo, conhecido por QDMC, e sua aplicação em processos multivariáveis que apresentam características complexas e requerem a utilização de métodos de controle mais elaborados para atender as exigências destes processos.

Propõe-se a inserção de critérios de otimização resolvidos de forma periódica sob a estruturação de otimização em uma camada. Para comparação de resultados, uma segunda forma de implementação de otimização, conhecida por otimização hierárquica, é também implementada.

A aplicação das metodologias propostas é feita através de simulações com o uso de programas matemáticos. Os processos utilizados para o estudo são: Coluna de Destilação Wood-Berry e Unidade de Craqueamento Catalítico em Leito Fluidizado. A coluna de destilação é utilizada para exploração das abordagens de otimização, desta forma, são efetuadas simulações com diferentes funções econômicas com o objetivo de avaliar o desempenho das metodologias e o comportamento frente a critérios distintos. O modelo da Unidade de Craqueamento Catalítico em Leito Fluidizado é utilizado para uma análise final das técnicas propostas.

Os resultados obtidos demonstram uma maior flexibilidade de aplicação da otimização em uma camada, quando comparada à otimização hierárquica, por apresentar bom desempenho no tratamento de variáveis de difícil controle e na resolução de função econômica não linear.

## PALAVRAS-CHAVE

controle preditivo baseado em modelo, otimização de processos, processos multivariáveis

## ÁREA/SUB-ÁREA DE CONHECIMENTO

- 3.04.05.02-5 Automação eletrônica de processos elétricos e industriais.
- 1.03.03.00-6 Metodologia e técnicas da computação.
- 3.06.01.00-2 Processos industriais de engenharia química.

2006

Nº: 401