

**LUIS ANTONIO REZENDE MUNIZ**

**CONTROLE PREDITIVO ADAPTATIVO APLICADO A UM  
REATOR DE PIRÓLISE OPERANDO EM REGIME SEMI -  
BATELADA**

Tese submetida ao Programa de Pós-Graduação em Engenharia Química, Departamento de Engenharia Química e Engenharia de Alimentos, Universidade Federal de Santa Catarina, como requisito final à obtenção do título de Doutor em Ciências da Engenharia Química.

Orientador: Prof. Ariovaldo Bolzan, Dr.

Florianópolis, 2004

# **Controle Preditivo Adaptativo Aplicado a um Reator de Pirólise Operando em Regime Semi - Batelada**

Por

**Luis Antonio Rezende Muniz**

Tese julgada para obtenção do título de **Doutor em Engenharia Química**, área de concentração **Desenvolvimento de Processos Químicos e Biotecnológicos** e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia Química da Universidade Federal de Santa Catarina.

---

Prof. Dr. Ariovaldo Bolzan  
**Orientador**

---

Prof. Dr. Agenor Furigo Junior  
**Coordenador do CPGENQ**

## **Banca Examinadora:**

---

Prof. Dr. Ariovaldo Bolzan

---

Prof. Dra. Ana Maria Frattini Fileti

---

Prof. Dr. Laércio Ender

---

Prof. Dr. Leonel Teixeira Pinto

---

Prof. Dr. Humberto Jorge José

**Florianópolis, 16 de julho de 2004**

*Um Samurai, um Guardiã, uma Gurreira*

*Este trabalho é dedicado a **Rafael Costa Muniz**, meu filho, que me presenteou com um olhar que vai estar para sempre em minhas memórias;*

*a meu pai **João de Queiroz Muniz Filho** pelo orgulho incontido frente ao filho doutorando, mas que não pode ver o desfecho deste trabalho;*

*e a minha esposa **Ana Rosa Costa Muniz**, pelo exemplo de uma guerreira numa luta firme e obstinada pela vida.*

## AGRADECIMENTOS

Desejo expressar minha sincera e profunda gratidão para as seguintes pessoas e instituições que contribuíram para a realização deste trabalho:

Ao professor Ariovaldo Bolzan pela compreensão e ao firme apoio durante a caminhada.

A minha avó Antonia pela inocência, minha mãe pela esperança e aos meus irmãos João, Patrícia e Ana Cláudia pela tranquilidade de poder contar com eles a qualquer momento.

A Ana Rosa e Evandro, companheiros de viagens, disciplinas e camarões.

A Marcos Mazzucco pelas discussões iniciais sobre redes neurais e aquisição de dados.

A Caio e Jaime pela amizade e discussões sobre controle preditivo e redes neurais.

A Universidade de Caxias do Sul pelo apoio prestado no meu processo de qualificação.

## RESUMO

MUNIZ, Luis Antonio Rezende. **Controle Preditivo Adaptativo Aplicado a um Reator de Pirólise Operando em Regime Semibatelada**. Florianópolis, 2004. 133p. Tese (Doutorado em Engenharia Química) – Curso de Pós-Graduação em Engenharia Química, Universidade Federal de Santa Catarina.

Orientador: Ariovado Bolzan

Defesa: 16/07/2004

Neste trabalho é implementado um algoritmo de controle preditivo com modelo adaptativo em um reator de pirólise operando em regime semibatelada. Um reator de 8L e mais um sistema de separação foram desenvolvidos para este propósito. A temperatura do reator é controlada através de um sistema de controle digital implementado para este processo. O modelo utilizado para inferir sobre o processo é uma rede neural multicamada completamente recursiva. Inicialmente um controlador preditivo é implementado, notando-se um problema de desvio permanente da variável controlada em relação ao *set point*. Para evitar problemas de *offset* um algoritmo adaptativo é adotado, efetuando *on-line* a atualização dos pesos da rede. A rede neural é utilizada para prever explicitamente a saída do processo (temperatura do reator) através de um horizonte de predição pré-definido. Esse vetor de saída do processo é usado para estimar, através de otimização, as entradas do processo (potência de aquecimento). O Controlador preditivo adaptativo apresentou desempenho superior aos controladores clássicos do tipo retroalimentação, estabilizando a temperatura sem *overshoots* significativos, sem *offset* e conseguindo compensar os fortes distúrbios ocasionados pelo alívio da pressão do reator através da liberação parcial dos produtos da pirólise de borra de tinta.

Palavras-chave: Controle Preditivo; Controle Adaptativo, Redes Neurais; Pirólise, Reator Batelada

## ABSTRACT

In the present work it was developed a Self-Tuning Adaptive Model Predictive Control Algorithm to control a semi batch pyrolysis reactor. An 8L reactor and a separation system were assembled for this purpose. The reactor temperature control was carried out through a digital control system implemented for this process. The model used to infer about the process was a multilayered neural network completely recursive. Firstly, a model predictive control was implemented and an offset can be seen. To avoid offset problems an adaptive algorithm was applied, performing on-line weights actualization. The neural network was used to explicitly predict the process output (reactor temperature) through a pre-defined prediction horizon. Through optimization, this output vector was used to estimate the process input (heat power supply). The adaptive model process control shown a performance superior to a classic feedback controller. The temperature stabilizes without overshoots and offsets. The developed control algorithm was able to compensate the strong disturbances that occurs during the partial discharge of pyrolysis products, due to reactor pressure relief.

Key-Words: Model Predictive Control, Adaptive Control, Neural Networks, Pyrolysis, Semi Batch Reactor

# SUMÁRIO

LISTA DE FIGURAS .....	xi
LISTA DE TABELAS .....	xv
NOMENCLATURA .....	xvi
<b>Capítulo 1.....</b>	<b>1</b>
<b>1 Introdução .....</b>	<b>1</b>
<b>Capítulo 2.....</b>	<b>5</b>
<b>2 Objetivo .....</b>	<b>5</b>
2.1 Objetivo Geral .....	5
2.2 Objetivos Específicos .....	5
<b>Capítulo 3.....</b>	<b>7</b>
<b>3 O Estado da Arte .....</b>	<b>7</b>
3.1 O Processo de Pirólise .....	7
3.2 Controle Preditivo .....	15
3.2.1 Controle LQG .....	16
3.2.2 IDCOM – Identificação e Comando .....	19
3.2.3 DMC – Controle por Matriz Dinâmica .....	19
3.2.4 QDMC – Controle por Matriz Dinâmica com Programação Quadrática.....	21
3.2.5 Terceira Geração .....	22
3.2.6 Quarta Geração .....	22
3.2.7 Modelos do Processo .....	23
3.2.7.1 Modelos Fenomenológicos Não Lineares .....	24
3.2.7.2 Modelos Empíricos Lineares.....	24
3.2.7.3 Modelos Empíricos Não Lineares .....	25
3.2.8 Aplicações de Controladores Preditivos .....	27
3.3 Controle Adaptativo .....	32
<b>Capítulo 4.....</b>	<b>42</b>
<b>4 Fundamentação Teórica .....</b>	<b>42</b>

4.1 O Controle Preditivo .....	42
4.1.1 A Estratégia do MPC .....	44
4.1.2 A Função Objetivo .....	46
4.1.2.1 Parâmetros .....	47
4.1.2.2 Trajetória de Referência .....	48
4.1.2.3 Restrições .....	49
4.1.2.4 Restrições de Sobre Elevação .....	50
4.1.2.5 Comportamento Monotônico .....	50
4.1.3 Obtenção da Lei de Controle .....	50
4.1.4 Modelos para o MPC .....	51
4.1.4.1 Linear ou Não Linear .....	51
4.1.4.2 Contínuo ou Discreto .....	52
4.1.4.3 Parâmetros Distribuídos ou Parâmetros Agrupados .....	52
4.1.4.4 Determinístico ou Estocástico .....	53
4.1.4.5 Entrada-Saída ou Espaço de Estado .....	53
4.1.4.6 Fenomenológicos ou “Caixa Preta” .....	54
4.2 Controlador Adaptativo .....	55
4.2.1 Adaptação Programada .....	56
4.2.2 Controlador Auto-Ajustável .....	57
<b>Capítulo 5.....</b>	<b>61</b>
<b>5 Metodologia.....</b>	<b>61</b>
5.1 Local de Trabalho: Laboratório de Reatores .....	61
5.2 Aparato Experimental .....	63
5.2.1 Sistema Operacional I: Retorta .....	64
5.2.2 Sistema Operacional II: Reator de Pirólise .....	66
5.2.3 Operação dos Aparatos Experimentais .....	67
5.3 Os Algoritmos de Controle .....	67
5.3.1 O Modelo do Processo .....	68
5.3.2 O Controlador Proporcional – Integral – Derivativo (PID) .....	68
5.3.3 O Controlador Preditivo .....	71
5.3.4 O Controlador Preditivo Adaptativo .....	73

5.4 O Código Computacional para o Sistema de Controle Digital .....	75
<b>Capítulo 6: .....</b>	<b>80</b>
<b>6 Resultados e Discussões .....</b>	<b>80</b>
6.1 Controle da Retorta .....	81
6.1.1 Controlador do Tipo Retroalimentação .....	81
6.1.1.1 Identificação do Sistema .....	81
6.1.1.2 Sintonia do Controlador .....	83
6.1.1.3 Teste do Controlador do Tipo Retroalimentação .....	84
6.1.2 Controlador Preditivo .....	85
6.1.2.1 Treinamento da Rede Neural .....	86
6.1.2.2 Sintonia do Controlador .....	86
6.1.3 Comparação Entre os Controladores .....	88
6.2 Controle do Reator de Pirólise .....	92
6.2.1 Redução dos Ruídos .....	92
6.2.2 Identificação do Sistema .....	94
6.2.3 Ajuste do Controlador do Tipo Retroalimentação .....	98
6.3 Ajuste do Controlador Preditivo .....	106
6.4 Ajuste do Controlador Preditivo e do Controlador Preditivo Adaptativo .....	113
6.5 Comparação dos Algoritmos de Controle .....	118
<b>Capítulo 7 .....</b>	<b>122</b>
<b>7 Conclusões .....</b>	<b>122</b>
<b>Capítulo 8 .....</b>	<b>126</b>
<b>8 Bibliografia .....</b>	<b>126</b>
<b>Anexo A 1 .....</b>	<b>135</b>
<b>Efeito da Massa de Resíduo Sobre o Calor Fornecido ao Reator de Pirólise .....</b>	<b>135</b>
<b>Anexo A 2 .....</b>	<b>136</b>
<b>Código Computacional do Controlador Preditivo Adaptativo .....</b>	<b>136</b>
<b>Anexo A 3 .....</b>	<b>163</b>

<b>Influência Qualitativa da Temperatura e do Tempo de Reação nos Produtos Gasosos da Pirólise de Borra de Tinta.....</b>	<b>163</b>
<b>Anexo A 4.....</b>	<b>164</b>
<b>Influência Qualitativa da Temperatura e do Tempo de Reação nos Produtos Líquidos da Pirólise de Borra de Tinta.....</b>	<b>164</b>
<b>Anexo A 5.....</b>	<b>165</b>
<b>Caracterização Física do Óleo Obtido pela Pirólise da Borra de Tinta .....</b>	<b>165</b>
<b>Anexo A 6.....</b>	<b>166</b>
<b>Influência da Temperatura e Tempo de Batelada Sobre o Rendimento do Óleo de Pirólise da Borra de Tinta.....</b>	<b>166</b>

## LISTA DE FIGURAS

Figura 3-1 - Diferenciação na estrutura química entre moléculas de dioxina e furano.....	9
Figura 3-2 - Formação de dioxinas e furanos a partir de reações superficiais catalíticas. ...	10
Figura 3-3 - Balanço para o cloro para três reatores agitados em seqüência. A mistura contém uma proporção de 1:6:3 em peso de PVC, poliestireno e polietileno. ....	11
Figura 3-4 - Graus de conversão calculadas para decomposição batelada de uma mistura de PVC, PS e PE (1:1:1 em peso) a várias temperaturas em uma pirólise em degraus a baixa temperatura.	14
Figura 3-5 - Evolução aproximada dos algoritmos lineares MPC. Adaptada de QIN e BADGWELL, 2003.....	21
Figura 4-1 - Estratégia do controlador preditivo (MPC).....	45
Figura 4-2 - Estrutura básica de um algoritmo de controle preditivo. ....	46
Figura 4-3 - Diagrama de blocos representando a estrutura do algoritmo de controle com adaptação programada. ....	57
Figura 4-4 - Diagrama de blocos representando o algoritmo de controle adaptativo auto-ajustável. ....	58
Figura 4-5 - Diagrama de blocos representando a estrutura do algoritmo de controle adaptativo com modelo de referência. ....	59
Figura 5-1 - Vista parcial do sistema de pirólise de 0.5 L do Laboratório de Reatores do Departamento de Engenharia Química da Universidade de Caxias do Sul.....	62
Figura 5-2 - Foto do sistema de pirólise com reator de 8 L. ....	63
Figura 5-3 - Fluxograma do processo de pirólise. ....	65
Figura 5-4 - Diagrama de blocos do sistema de controle de temperatura do reator de pirólise.	66
Figura 5-5 - Representação esquemática de uma rede neural completamente recorrente...	73
Figura 5-6 - Definição do padrão de treinamento utilizando o procedimento da janela móvel.	74
Figura 5-7 - Fluxograma do algoritmo do controlador preditivo e adaptativo. ....	75

Figura 5-8 - Módulo de configuração da placa de aquisição de dados.....	76
Figura 5-9 - Código computacional para o controle digital operando em malha aberta. ....	77
<b>Figura 5-10</b> - Seleção do algoritmo de controle a ser usado. ....	78
Figura 6-1 - Validação do modelo de primeira ordem mais tempo morto para a retorta. ....	83
Figura 6-2 - Comportamento dinâmico do controlador do tipo retroalimentação a uma perturbação no <i>set point</i> .....	84
Figura 6-3 - Esforço do controlador do tipo retroalimentação para condizir o processo de pirólise a um novo <i>set point</i> .....	85
Figura 6-4 - Comparação da performance do controlador preditivo para diferentes horizontes de predição e controle.....	87
Figura 6-5 - Esforço do controlador preditivo para diferentes horizontes de predição e controle.	88
Figura 6-6 - Comparação entre o algoritmo de controle do tipo retroalimentação e o Controlador preditivo com horizontes de controle e predição iguais a 30. ....	89
Figura 6-7 - Comparação do esforço dos controladores do tipo retroalimentação e preditivo para conduzir a temperatura do reator da temperatura ambiente até 320°C.....	90
Figura 6-8 - Comparação da performance dos algoritmos de controle, quando o processo é submetido a uma perturbação.....	90
Figura 6-9 - Esforço de diferentes controladores para suprimir o efeito de distúrbios no processo.	91
Figura 6-10 - Análise dos efeitos do curto-circuito nos canais analógicos de leitura não utilizados e do filtro sobre os ruídos, na leitura da temperatura do reator.....	93
Figura 6-11 - Comparação dos resultados obtidos com o teste a degrau no reator de pirólise com o modelo de primeira ordem mais tempo morto. Os parâmetros obtidos foram $K_p = 116.5 \frac{^{\circ}\text{C}}{\text{V}}$ , $\tau_p = 51.0 \text{ min}$ e $\theta = 13.3 \text{ min}$ .....	95
Figura 6-12 - Comparação dos resultados obtidos com o teste a degrau no reator de pirólise com o modelo de primeira ordem mais tempo morto. Os parâmetros obtidos foram $K_p = 189.3 \frac{^{\circ}\text{C}}{\text{V}}$ , $\tau_p = 30.3 \text{ min}$ e $\theta = 6.5 \text{ min}$ .....	96

Figura 6-13 - Comparação dos resultados obtidos com o teste a degrau no reator de pirólise com o modelo de primeira ordem mais tempo morto. Os parâmetros obtidos foram $K_p = 183.4 \frac{^{\circ}\text{C}}{V}$ , $\tau_p = 40.4 \text{ min}$ e $\theta = 3.6 \text{ min}$ .....	97
Figura 6-14 - Comparação dos resultados obtidos com o teste a degrau no reator de pirólise com o modelo de primeira ordem mais tempo morto. Os parâmetros obtidos foram $K_p = 140.3 \frac{^{\circ}\text{C}}{V}$ , $\tau_p = 31.2 \text{ min}$ e $\theta = 12.7 \text{ min}$ .....	98
Figura 6-15 - Resultado de um sistema servo com controlador PID. $K_C = 0.015 \frac{V}{^{\circ}\text{C}}$ , $\tau_I = 42.26 \text{ min}$ , $\tau_D = 4.17 \text{ min}$ e $\alpha = 0.9$ .....	100
Figura 6-16 - Esforço do controlador PID para conduzir o processo da temperatura ambiente até 250°C e em seguida, até 400°C.....	101
Figura 6-17 - Comparação da performance do controlador PID para diferentes filtros na ação derivativa.....	102
Figura 6-18 - Esforço do controlador PID para diferentes filtros na ação derivativa.....	102
Figura 6-19 - Comportamento da temperatura do reator à perturbações degrau no <i>set point</i> , para um controlador PI. ....	103
Figura 6-20 - Esforço do controlador PI para conduzir o processo da temperatura ambiente até 250°C e em seguida, até 400°C.....	104
Figura 6-21 - Comparação da dinâmica do processo ao ser conduzido para diferentes <i>set points</i> por controladores PI e PID.....	105
Figura 6-22 - Esforço dos controladores PI e PID frente a problemas servo. ....	106
Figura 6-23 - Desempenho do controlador para diferentes fatores de penalização no esforço do controlador. Horizonte de Predição igual a 10 e de controle igual a 1. ....	107
Figura 6-24 - Esforço do controlador para diferentes penalizações impostas nas variações da ação de controle. Horizonte de Predição igual a 10 e de controle igual a 1.....	108
Figura 6-25 - Desempenho do controlador preditivo com horizonte de controle igual a 1 e diferentes horizontes de predição.....	109

Figura 6-26 - Esforço do controlador preditivo para horizonte de controle igual a 1 e diferentes horizontes de predição. ....	110
Figura 6-27 - Eliminação do <i>offset</i> mediante alteração dos pesos da rede neural através do treinamento <i>on-line</i> . ....	112
Figura 6-28- Ações do controlador submetido a trocas dos pesos para eliminação do <i>offset</i> . ....	112
Figura 6-29 - Influência do tamanho da janela móvel no desempenho do controlador preditivo com horizonte de controle igual a 1 e de predição igual a 18. ....	114
Figura 6-30 - Influência do tamanho da janela móvel no esforço do controlador preditivo com horizonte de controle igual a 1 e horizonte de predição igual a 18. ....	115
Figura 6-31- Efeito do esquema de adaptação na eliminação do <i>kickback</i> . Controladores preditivos e adaptativos com horizonte de predição igual a 45 e horizonte de controle igual a 1. ....	117
Figura 6-32 - Esforço do controlador com diferentes esquemas de adaptação, na tentativa de eliminar o <i>kickback</i> . ....	117
Figura 6-33 - Evolução da pressão sujeita a pulsos ao longo da reação de pirólise de borra de tinta. ....	119
Figura 6-34 - Comparação dos algoritmos de controle durante uma reação de pirólise de borra de tinta sujeita a pulsos na pressão. ....	120
Figura 6-35 - Esforço dos controladores durante uma reação de pirólise de borra de tinta sujeita a pulsos na pressão. ....	120

## LISTA DE TABELAS

Tabela 5-1 - Fórmulas para sintonia de controladores PID pelo método ITAE submetidos a mudanças no <i>set point</i> .....	70
Tabela 5-2 - Fórmulas para sintonia de controladores PID pelo método ITAE submetidos um problema regulador.....	71
Tabela 5-3 - fórmulas para a sintonia de controladores PI pelo método ITAE submetidos a um problema servo.....	71
Tabela 6-1 - Parâmetros do modelo do processo (primeira ordem mais tempo morto) obtidos pelo <i>Digest<sup>TM</sup></i> .....	83
Tabela 6-2 - Parâmetros do controlador obtidos pelo método IAE ( <i>Integral of Absolute Error</i> ).84	
Tabela 6-3 - Parâmetros do controlador preditivo.....	87
Tabela 6-4 - Comparação entre os critérios de desempenho relativos para os algoritmos de controle.....	89
Tabela 6-5 - Compilação dos parâmetros do modelo de primeira ordem mais tempo morto para os diversos testes a degrau implementados. ....	98
Tabela 6-6 - Sintonia do controlador PID pelo método ITAE para perturbações no <i>set point</i> . Cálculos efetuados para os diversos modelos da seção anterior. ....	100
Tabela 6-7 - Índices de performance ITAE relativos entre os controladores PI e PID no controle da temperatura de um reator de pirólise.....	105
Tabela 6-8 - Análise comparativa dos critérios de desempenho (ITAE) do controlador preditivo com diferentes tamanhos de janelas móveis. ....	114
Tabela 6-9 - Índices de performance ITAE relativos entre os controladores preditivo e adaptativo e PI no controle da temperatura de um reator de pirólise.....	121

## NOMENCLATURA

$c$	Saída do controlador
$d$	Distúrbio medidos
$E$	Erro no domínio de Laplace
$h$	Coefficientes do modelo obtido a partir de uma resposta a impulso
$J$	Função objetivo a ser minimizada
$K_c$	Ganho do controlador PID
$K_f$	Ganho do filtro de Kalman
$K_p$	Ganho do processo
$N_1$	Valor mínimo do horizonte de predição
$N_2$	Valor máximo do horizonte de predição
$N_u$	Valor do horizonte de controle
$Q$	Fluxo de calor
$r$	Evolução futura da referência
$R$	Referência no domínio de Laplace
$S$	Coefficientes do modelo linear obtido a partir de uma resposta a degrau
$t$	Tempo
$T$	Temperatura do reator
$T_m$	Medida da temperatura
$u$	Variável manipulada
$U$	variável manipulada no domínio de Laplace
$v$	Distúrbios não medidos
$\hat{y}$	Estimativa da variável controlada
$y$	Variável controlada
$y_{ref}$	trajetória de referência
$\hat{x}$	Estimativa dos estados do processo

$x$	Estados do processo a ser controlado
$\alpha$	Fator de correção para a trajetória
$\delta$	Fator de ponderação para a penalização do erro
$\chi$	Constante do filtro para a ação derivativa do controlador PID
$\delta$	Fator de penalização do erro
$\Delta u$	Esforço do controlador
$\lambda$	Fator de penalização do esforço do controlador
$\eta$	Constante do filtro da ação derivativa do controlador PID
$\theta$	Retardo dinâmico do processo
$\tau_D$	Tempo derivativo do controlador PID
$\tau_I$	Tempo integral do controlador PID
$\tau_P$	Constante de tempo dominante do processo
$\xi$	Ruído

# Capítulo 1

## Introdução

---

O aumento contínuo dos resíduos industriais e a necessidade de fornecer um destino adequado para os mesmos têm estimulado a pesquisa por processos que eliminem ou ao menos reduzam estes rejeitos. A pirólise é um processo de tratamento térmico que vem sendo bastante utilizado no aproveitamento desses materiais. Este processo tem sido aplicado para o tratamento de resíduos plásticos, borra de tinta, resíduos domésticos e hospitalares, areia de fundição, entre outros.

A temperatura de reação do processo de pirólise é uma variável importante, a qual irá determinar, juntamente com o tempo de residência do material a ser pirolisado, as características do produto final obtido. A pirólise aparece como uma alternativa aos processos de incineração que produzem dioxinas e furanos, compostos químicos altamente nocivos à saúde humana. Estes compostos formam-se a temperaturas elevadas e na presença de cloro e oxigênio. O controle da temperatura da reação torna-se uma tarefa primordial na determinação do rendimento do processo e qualidade dos produtos obtidos.

Qualquer que seja a estratégia de controle adotada, o conhecimento da dinâmica do processo é um dos primeiros passos na busca da estratégia e sintonia do controlador. Devido às inúmeras reações que ocorrem no reator de pirólise, o desenvolvimento de um modelo matemático, a partir de balanços de massa e energia, torna-se uma tarefa extremamente complexa, além do que, o número de equações necessárias inviabiliza a sua

solução para aplicações em controle *on-line*. Existem modelos simplificados que analisam apenas o rendimento da pirólise, não fazendo o estudo por componente. Entretanto, existem muitas divergências quanto à representatividade destes modelos.

Diversos trabalhos apresentados na literatura mostram que as redes neurais podem reduzir consideravelmente o esforço necessário para a obtenção de um modelo matemático, principalmente quando se trata de sistemas não lineares, com parâmetros físico-químicos de difícil/custosa determinação.

Sob o ponto de vista do controle, processos em batelada ou semibatelada carecem de um melhor estudo, visto que tais processos sofrem uma grande variação no seu ponto de operação. Desta forma, o controle clássico, baseado em modelos lineares, tem sua performance prejudicada, uma vez que essa técnica apresenta bom desempenho apenas próximo ao ponto de linearização. Algumas alternativas são apontadas na literatura especializada, destacando-se entre elas o controle preditivo e o controle adaptativo.

O controle preditivo é apontado na literatura moderna como uma ferramenta de grande potencial para aplicações em processos não lineares e que são submetidos a grandes variações durante a sua operação. Esta técnica utiliza um modelo interno, o qual irá estimar os estados futuros do processo num intervalo (horizonte de predição) pré-definido. Estas estimativas serão utilizadas para o cálculo das ações de controle.

Neste trabalho propõe-se um sistema de controle para um reator de pirólise que opera em regime semibatelada. A estratégia proposta utiliza uma filosofia de controle preditivo e adaptativo, auto - ajustável, utilizando as redes neurais artificiais como modelo do processo. Foi utilizado um reator de bancada disponível na Universidade de Caxias do Sul. Devido às características construtivas do reator, o sistema apresenta grande retardo dinâmico (cerca de 12 minutos), sendo o mesmo variável, dependendo do ponto de operação. Além disto, a modelagem fenomenológica do reator torna-se uma tarefa

complexa devido à grande quantidade de reações que ocorrem durante o processo de pirólise. As redes neurais artificiais têm sido aplicadas com êxito para descrever o comportamento de sistemas estáticos ou dinâmicos e não lineares. A estrutura da rede mais empregada em processos químicos tem sido a *feedforward*, com o algoritmo de treinamento *backpropagation*. Entretanto, um elevado número de iterações é necessário para o ajuste dos parâmetros da rede neural, sendo apontadas algumas dificuldades para sua aplicação em tempo real, como em controle adaptativo de processos, devido à necessidade de um elevado tempo de processamento computacional para o seu treinamento. Através da técnica da janela móvel o tempo de “aprendizagem” da rede pode ser consideravelmente reduzido, diminuindo-se o padrão de treinamento.

O controlador proposto baseia-se na minimização de um critério de desempenho quadrático, onde a rede neural é o modelo do processo. É levada em consideração, na função objetivo, tanto a diferença entre a trajetória proposta para a temperatura do reator e o valor predito pelo modelo, quanto um fator de penalização para oscilações na variável manipulada. A rede neural utilizada tem uma estrutura recorrente, de forma a melhorar o desempenho da mesma na predição do comportamento dinâmico do sistema. Esta estrutura foi utilizada desde o treinamento da rede, onde o horizonte de predição definia o número de pontos futuros que a rede tinha que prever, sendo estes valores confrontados com o padrão de treinamento. Apesar da boa predição do comportamento dinâmico do sistema, a rede apresentou dificuldades na representação do estado estacionário, gerando *offsets* significativos. Estes, por sua vez, puderam ser eliminados através do treinamento *on-line* da rede. Foram realizados testes comparativos analisando a influência dos parâmetros do controlador no seu desempenho, sendo estes resultados confrontados com o controlador clássico do tipo retroalimentação.

O trabalho está dividido em sete capítulos. Os objetivos traçados para este trabalho são apresentados no capítulo 2. O capítulo 3 traz uma revisão bibliográfica apresentando o estado da arte para o processo de pirólise, e principalmente, o estado da arte do controle de preditivo e adaptativo. O capítulo 4 apresenta os fundamentos teóricos do controle preditivo e do controle adaptativo, os quais foram empregados no desenvolvimento deste trabalho. O capítulo 5 descreve a metodologia utilizada para o desenvolvimento do trabalho. O processo com o reator e o sistema de separação, além da instrumentação, é apresentado. O método usado para a sintonia do controlador do tipo retroalimentação é descrito. O algoritmo do controlador proposto, além do algoritmo de adaptação *on-line* também é discutido. O capítulo 6 traz uma aplicação das estratégias de controle feedback e dos controladores preditivo e proeditivo adaptativo discutidos no controle da temperatura da pirólise de borra de tinta. O índice de performance ITAE (*Integral of the Time-Weighted Absolute Value of the Error*) é usado como critério de desempenho, o mesmo usado na sintonia do controlador do tipo retroalimentação. Por fim, o capítulo 7 apresenta as principais conclusões obtidas com o desenvolvimento deste trabalho e aponta alguns desdobramentos que merecem um estudo futuro.

# Capítulo 2

## Objetivo

---

### 2.1 Objetivo Geral

Desenvolver um algoritmo de controle para controlar a temperatura de um reator de pirólise operando em regime semibatelada.

### 2.2 Objetivos Específicos

*a) Desenvolver um código computacional para o controle digital do reator de pirólise.*

*b)- Estudar os algoritmos de controle propostos:* Realizar uma profunda revisão bibliográfica sobre os algoritmos de controle propostos, buscando suas características positivas e procurando soluções para suas deficiências, gerando assim um algoritmo de controle simples e eficiente.

*c) Estudar a performance das Redes Neurais Recursivas como modelo dinâmico para o reator de pirólise:* Analisar o poder de predição das redes neurais para diferentes horizontes de predição e sua capacidade de predizer o comportamento dinâmico do reator de pirólise.

*d) Avaliar o algoritmo de controle proposto:* implementar o algoritmo de controle em um reator de pirólise operando com diferentes resíduos e avaliar o efeito de seus

parâmetros na performance do controlador. Comparar seu desempenho com o do controlador do tipo retroalimentação.

Os capítulos seguintes apresentam as etapas percorridas para se atingir os objetivos propostos, iniciando, no próximo capítulo, com o estudo do estado da arte do processo de pirólise, indicando as dificuldades de uma modelagem fenomenológica. É feito ainda, um estudo mais detalhado das aplicações de controladores preditivos e adaptativos em processos químicos.

# Capítulo 3

## O Estado da Arte

---

A intenção deste capítulo é apresentar um panorama das principais publicações sobre aplicações da pirólise no aproveitamento de resíduos industriais, os esforços envidados na tentativa de modelar este processo, assim como o atual estado de desenvolvimento e aplicações do controle preditivo e do controle adaptativo em processos químicos, foco principal deste trabalho.

### 3.1 O Processo de Pirólise

A pirólise é um método de reciclagem terciária, que consiste numa reação de degradação térmica na ausência, ou com uma mínima quantidade de oxigênio, de forma a obter produtos de valor no mercado. A decomposição de uma substância por ação exclusiva do calor denomina-se pirólise (MORRISON e BOYD, 1993). Esta palavra, que deriva do grego (*pyr* = fogo e *lysis* = desprendimento) tem para os químicos o significado de decomposição pelo calor, fazendo uma analogia com a hidrólise que é a decomposição pela água.

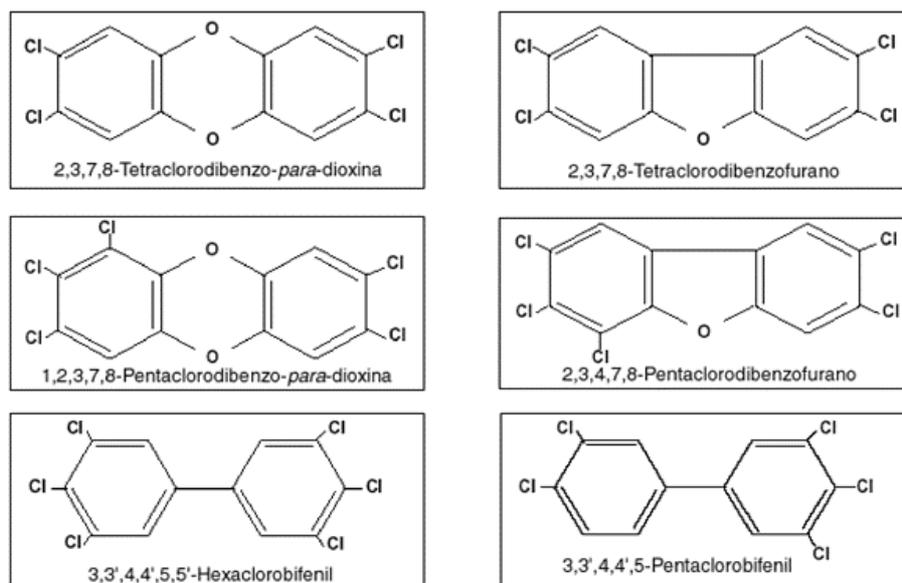
A crescente quantidade de resíduos industriais tem incentivado o desenvolvimento de processos de reuso. Dentre estes processo destacam-se a incineração, a degradação química, moagem e reutilização e a pirólise (FIGUEREDO, 1991). Dentre os processo

térmicos as principais vantagens da pirólise sobre a combustão ou incineração é que de cinco a vinte vezes menos gás é produzido, significando que podem ser feitas consideráveis economias na lavagem de gases e, além disto, o fato de se trabalhar na ausência de oxigênio, evita a formação de compostos oxigenados, como dioxinas e furanos, compostos extremamente tóxicos (LIMA, 1998).

As dibenzo-para-dioxinas policloradas (PCDD) e os dibenzofuranos policlorados (PCDF), ou simplesmente dioxinas e furanos, são duas séries de compostos com ligações tricíclicas aromatzadas, involuntariamente sintetizadas de forma plana, com características físicas, biológicas, químicas e ultratóxicas semelhantes. Os átomos de cloro se ligam nestes compostos criando possibilidades de um grande número de isômeros – 75 para as dioxinas e 135 para os furanos. Estes isômeros, também chamados congêneres, são compostos derivados de uma mesma classe química, possuindo igual fórmula, mas átomos em posições diferentes.

A diferença entre dioxinas e furanos, como pode ser visto na Figura 3-1, é que as primeiras – com dois oxigênios, contra só um dos furanos – correspondem a moléculas mais fixas.

O principal precursor na formação de dioxinas e furanos é a presença de cloretos, devendo-se inibir a sua presença nos produtos obtidos. As dioxinas derivam de reações em moléculas de cloro expostas à grande pressão e temperaturas em ambientes fartos de matéria orgânica. Estudos sugerem um mecanismo para a formação das dioxinas e dos furanos (EDULJEE e CAINS, 1997). Em se tratando de processos pirolíticos o problema apareceria na queima do óleo combustível. Uma ilustração do mecanismo pode ser visualizada na Figura 3-2. O mecanismo poderia ser subdividido em:

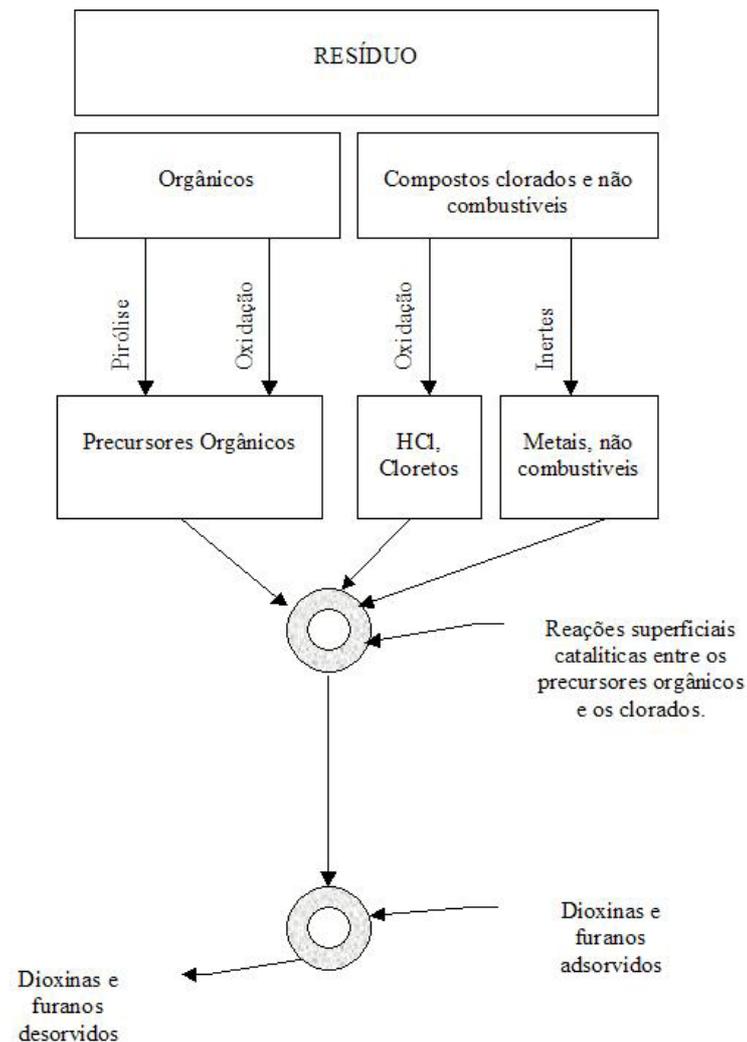


**Figura 3-1** - Diferenciação na estrutura química entre moléculas de dioxina e furano.

- A combustão incompleta da matéria orgânica leva à formação de fragmentos orgânicos, que serviriam como precursores das moléculas de dioxinas e furanos;
- A existência de cloro (liberado do resíduo durante a pirólise) e metais é fator imprescindível para a formação das dioxinas e furanos;
- O precursor orgânico adsorve na superfície metálica e seguindo uma seqüência complexa de reações leva a formação dos componentes indesejados.

Na pirólise em estágios o teor de cloro eventualmente presente no resíduo pode ser significativamente reduzido, evitando a possibilidade de formação de dioxinas e furanos (BOCKHORN et al., 1999). A Figura 3-3 apresenta o balanço de cloro durante a pirólise de uma mistura de polímeros (PVC, PS e PE) através de três reatores. O resíduo do primeiro e segundo reator é transportado para o terceiro reator. A quantidade de cloro no resíduo do terceiro reator é cerca de 0.2% em peso. Uma pequena quantidade de cloro foi detectada no gás de pirólise do segundo e terceiro reator.

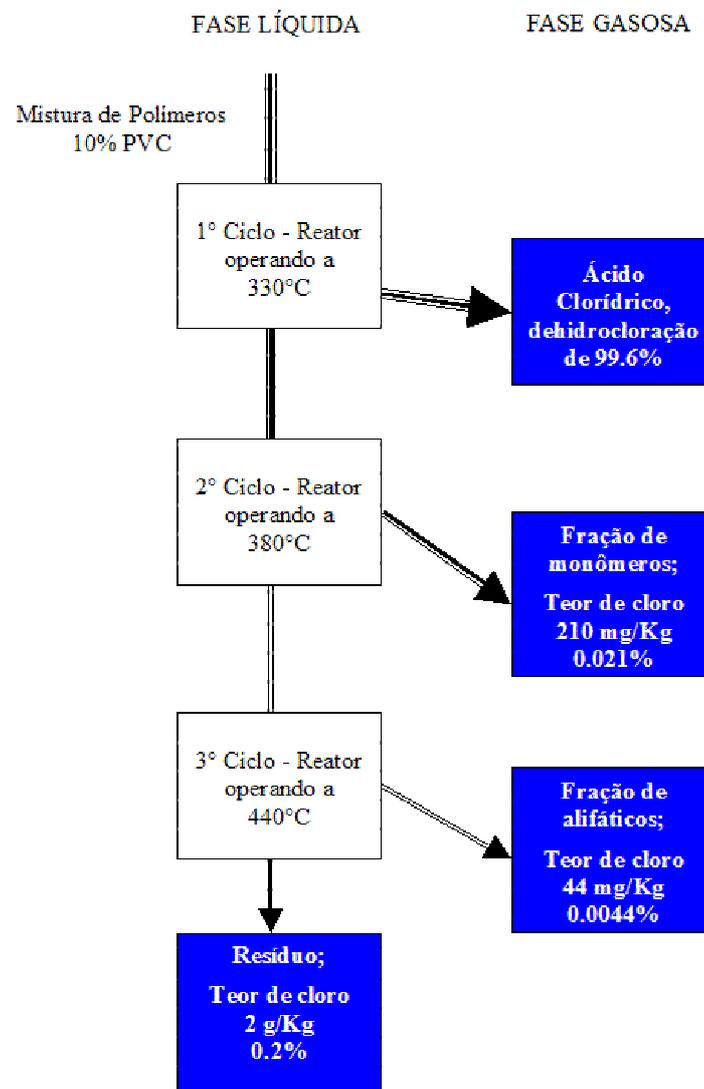
As primeiras experiências com reatores pirolíticos tiveram origem na Alemanha (LIMA, 1991). No final da Segunda Guerra Mundial, os alemães, utilizando estudos de Winkler, produziram gases combustíveis (metano e isobutano) a partir de resíduos domésticos auxiliando na movimentação da sua frota.



**Figura 3-2** - Formação de dioxinas e furanos a partir de reações superficiais catalíticas.

Nos Estados Unidos as pesquisas com reatores pirolíticos começaram em 1929 com o desenvolvimento de um protótipo para carbonização de carvão. Aproveitando a experiência, foram introduzidos no reator resíduos de pneus, sendo estes os primeiros resíduos industriais a serem pirolisados. Um gás com alto poder calorífico, óleos e

resíduos sólidos foram obtidos nestas corridas. Com resultados iniciais proveitosos novos resíduos foram introduzidos no reator como plásticos e resíduos de curtumes (LIMA, 1991).



**Figura 3-3** - Balanço para o cloro para três reatores agitados em seqüência. A mistura contém uma proporção de 1:6:3 em peso de PVC, poliestireno e polietileno.

No Brasil, a utilização da pirólise de resíduos industriais concentra-se na Petrobrás do Paraná (PETROSIX), que realiza o processo de pirólise de pneus, reaproveitando a fase gasosa e parte da fase líquida da reação como combustível e a parte mais pesada do líquido é aplicada como aditivo em asfaltos (NOVICKI, 2000).

O aproveitamento de diferentes resíduos por meio da pirólise tem sido estudado por diversos autores: (BALLICE et al., 1998; LIN et al., 1999; ISLAM et al., 1999; KIM e KIM, 2000) no aproveitamento de óleos; (BOCKHORN et al., 1999; DOMINGUEZ, et al., 2001; MOUSQUES, et al., 2001; ARENA e MASTELLONE, 2001; MASTELLONE e ARENA, 2002) analisaram o reaproveitamento de resíduos plásticos; (KAMINSKI, 1991, LOVETT et al., 1997, JANSE et al., 2000; ISLAM e ANI, 2000, DI BLASI, 2002, WURZENBERGER et al., 2002) testaram a pirólise como alternativa para o reaproveitamento de madeira e biomassa; (SEBASTIAN e DOBOSZ, 1988; ERDMAN e JOHNSON, 1989; MITCHELL e SCHWEERS, 1989; KIM et al., 1996; KIM et al., 1997; NAKOUZI, et al., 1998) verificaram a viabilidade técnica da pirólise da borra de tinta. Na pirólise formam-se três fases, buscando-se uma fase gasosa atóxica e com alto poder calorífico, uma fase líquida que pode ser aproveitada como óleo combustível e uma quantidade mínima de sólidos. As proporções entre as fases e a qualidade das mesmas são determinadas, principalmente, pela temperatura da reação de pirólise (MUNIZ et al. 2003).

Para que estas metas sejam atingidas é primordial um bom conhecimento dos possíveis componentes formados durante a reação de pirólise, assim como os mecanismos de formação dos produtos. Os diferentes componentes do resíduo orgânico atingem suas temperaturas de decomposição e começam a liberar uma ou mais das seguintes substâncias:

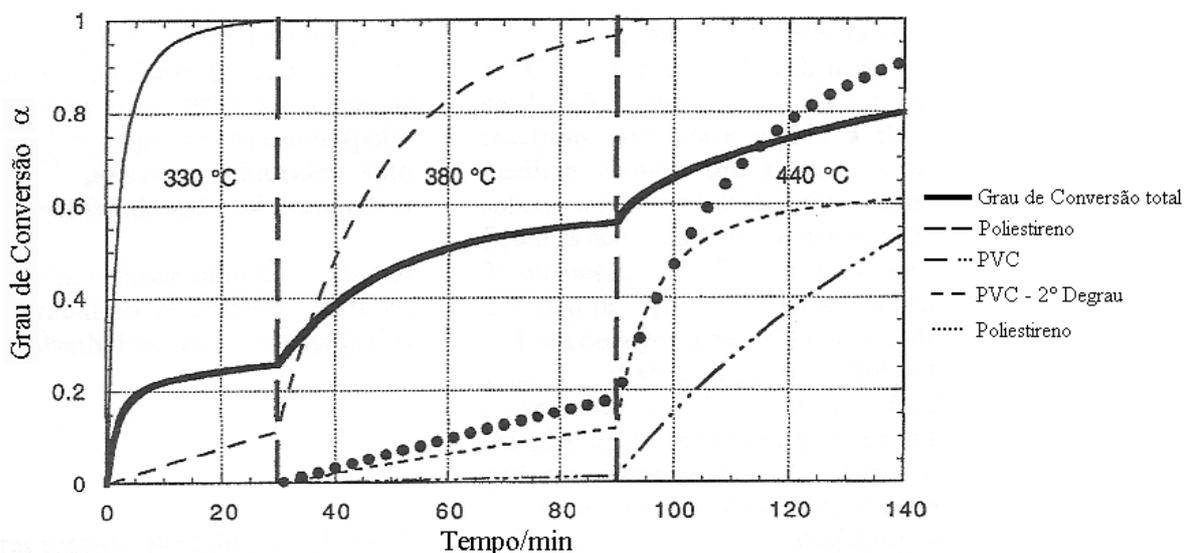
- a) Gases combustíveis como alcanos, alcenos, formaldeído e monóxido de carbono;
- b) Gases não combustíveis como vapor de água e dióxido de carbono;
- c) Gases corrosivos como cloreto de hidrogênio e brometo de hidrogênio;
- d) Líquidos, geralmente fragmentos da cadeia polimérica;

- e) Partículas sólidas como fuligem, fibra de vidro e cargas minerais;
- f) Radicais livres.

A descrição matemática da fenomenologia envolvida nas reações de pirólise tem sido assunto de ampla discussão na literatura científica, sendo sem sombra de dúvidas, um problema que ainda permanece em aberto. Diversos são os fatores que contribuem para fazer com que este processo seja extremamente complexo. Primeiramente, diversas simplificações devem ser assumidas de forma a se obter um modelo geral. Além disto, diversos esforços têm sido feito para a representação de aspectos químicos. Existe uma grande dificuldade em se encontrar um conjunto de dados completos de um material e os seus produtos de pirólise, englobando fenômenos térmicos, químicos e físicos. Finalmente, a transferência de calor deve ser precisamente descrita de forma a representar adequadamente as várias condições de operação e tamanhos de partículas, fator de extrema importância para a determinação da cinética da reação.

A cinética da pirólise é importante para predizer a formação dos compostos a partir dos resíduos industriais. Um método comum para a determinação de parâmetros cinéticos é ajustar um modelo a uma curva de conversão obtida a partir de experimentos isotérmicos ou dinâmicos. Entretanto, estudos tentando determinar as cinéticas das reações de pirólise revelaram grandes discrepâncias entre os modelos cinéticos, quando os parâmetros foram obtidos a partir de experimentos isotérmicos e dinâmicos (BOCKHORN et al, 1999). As explicações para estas discrepâncias são embasadas pelas limitações à transferência de calor ou por mecanismos complexos de degradação que não podem ser representados por modelos simplificados. Dados cinéticos confirmam, ainda, que estruturas moleculares diferentes são representadas por diferentes mecanismos de decomposição térmica, diferentes taxas de reação e diferentes dependências da taxa de decomposição com a temperatura. Além disto, os dados revelam que as taxas de

decomposição dos plásticos são fortemente influenciadas por interações entre os diferentes plásticos presentes na mistura (Figura 3-4).



**Figura 3-4** - Graus de conversão calculadas para decomposição batelada de uma mistura de PVC, PS e PE (1:1:1 em peso) a várias temperaturas em uma pirólise em degraus a baixa temperatura.

A determinação exata da temperatura da amostra é de grande importância para a avaliação dos dados cinéticos. Entretanto, na maioria dos experimentos a temperatura é obtida por um termopar próximo da amostra e nenhuma informação a respeito do perfil de temperatura dentro da amostra está disponível. Desde que os resíduos utilizados para pirólise (plásticos e madeira) são péssimos condutores de calor, a dinâmica de aquecimento do resíduo gera gradientes de temperaturas não desprezíveis dentro do material. Outro fator que influencia o perfil de temperatura é que as reações de degradação dos compostos orgânicos são tipicamente endotérmicas. Além disto, os efeitos são acoplados através da dependência da taxa de reação com a temperatura, acentuando ainda mais estes gradientes. Apesar de existir um grande número de trabalhos avaliando a distribuição da temperatura em partículas sólidas submetidas a reações químicas (DI BLASI, 1996), o mesmo não pode ser dito para a avaliação do efeito de temperaturas não uniformes na obtenção de parâmetros cinéticos a partir de experimentos dinâmicos.

Fica evidente que a temperatura de reação é uma variável de grande importância no processo de pirólise. É essa variável que irá determinar a taxa de calor que deve ser suprida ao processo para atender a demanda das reações de degradação, a quantidade de gás e líquido gerados no processo, assim como a qualidade dos mesmos (MUNIZ et al., 1999). Grande parte dos processos de pirólise é conduzida em reatores semibatelada ou batelada. A automação e o controle destes processos é uma tarefa bastante complexa, onde não é possível se utilizar os procedimentos padrões de projetos de controladores (CANCELIER, 1998). O desenvolvimento da teoria de controle automático tem motivado o desenvolvimento e a adaptação de algumas técnicas de controle para processos químicos. Algumas estratégias baseadas em controle não linear, preditivo e adaptativo têm sido motivo de estudo na literatura especializada, sendo o próximo tópico deste capítulo.

### **3.2 Controle Preditivo**

Entre as estratégias de controle avançado uma que tem recebido muitas contribuições na literatura é o controlador preditivo com modelo interno, principalmente devido aos avanços de *hardware* nos computadores digitais, o que tem permitido que esta técnica possa ser implementada em tempo real. Apesar disto, a grande maioria dos trabalhos apresentados na literatura testam os algoritmos de controle propostos através de simulações.

O controlador preditivo (MPC) refere-se a uma classe de algoritmos de controle computacionais que utilizam explicitamente um modelo do processo para prever a resposta futura de uma planta (QIN e BADGWELL, 2003). A cada intervalo de tempo, um algoritmo MPC tenta otimizar o comportamento futuro da planta através do cálculo de uma seqüência futura de ajustes na variável manipulada. A primeira entrada, na

seqüência ótima, é então enviada à planta e todo o cálculo é repetido entre cada intervalo de amostragem.

Esta seção apresenta uma breve revisão da história do MPC, descrevendo as idéias-chaves dos algoritmos de controle propostos. Originalmente proposto para atender a necessidades específicas de controle de plantas de geração de energia e refinarias de petróleo, a tecnologia MPC pode ser encontrada atualmente em uma vasta gama de aplicações incluindo as áreas química, processamento de alimentos, automotiva e aeroespacial.

### 3.2.1 Controle LQG

O desenvolvimento dos conceitos do controle moderno pode ser encontrado no trabalho de Kalman, no início da década de 60 (KALMAN, 1960).

O processo considerado por Kalman pode ser descrito na forma de variáveis de estado de acordo com as equações a seguir:

$$x_{k+1} = Ax_k + Bu_k + Gd_k \quad (3-1)$$

$$y_k = Cx_k + \xi_k \quad (3-2)$$

Onde o vetor  $u$  representa a variável manipulada e o vetor  $y$  descreve a variável medida. O vetor  $x$  representa os estados do processo a ser controlado. O distúrbio é  $d_k$  e o ruído  $\xi_k$ .

A função objetivo a ser minimizada,  $J$ , deve penalizar desvios da variável controlada em relação a uma trajetória especificada, e também, à mudanças da variável manipulada (esforço do controlador). A função objetivo proposta é quadrática na forma da equação , ou alguma variação da mesma

$$J = \sum_{k=N_1}^{N_2} (y_{ref\ k} - \hat{y}_k)^2 + \sum_{k=1}^{N_u} \Delta u_k^2 \quad (3-3)$$

A solução do problema conhecido como controlador LQG (*Linear Quadratic Gaussian*) envolve dois passos distintos. No intervalo de tempo  $t$ , a saída medida  $y_k$  é usada para obter uma estimativa ótima dos estados  $\hat{x}_k$ :

$$\hat{x}_{k-1} = A\hat{x}_{k-1} + Bu_{k-1} \quad (3-4)$$

$$\hat{x}_k = \hat{x}_{k-1} + K_f(y_k - C\hat{x}_{k-1}) \quad (3-5)$$

Então, a entrada ótima  $u_k$  é computada usando um controlador de estado proporcional ótimo:

$$u_k = -K_C \hat{x}_k \quad (3-6)$$

Este algoritmo utiliza um horizonte de predição infinito e proporciona ao algoritmo propriedades estáveis (QUIN e BADGWELL, 2003). Entretanto, o algoritmo não permite restrições na entrada, nos estados e saídas do processo.

As principais limitações ao uso do controlador LQG são (MORARI e ZAFIRIOU, 1989):

- a) Restrições;
- b) Processos não lineares;
- c) Incertezas do modelo (robustez);
- d) Critério de performance único;
- e) Razões culturais;

Segundo QUIN e BADGWELL (QUIN e BADGWELL, 2003) um controlador deve ser capaz de manter o processo o mais próximo possível dos níveis operacionais

exigidos, sem violar restrições, as quais muitas vezes estão nas vizinhanças destes níveis. Em adição, as unidades de processo são tipicamente complexas, não lineares, com restrições multivariáveis e cuja dinâmica varia com o tempo, devido a mudanças nas condições operacionais, ação de catalisadores, etc. As unidades de processo podem ter critérios de performance únicos que são difíceis de expressar na estrutura LQG. Entretanto, a falha da teoria LQG, ainda segundo os autores supracitados, está relacionada com a cultura da comunidade de controle de processos industriais, a qual não foi exposta aos conceitos do LQG ou o consideravam impraticáveis.

Este ambiente levou ao desenvolvimento de uma metodologia de controle baseada em modelos mais gerais, na qual o problema de otimização dinâmica é resolvido *on-line* a cada execução do controle. As entradas do processo são calculadas de forma a otimizar o comportamento futuro da planta através de um intervalo de tempo conhecido como horizonte de predição. No caso geral, qualquer função objetivo pode ser usada. A dinâmica da planta é descrita por um modelo do processo explícito, que pode, a princípio, ter qualquer forma matemática. As restrições para as entradas e saídas do processo são incluídas diretamente na formulação do problema, tal que, violações futuras são antecipadas e prevenidas. A primeira entrada da seqüência ótima obtida é injetada na planta e o problema é repetido novamente, no próximo intervalo de amostragem, usando medidas atualizadas do processo. Em adição ao desenvolvimento de uma tecnologia de controle mais flexível, novas técnicas de identificação foram desenvolvidas, para permitir estimativas mais rápidas dos modelos dinâmicos empíricos a partir de dados de testes, reduzindo consideravelmente o custo de desenvolvimento do modelo. Esta nova metodologia para modelagem e controle de processos industriais é o que se define na atualidade como tecnologia MPC.

### 3.2.2 IDCOM – Identificação e Comando

A primeira descrição de aplicações do controle preditivo foi em 1978, num trabalho publicado por Richalet e colaboradores (RICHALET ET AL., 1978). Eles denominaram o controlador desenvolvido como MPHC (*Model Predictive Heuristic Control*). O código computacional usado para solução do problema foi denominado de IDCOM (*Identification and Command*).

Richalet e colaboradores escolheram uma representação entrada-saída, um modelo discreto da resposta a impulso finito (FIR – *Finite Impulse Response*). Para o caso SISO o modelo FIR pode ser escrito como:

$$\hat{y}_{k+j} = \sum_{i=1}^N h_i u_{k+j-i} \quad (3-7)$$

Este modelo prediz que a saída a um dado tempo depende de uma combinação linear de valores passados da entrada. Os pesos  $h_i$  do somatório são os coeficientes da resposta a impulso. O somatório é truncado no ponto em que as entradas passadas não influenciam mais a saída.

A natureza iterativa do algoritmo de controle permite que as restrições de entrada e saída sejam verificadas à medida que o algoritmo prossegue. Como a lei de controle não é linear e não pode ser expressa como uma função de transferência, o algoritmo foi considerado como heurístico. No contexto atual o algoritmo poderia ser referido como um MPC linear.

### 3.2.3 DMC – Controle por Matriz Dinâmica

Engenheiros da Shell desenvolveram sua própria tecnologia MPC, no início da década de 70, com uma aplicação inicial apresentada em 1973 (CUTLER e RAMAKER, 1979).

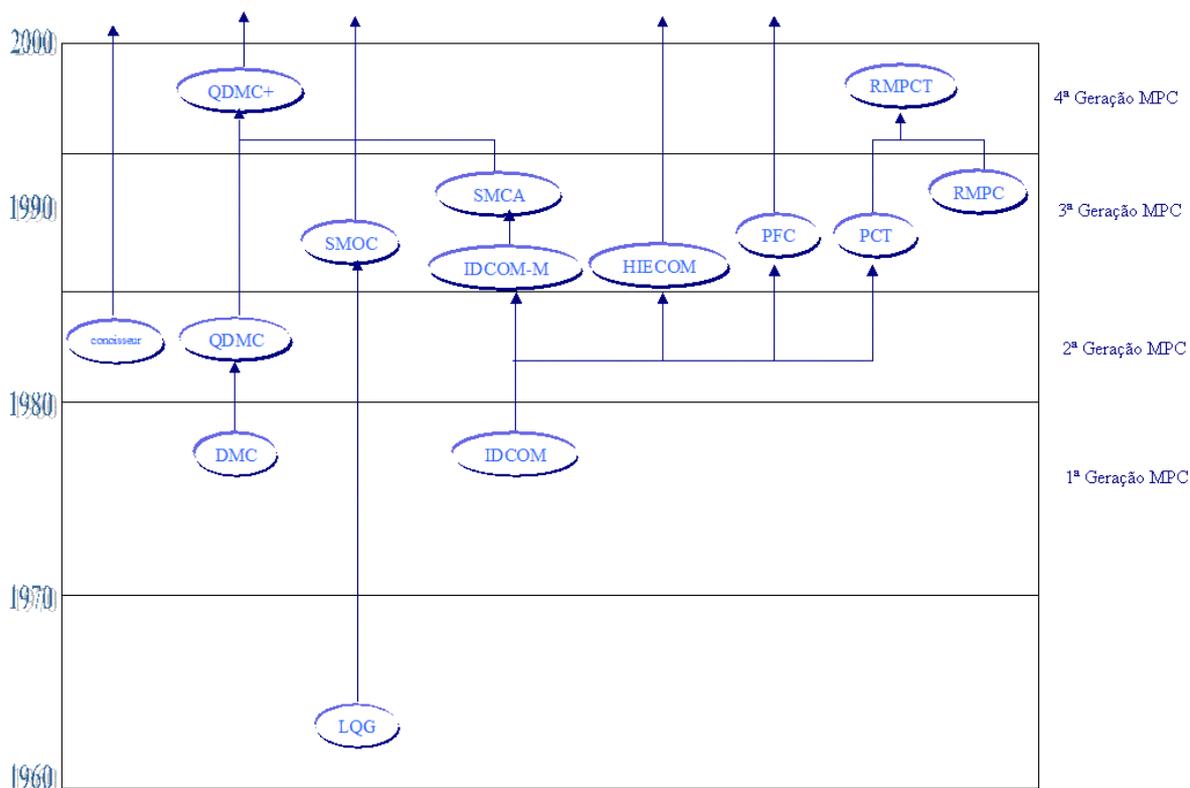
O modelo linear da resposta a degrau, usado no algoritmo DMC (*Dynamic Matrix Control*), relaciona mudanças na saída do processo a um somatório ponderado de valores passados das mudanças na entrada. Para o caso SISO o modelo do processo é do tipo:

$$\hat{y}_{k+j} = \sum_{i=1}^N S_i \Delta u_{k+j-i} + S_N u_{k+j-N} \quad (3-8)$$

Os pesos móveis  $S_i$  são os coeficientes da resposta a degrau. Usando o modelo da resposta a degrau pode-se escrever as variações previstas para a saída como uma combinação linear das variações das entradas futuras. A matriz que as conecta é chamada de Matriz Dinâmica. Esta representação permite que o vetor ótimo possa ser computado analiticamente como a solução de um problema de mínimos quadrados. Na prática, a matriz inversa necessária pode ser computada *off-line* para reduzir o tempo computacional. Apenas a primeira linha da matriz ganho do controlador precisa ser salva porque apenas a primeira variação precisa ser calculada.

O objetivo do controlador DMC é conduzir a saída do processo o mais próximo possível do *set point* e com uma restrição no movimento das variáveis manipuladas. Isto resulta em menores variações nas entradas e uma resposta menos agressiva. Assim como no IDCOM, esta técnica fornece uma maior robustez a erros na modelagem (QIN e BADGWELL, 2003).

Os algoritmos de controle IDCOM e DMC representam a primeira geração da tecnologia MPC. Elas tiveram enorme impacto no controle de processos industriais e serviu como marco para o paradigma do MPC industrial. A Figura 3-5 apresenta uma representação da evolução do MPC.



**Figura 3-5** - Evolução aproximada dos algoritmos lineares MPC. Adaptada de QIN e BADGWELL, 2003.

### 3.2.4 QDMC – Controle por Matriz Dinâmica com Programação Quadrática

Os algoritmos IDCOM e DMC forneceram um excelente controlador para processo multivariáveis sem restrições. O problema das restrições persistia. Engenheiros da Shell buscaram uma melhoria no algoritmo incrementando no algoritmo DMC uma programação quadrática, na qual as restrições nas entradas e saídas aparecem explicitamente. (GARCÍA E MORSHEDI, 1986). As suas principais características são:

- Modelo linear a uma resposta a degrau para a planta;
- Objetivo de performance quadrático através de um horizonte de predição finito;
- Comportamento para a saída futura da planta especificado, seguindo o *set point* o mais próximo possível;

- d) Entradas ótimas computadas como a solução de uma programação quadrática.

O algoritmo QDMC (*Quadratic Program Dynamic Matrix Control*) representa a segunda geração da tecnologia MPC, compreendendo os algoritmos que fornecem um procedimento sistemático para implementar restrições nas entradas e saídas do processo.

### 3.2.5 Terceira Geração

À medida que a tecnologia MPC foi ganhando aceitação, os problemas cobertos por essa estratégia de controle tornaram-se mais complexos e os engenheiros que utilizavam a segunda geração da tecnologia MPC caíram em outros problemas de ordem prática. O algoritmo QDMC forneceu uma estratégia para incorporar restrições, mas não havia uma forma clara para tratar com soluções impossíveis. Tornou-se difícil incorporar requerimentos de controle através de pesos relativos em uma única função custo. “A combinação de múltiplos objetivos em uma função objetivo não permite que o projetista reflita os verdadeiros critérios de performance” (PRETT e GARCÍA, 1988).

O IDCOM-M (*Identification and Command Multiple*), HIECON (*Hierarchical Constraint Control*), SMCA (*Setpoint Multivariable Control Architecture*), SMOC (*Shell Multivariable Optimizing Controller*) representam a terceira geração da tecnologia MPC. Esta geração distingue diversos níveis de restrições, fornece mecanismo para recuperar soluções impossíveis, além de tratar com uma grande faixa de dinâmicas de processos (estáveis e instáveis).

### 3.2.6 Quarta Geração

Pode-se sumarizar o ganho da quarta geração como sendo o fornecimento de uma maior gama de técnicas, como níveis de otimizações múltiplas para os objetivos de

controle prioritários, inclusão de objetivos econômicos, consideração direta de incertezas no modelo e melhorias nas técnicas de identificação de modelos.

### 3.2.7 Modelos do Processo

O controlador preditivo é fundamentalmente definido pela forma do modelo utilizado para descrever o processo, tendo esse modelo um papel decisivo na performance do controlador. Modelos lineares e não lineares têm sido empregados na tecnologia MPC. Estes podem ser empíricos, os quais são derivados exclusivamente de dados do processo. Como os parâmetros dos modelos empíricos são obtidos através de um ajuste do modelo a um conjunto de dados, geralmente eles não podem prever precisamente o comportamento do processo fora da faixa dos dados utilizados para o seu desenvolvimento. Os modelos baseados em balanços de massa e energia são mais caros para serem desenvolvidos, mas são capazes de prever o comportamento através de uma maior faixa de operação. Os modelos fenomenológicos, em geral, acabam tornando-se semi-empíricos uma vez que parâmetros chaves do modelo são usados para calibrá-lo. Os modelos empregados em controladores preditivos caem, predominantemente, em três quadrantes: modelos fenomenológicos não lineares, modelos empíricos não lineares e modelos empíricos lineares (QIN e BADGWELL, 2003). As várias formas podem ser visualizadas como casos especiais de um modelo em espaço de estado não linear contínuo no tempo, como representado nas equações (3.9) e 3-10), a seguir:

$$\dot{x} = \bar{f}(x, u, d, v) \quad (3-9)$$

$$y = \bar{g}(x, u) + \xi \quad (3-10)$$

Onde  $u$  é o vetor das variáveis manipuladas,  $y$  é o vetor das variáveis controladas,  $x$  é o vetor das variáveis de estado,  $d$  é o vetor dos distúrbios medidos,  $v$  é

o vetor dos distúrbios não medidos ou ruídos de processo e  $\xi$  é o vetor dos ruídos medidos. As próximas seções descrevem cada modelo com um pouco mais de detalhes.

### 3.2.7.1 Modelos Fenomenológicos Não Lineares

Os modelos fenomenológicos não lineares são derivados a partir dos princípios de conservação da massa e da energia, podendo ser facilmente escritos na forma das equações ( 3-9 ) e ( 3-10 ). Os parâmetros desconhecidos, como os coeficientes de transferência de calor e constantes cinéticas, são, em geral, estimados *off-line* a partir de dados do processo ou *on-line* usando um filtro estendido de Kalman. Tipicamente, o modelo do processo tem entre 10 e 100 equações álgebra-diferenciais.

A integração do modelo entre instantes de amostragens gera um modelo discreto com a forma geral:

$$x_{k+1} = f(x_k, u_k, v_k, w_k) \quad (3-11)$$

$$y_k = g(x_k, u_k) + \xi_k \quad (3-12)$$

### 3.2.7.2 Modelos Empíricos Lineares

Os modelos lineares empíricos têm sido os mais usados em aplicações MPC. Uma grande variedade de formas de modelos tem sido usada, podendo ser derivada das equações ( 3-11 ) e ( 3-12 ), linearizando-as em torno de um ponto de operação, fornecendo:

$$x_{k+1} = Ax_k + B_u u_k + B_v d_k + B_w v_k \quad (3-13)$$

$$y_k = Cx_k + Du_k + \xi_k \quad (3-14)$$

Um modelo discreto na forma de função de transferência escrito na forma matricial conhecido como ARX – *Autoregressive Model with Exogenous Inputs* (KAILATH, 1980) pode ser representado como:

$$y_k = \Phi_y(q^{-1})y_k + \Phi_u(q^{-1})u_k + \Phi_v(q^{-1})d_k + \Phi_w(q^{-1})v_k + \zeta_k \quad (3-15)$$

Onde:

$$\zeta_k = [I - \Phi_y(q^{-1})]\xi_k \quad (3-16)$$

Para um sistema estável, um modelo FIR (*Finite Impulse Response*) pode ser obtido como:

$$y_k = \sum_{i=1}^{N_u} h_i^u u_{k-i} + \sum_{i=1}^{N_v} h_i^v d_{k-i} + \sum_{i=1}^{N_w} h_i^w v_{k-i} + \xi_k \quad (3-17)$$

Uma forma alternativa é o FSR (*Finite Step Response*) (CLUTER et al., 1983) dada por:

$$y_k = \sum_{i=1}^{N_u-1} S_i^u \Delta u_{k-i} + S_{N_u}^u u_{k-N_u} + \sum_{i=1}^{N_v-1} S_i^v \Delta d_{k-i} + S_{N_v}^v d_{k-N_v} + \sum_{i=1}^{N_w-1} S_i^w \Delta v_{k-i} + S_{N_w}^w v_{k-N_w} + \xi_k \quad (3-18)$$

### 3.2.7.3 Modelos Empíricos Não Lineares

Dois tipos básicos de modelos empíricos não lineares são utilizados nas aplicações MPC. Um desses tipos compreende um modelo linear para os estados dinâmicos, com uma equação para a saída que inclui um termo linear somado com um termo não linear:

$$x_{k+1} = Ax_k + B_u u_k + B_v d_k + B_w v_k \quad (3-19)$$

$$y_k = Cx_k + Du_k + N(x_k, u_k) + \xi_k \quad (3-20)$$

A função não linear  $N$  é obtida a partir de uma rede neural.

É bem conhecido que uma rede neural não está apta para extrapolações fora da faixa dos dados de treinamento. Alguns algoritmos contornam este problema calculando um índice de confiança do modelo (MCI – *Model Confidence Index*) *on-line*. À medida em que o MCI vai se deteriorando a rede vai gradualmente sendo “desligada” e o modelo vai tornando-se apenas linear. Uma variação deste algoritmo é utilizar um Filtro Estendido de Kalman (EKF) para corrigir erros na modelagem e distúrbios não medidos (ZHAO et al., 1998). O EKF faz uma correção do *bias* e do ganho do modelo *on-line*.

O outro tipo de modelo é um modelo não linear estático, o qual simplifica a tarefa de identificação do modelo. A sua representação é da forma SISO, mas o conceito pode ser estendido para processos multivariáveis (PICHE et al., 2000). Assume-se que a entrada e a saída do processo pode ser decomposta em um termo estacionário que obedece a um modelo não linear estático e um termo de desvio que segue um modelo dinâmico linear. Para qualquer entrada  $u_k$  e saída  $y_k$ , as variáveis desvios são calculadas como segue:

$$\delta u_k = u_k - u_s \quad (3-21)$$

$$\delta y_k = y_k - y_s \quad (3-22)$$

Onde  $u_s$  e  $y_s$  são os valores para entrada e saída no estado estacionário, os quais seguem um relação não linear:

$$y_s = h_s(u_s) \quad (3-23)$$

As variáveis desvio seguem uma relação dinâmica linear de segunda ordem:

$$\delta y_k = \sum_{i=1}^2 a_i \delta y_{k-i} + b_i u_{k-i} \quad (3-24)$$

A identificação do modelo dinâmico linear é baseada em dados de teste a partir de pulsos, enquanto o modelo estático não linear é uma rede neural construída a partir de históricos da planta.

A seguir são apresentadas algumas aplicações do controle MPC em processo químicos.

### 3.2.8 Aplicações de Controladores Preditivos

NAHAS et al., 1992 propuseram um controle preditivo com modelo baseado em redes neurais para controlar processos não lineares. Foi utilizada uma rede com estrutura *feedforward* com três camadas, utilizando o algoritmo do gradiente conjugado para o treinamento. O controlador era provido com um modelo inverso (uma rede neural treinada para aprender o comportamento inverso do sistema) e um filtro robusto com um parâmetro para sintonia. A estratégia proposta incluía ainda uma compensação para tempo morto na forma de um preditor de Smith. O controlador foi testado através da simulação de um reator CSTR não isotérmico com três estados estacionários (dois estáveis e um instável) e também no controle de pH de um processo de neutralização (também por simulação). Os dois processos apresentam grandes não linearidades e a estratégia proposta é confrontada com o controle clássico PID. Enquanto o controle clássico apresentou *overshoot*, o controlador com modelo interno, baseado em redes neurais, apresentou uma resposta mais rápida e muito mais estável, tanto em problemas servo como para problemas reguladores. Entretanto, o algoritmo foi testado apenas em problemas simulados e com dinâmica constante. A avaliação do controlador proposto em processos bateladas também não foi efetuada.

RITA, 1995 implementou uma rede neural artificial no controle de um tanque simples e para tanques acoplados. A ação de controle era obtida a partir de uma função custo quadrática para horizonte de predição e horizonte de controle igual a um. Desta forma, evita-se o problema de otimização *on-line*, sendo válido para sistemas sem retardo dinâmico.

MAZZUCCO, 1996 aplicou uma rede neural com estrutura *feedforward* como modelo de um controlador quadrático no controle de um sistema de nível e outro de temperatura. Em ambos os casos duas foram as redes utilizadas, a fim de separar a dinâmica do sistema. No caso do controlador de nível, o tanque possuía duas seções diferentes, uma cilíndrica e outra cônica. No controle de temperatura, as dinâmicas de aquecimento e resfriamento eram diferentes. Neste último caso foi desenvolvido um sistema para o treinamento e utilização de uma rede neural para um processo com tempo morto. Entretanto, o método só é eficiente para sistemas com tempo morto muito bem definido. Os horizontes de controle e predição eram iguais a um, evitando também o problema de otimização *on-line*.

TURNER et al., 1996 descreveram um procedimento para implementação de controle ótimo baseado em redes neurais recursivas. Como a rede deve possuir características necessariamente dinâmicas para ser aplicada na predição da variável controlada e subsequente cálculo da ação de controle, foi adotada uma rede com filtros (WILLIS et al., 1991), a qual oferecem uma eficiente capacidade de modelagem do comportamento dinâmico do processo. Foi utilizado o método de otimização de Levenburg-Marquardt para treinamento da rede neural. O algoritmo foi testado na simulação do controle de pressão de uma coluna de destilação em operação na Austrália, a qual apresenta uma complexa não linearidade, e a performance do controlador é comparada com um controlador PI e um controle ótimo baseado em um modelo linear. O

controle ótimo linear tem uma performance superior ao controle clássico, enquanto o controle baseado em redes tem um desempenho melhor do que o do controle ótimo linear. Mais uma vez o trabalho apresenta apenas os resultados obtidos por simulação e evidencia a necessidade do uso de filtros para a representação dinâmica do processo através do uso de modelo baseado em redes neurais.

CANCELIER, 1998 propõe um sistema de controle para um reator em regime batelada e batelada alimentada, onde ocorre uma reação altamente exotérmica. O sistema tinha duas variáveis manipuladas (a taxa de aquecimento e a vazão da água de refrigeração) e uma variável controlada (temperatura do reator). A estratégia proposta utiliza uma filosofia de controle preditivo, utilizando redes neurais artificiais como modelo de processo. O algoritmo de controle proposto possuía uma lei de controle para o aquecimento e uma outra para o resfriamento. Foi proposto um algoritmo para ajuste da trajetória de referência do controlador baseado na magnitude de variação do *set point* e do estado do sistema.

MORARI e LEE, 1999 publicaram uma revisão sobre o controle preditivo, fornecendo uma visão geral da origem do controle preditivo (MPC), sendo dada uma maior ênfase ao futuro do MPC do que ao seu passado. Segundo os autores, o que limita a performance e aplicação da tecnologia MPC não são as deficiências do algoritmo de controle, mas as dificuldades na modelagem, sensoriamento e estimativa de estados. Reforçam ainda, que o escasso número de aplicações MPC em processos bateladas deve-se fundamentalmente ao fato de que durante o curso de uma batelada, as variáveis de processo percorrem uma grande faixa de operação e então, a dinâmica do processo sofre mudanças significativas devido às suas não linearidades, tornando a tarefa de encontrar um modelo preciso para o processo muito difícil.

LANOUILLE ET AL., 1999 apresentaram um trabalho para melhoria na modelagem de processos complexos quando apenas um pequeno conjunto de dados experimentais está disponível. Várias estratégias de soluções foram testadas incluindo redes neurais *feedforward* e RBF (*radial basis function*) em três problemas, entre eles, duas aplicações em polpa de madeira. Os dados experimentais, obtidos através de um projeto ótimo e a partir de seleção randômica de dados experimentais, foram comparados no que se refere às suas habilidades de obtenção de modelos realistas. Estudou-se ainda a influência da função de ativação, do número de níveis e da composição dos dados de treinamento. O estudo mostrou que os dados obtidos a partir de um projeto apresentam melhores resultados do que aqueles obtidos de forma randômica, devido à sua alta ortogonalidade. Entretanto, o trabalho limita-se à modelagem no estado estacionário.

Um trabalho com uma extensiva revisão de diversas aplicações utilizando redes neurais em controle de processos químicos, tanto por simulação como para aplicações *on-line* é apresentado (HUSSAIN, 1999). Estas aplicações foram classificadas em três categorias principais: Controle Preditivo, Controle Baseado em Modelo Inverso, e métodos de Controle Adaptativo. O artigo mostra que a rede neural multicamada é a mais popular em aplicações para controle e que existem poucas aplicações *on-line* com sucesso, até o presente, abrindo espaço para um maior número de trabalhos em planta piloto.

Um controlador com modelo interno não linear usando redes neurais para sistemas com retardo dinâmico foi proposto (RIVALS e PERSONNAZ, 2000). O controlador emprega um modelo interno baseado numa rede neural *feedforward* e o inverso do modelo com a eliminação do retardo. O modelo inverso pode ser obtido através de um treinamento da rede ou através da explicitação da entrada de controle em função das entradas, das saídas e referências passadas. O controlador é construído com um modelo

neural inverso, um modelo projetado para eliminar o retardo do modelo (suas entradas são o *set point* corrigido e as saídas passadas do modelo sem retardo). Os cálculos efetuados pelo controlador no tempo  $k$  são:

- a) A diferença entre a saída do processo e a do modelo interno;
- b) O *set point* corrigido para o modelo interno;
- c) A saída do modelo projetado;
- d) O valor de controle, saída do modelo inverso;
- e) A saída do modelo com eliminação do retardo, a qual será necessário para os cálculos seguintes.

A vantagem do modelo interno é a sua robustez com respeito a erros do modelo e a distúrbios. Entretanto, esta propriedade só é obtida se o modelo de referência do controlador for perfeito.

KWONG, 2000 propôs uma modificação no algoritmo de controle preditivo conhecido como SMPC (*Simplified Model Predictive Control*) utilizando a estrutura do controlador com modelo interno. O algoritmo foi testado através de simulações, entretanto sua performance foi boa apenas para desvios moderados no *set point*.

O desenvolvimento de um controlador preditivo robusto foi apresentado, aplicável para sistemas estáveis em malha aberta (RODRIGUES e ODLOAK, 2002). A estabilidade da malha fechada é garantida usando um controlador preditivo com horizonte infinito e um observador de estado estável. A performance e o esforço computacional desta abordagem foram comparados ao controlador robusto apresentado por Badgwell (BADGWELL, 1997). O controlador proposto é mais genérico uma vez que elimina o *offset* de problemas servo e regulador, enquanto o algoritmo utilizado para comparação garante comportamento livre de *offset* apenas para problemas reguladores. As incertezas da modelagem são aproximadas por um conjunto finito de modelos lineares desacoplados.

SARKAR e MODAK, 2003 introduziram uma técnica numérica para resolver problemas de controle ótimo não linear. Eles utilizaram uma rede neural com três camadas combinada com o algoritmo *simulated annealing* para desenvolver um algoritmo híbrido de otimização para determinar o perfil de controle ótimo. A aplicabilidade da técnica é testada por simulação e comparado com estudos apresentados na literatura.

Pode-se observar, a partir desta compilação de artigos na área de controle preditivo, um número restrito de aplicações em tempo real, sendo a maioria delas estudadas através de simulações. Além disto, fica evidente que o modelo não linear mais adotado é a rede neural, a qual, para uma representação satisfatória do comportamento dinâmico do processo, exige o uso de filtros, sendo o mais empregado o EKF (Filtro Estendido de Kalman)

Para manter a performance do controlador preditivo através de uma faixa de operação mais ampla estratégias de controle adaptativas têm sido propostas (DOUGHERTY e COOPER, 2003). Na próxima seção serão apresentadas algumas importantes aplicações na área de controle adaptativo.

### **3.3 Controle Adaptativo**

Sistemas de controle adaptativos têm sido tema de pesquisa desde a década de 60. Inicialmente, estas pesquisas eram restritas a modelos lineares (ROVITHAKIS e CHRISTODOULOU, 1994). Os avanços na teoria de controle não linear, e em particular as técnicas de linearização, motivou o desenvolvimento de esquemas de controle adaptativo para plantas não lineares (KANELLAKOPOULOS et al., 1991). A partir da década passada as redes neurais surgiram como uma poderosa ferramenta para o aprendizado estático e dinâmico de sistemas não lineares. Devido à sua característica de paralelismo, rápida adaptabilidade e a inerente capacidade de aproximação, boa parte das

pesquisas envolvendo as redes neurais concentraram-se na área de identificação e controle (ROVITHAKIS e CHRISTODOULOU, 1994).

O problema foi formulado originalmente no início da década de 90 (NARENDRA et al., 1990). Ele propôs um esquema provido de uma rede neural estática *backpropagation* conectada em série ou em paralelo com um sistema dinâmico linear. Este trabalho deu desdobramento a uma série de aplicações de controladores adaptativos baseados em redes neurais.

Bolzan (BOLZAN, 1991) estudou o uso de controladores adaptativos, mas especificamente o STC (Controlador Auto-Ajustável), para o controle da temperatura de um reator semibatelada, processando uma reação altamente exotérmica. Os testes foram validados experimentalmente em uma unidade piloto, mostrando a superioridade deste controlador quando comparado ao GPC e o PID clássico, em todo o ciclo de operação.

LEE e PARK (LEE e PARK, 1992) propuseram um esquema de controle utilizando um controle preditivo. Uma rede neural, treinada *on-line*, é utilizada em paralelo com o controlador preditivo DMC (*Dynamic Matrix Control*). O objetivo de treinar a rede é encontrar os pesos que produzem uma ação de controle que minimizem o quadrado do erro entre o valor do *set point* e o da variável controlada. A ação de controle é um somatório das ações de controle calculadas pelo controle DMC (resultantes de efeitos modelados e não modelados) e a ação de controle obtido pela rede neural. Entretanto, o padrão de saída para o treinamento da rede neural não está disponível (ação de controle que minimiza o quadrado do erro). O procedimento proposto, então, é utilizar como padrão a saída da rede, no instante anterior, e a saída do controlador DMC devido a efeitos não modelados. O controlador é testado em uma coluna de destilação e em um reator não isotérmico, ambos através de simulação. Foi testada a performance do método frente à falhas, fixando randomicamente, metade dos pesos da rede com o valor zero.

Apesar desta severa falha a performance do controlador foi satisfatória. Foi testado também o desempenho do controlador frente a erros de modelagem. Estes erros referem-se sempre às relações entre as variáveis controladas e as variáveis manipuláveis e nunca entre as variáveis controladas e os distúrbios. Mais uma vez o controlador apresentou um bom desempenho, melhor que o controlador DMC.

Um outro trabalho apresentando a aplicação de um controlador neural para a temperatura de um reator batelada foi apresentado (DIRION et al., 1996). Nele, uma rede neural multicamada calcula a ação de controle a ser aplicada no processo. Dois métodos para adaptação *on-line* dos pesos da rede são apresentados: um deles é a técnica de treinamento especializado, enquanto outro utiliza mais uma rede para modelar a dinâmica do reator. O reator utilizado é representado por um modelo com diversas idealizações. O reator é encamisado e a temperatura da camisa é definida através da mistura de uma corrente fria a 10°C com uma outra corrente quente a 70°C. Assume-se como conhecidas apenas a temperatura da mistura reagente e as temperaturas de entrada e saída da camisa. O objetivo do controlador é manter a temperatura do reator dentro de um perfil estipulado. Para isto a abertura da válvula que alimenta a corrente de água quente deve ser calculada. Era desejado encontrar uma rede neural que fosse capaz de calcular a abertura adequada para a válvula. O critério a ser minimizado:

$$J = \sum_{i=1}^{t_b} [y_{ref}(t) - y_C(t)]^2 \quad (3-25)$$

Uma das formas de satisfazer este critério, conhecido como método indireto, consiste em comparar o valor calculado pela rede com o valor “ideal” que permite que  $y_{ref}(t) = y_C(t)$  e minimizar:

$$J = \sum_{i=1}^{t_b} [u_m(t) - u^*(t)]^2 \quad (3-26)$$

O grande problema é que apesar dos valores de  $y_c(t)$  serem conhecidos, já que são fixados pelo usuário, os alvos  $u^*(t)$  da rede são desconhecidos.

Diversos métodos foram propostos para solucionar este problema. Um deles utiliza um controlador clássico para gerar este valor da ação de controle “ideal”. Segundo os autores do trabalho (DIRON et al, 1996) qualquer controlador pode ser usado para fornecer estes valores, gerando assim os dados para o treinamento. Entretanto, se as ações de controle ideal são gerados por qualquer algoritmo de controle, não se pode esperar um avanço de um controlador que foi treinado sob estas condições.

Um controlador adaptativo STC (MACHADO, 1996), ajustado com os parâmetros de um PI clássico, foi empregado no controle de temperatura de um reator encamisado, onde a reação de polimerização do estireno em suspensão foi processada. O reator foi operado em batelada. Apesar do grande número de perturbações introduzidas no sistema, o controlador STC mostrou-se robusto para controlar processos desta natureza.

MINZGZHONG e FULLI, 1997 apresentaram um método de controle adaptativo para sistemas não lineares. A lei de controle é derivada através da minimização de um índice de performance e sua implementação requer apenas o cálculo da sensibilidade entre a entrada do sistema controlado e a saída, além da saída do sistema em uma predição um passo a frente (*quase-one-step-ahead*). A sensibilidade da planta é estimada utilizando um algoritmo de mínimos quadrados com janela recursiva (*recursive rectangular window least square algorithm*) e a saída predita é obtida através de redes neurais recorrentes. A sensibilidade poderia ser obtida diretamente da derivada da rede neural em relação às ações de controle, porém os autores ponderam que do ponto de vista matemático, um bom

“aproximador” de alguma função não é necessariamente um bom “aproximador” para a derivada da mesma.

FILETI e PEREIRA, 1997 apresentaram duas estratégias de controle, uma estratégia adaptativa e outra preditiva, para o controle de uma coluna de destilação operando em batelada, com o objetivo de controlar a pureza do produto de topo através da razão de refluxo. O controlador foi testado em uma planta piloto. Na primeira estratégia implementada, a composição do refeedor é utilizada como variável auxiliar para determinar as condições operacionais da coluna. Os parâmetros de um controlador PI são ajustados em função deste ponto. Para o controle preditivo foi proposta uma rede neural para representar o processo. A rede foi treinada usando o método GDR (*Generalized Delta-Rule*) ou técnica do momentum. A rede neural era treinada *on-line* e determinava a saída do processo através do horizonte de predição determinado. As predições da rede eram submetidas a uma rotina de otimização para minimizar a função objetivo, gerando uma seqüência de ações para o controle ótimo.

FOLLY et al., 1997 propuseram uma estratégia de controle adaptativo para um fermentador em batelada alimentada (*fed-batch*). Os estudos foram realizados em uma planta piloto contendo quatro unidades: uma seção de fermentação, uma unidade de destilação, o setor de utilidades e a sala de controle. A variável controlada era a densidade do mosto e a mesma era ajustada através de manipulações na alimentação de entrada do fermentador. Foi utilizado como estratégia de controle um controlador PI com adaptação dos parâmetros.

BRDYS et al., 1998 apresentaram uma técnica de controle adaptativo para processos não lineares com estado não medido, baseada em uma rede neural recorrente como o modelo dinâmico da planta. Usando este modelo dinâmico um controle *feedback*

linearizado é implementado, sendo os parâmetros da rede atualizados *on-line*. A estratégia é testada através de simulações.

SILVA et al., 1999 apresentaram mais uma aplicação de controle adaptativo em processos biotecnológicos. O trabalho descreve o uso de dois algoritmos de controle preditivo e um controle adaptativo para um processo de fermentação contínua, onde a produtividade é a variável controlada e a concentração de substrato na alimentação é a variável manipulada. Estes três algoritmos são comparados com o controle por matriz dinâmica tradicional (DMC – *Dynamic Matrix Control*). As estratégias são comparadas por simulação. Os dois controladores preditivos propostos diferem entre si na forma de resolução do modelo. O primeiro controlador utiliza colocação ortogonal em elementos finitos como método de solução para o sistema de equações diferenciais que descreve o processo, enquanto o segundo utiliza colocação ortogonal com pontos equidistantes, resultando em um problema de dimensão menor e conseqüentemente exigindo um esforço computacional também menor, o que se torna um fator importante para aplicações *on-line*.

BELTRAN e JACKSON, 1999 usaram uma rede neural adaptativa para modelar e controlar o pH numa aplicação industrial. Foi utilizado o algoritmo de Levenberg – Marquardt para treinamento da rede. Foi utilizada uma estratégia de controle ótimo, utilizando o método de Hooke e Jeeves para obtenção da seqüência de controle ótimo.

Foi desenvolvido um controlador adaptativo indireto baseado em uma rede neural multicamada (ZHANG et al., 1999). O esquema proposto evita o problema de singularidade que os controladores adaptativos diretos estão sujeitos. O sistema de eliminação do erro converge para uma vizinhança próxima de zero (não o evita efetivamente), enquanto a estabilidade do sistema é garantida. A performance transiente do sistema adaptativo resultante é quantificada analiticamente e um exemplo, por

simulação, é apresentado. A ação de controle é expressa através de uma rede neural e a ação de controle “ideal” é obtida por

$$u = -\frac{1}{b(x)}[a(x) + v] - \left[ \frac{1}{\varepsilon} - \frac{\dot{b}(x)}{2b^2(x)} \right] e_s \quad (3-27)$$

Com  $v$  sendo uma nova variável controlável,  $b(x)$  independente do estado  $x_n$ ,  $\varepsilon > 0$  e  $\lim_{t \rightarrow \infty} \|e_s\| = 0$ . Como esta ação de controle proposta evita o problema de singularidade a rede assim treinada, também o evitará.

PEREIRA et al., 2000 apresentaram um trabalho prático avaliando duas abordagens para modelagem paramétrica linear e não linear (redes neurais) para controle adaptativo automático. O controle neural adaptativo é baseado em uma técnica de aprendizagem híbrida usando uma taxa de aprendizagem adaptativa *on-line* para uma rede neural radial. O controle linear é auto – ajustado por alocação de pólos. Um método com fator de esquecimento seletivo foi aplicado em ambos os casos: no caso neural para estimar *on-line* os pesos da segunda camada e no caso linear para estimar os parâmetros do modelo. Estas duas técnicas foram aplicadas a uma unidade de laboratório com possibilidade de modificações dinâmicas e diferentes tipos de perturbações. Verificou-se uma performance superior do controle neural, principalmente quando o processo era submetido a mudanças na sua dinâmica.

A aplicação da estratégia de controle adaptativo na produção de ácido láctico em um reator CSTR com dois estágios foi apresentada (YOUSSEF et al, 2000). É proposto um modelo fenomenológico obtido para o processo de fermentação do ácido láctico, levando em conta o efeito da limitação nutricional no crescimento celular e na produção do ácido. Uma estratégia de controle foi investigada com objetivos baseados em critérios técnico-econômicos. As necessidades econômicas caem principalmente na relação entre

o esvaziamento total do substrato e a produtividade máxima e o compromisso entre o transbordamento do fator nutricional e condições propícias de crescimento. Aproveitando as informações obtidas a partir do modelo, uma análise no estado estacionário foi feita de modo a especificar o ponto ótimo de operação, ou ao menos uma boa aproximação, na configuração da planta em dois estágios. Um controle adaptativo com complexidade reduzida, cujo objetivo era regular a concentração de substrato através das taxas de diluição em cada estágio, foi escolhido devido à necessidade de se propor um algoritmo viável. O algoritmo de controle foi eficiente para rejeitar distúrbios internos (mudanças de *set point* e variações na carga de nutrientes). Apesar da calibração e validação do modelo ter feito uso de dados experimentais, o teste do algoritmo de controle proposto foi implementado através de simulações.

ENDER e MACIEL FILHO, 2000 apresentaram uma estratégia de controle multivariável utilizando redes neurais. A estratégia de controle proposta utiliza informações passadas e presentes do processo para projetar o melhor controlador, assim como gerar novas ações de controle. A cada instante de amostragem o controlador é otimizado, usando o erro futuro da malha fechada, gerada por uma rede neural que representa a dinâmica do processo. O erro desse controlador treinado *on-line* é comparado com o controlador treinado *off-line*. Só haverá mudança no controlador caso o erro seja menor para o controlador treinado *on-line*. Caso contrário mantém-se o controlador treinado *off-line*. O algoritmo de controle proposto foi testado pela simulação de um reator catalítico de leito fixo, o qual tem um comportamento dinâmico complexo, apresentando resposta inversa. Esta estratégia foi aplicada também na simulação de um processo fermentativo para a produção de penicilina (ENDER e MACIEL FILHO, 2001).

CHEN e NARENDRA, 2001 propuseram um controle adaptativo o qual, baseado numa lei estabelecida, escolhe entre um controlador adaptativo linear ou um controlador

adaptativo baseado em redes neurais. O controlador linear tem estabilidade garantida, mas uma performance nem sempre satisfatória, enquanto o controlador baseado em redes tem uma melhor performance, mas não possui critérios que garantam a estabilidade. A estratégia que permite uma escolha *on-line* entre os dois tipos de controladores apresentou uma melhora tanto na performance quanto na estabilidade.

Um estudo sobre uso de redes neurais adaptativas para controlar a temperatura do ar na saída de um trocador de calor compacto foi apresentado (DÍAZ et al., 2001). O controlador, baseado na estratégia IMC foi adaptado *on-line* com base em diferentes critérios de performance.

Uma nova estratégia de controle adaptativa para um controlador preditivo linear foi proposta (DOUGHERTY e COOPER, 2003). O método proposto é projetar múltiplos controladores lineares DMC. Os parâmetros ajustáveis são obtidos usando uma nova expressão analítica. A saída do controlador adaptativo DMC é uma média ponderada dos múltiplos controladores lineares DMC.

Segundo o que foi exposto no texto apresentado neste capítulo, o controle de processos em batelada é uma tarefa complexa e apesar do grande número de trabalhos envolvendo algoritmos de controle preditivo, poucos trabalhos abordando o controle deste tipo de processo foram apresentados na literatura. A grande dificuldade é encontrar um modelo que represente com precisão o comportamento dinâmico do processo através de toda a faixa de operação. Uma alternativa plausível é atualizar o modelo *on-line*, de forma a que ele consiga representar adequadamente o processo, em todos os pontos de operação.

Neste trabalho estudou-se um algoritmo de controle preditivo e adaptativo para o controle de um reator de pirólise, com um regime de operação semibatelada. Fica evidente, a partir da revisão bibliográfica apresentada, que o controle da temperatura do

reator é essencial para a determinação do rendimento e da qualidade dos produtos obtidos nas reações pirolíticas. Para evitar a perigosa formação de dioxinas e furanos, a reação deve ser conduzida em estágios, reduzindo a níveis baixíssimos a quantidade de cloro nos produtos de pirólise. O modelo utilizado para representar o processo foi uma rede neural *feedforward* totalmente recorrente. Com isto, reduz-se consideravelmente o custo de obtenção do modelo, quando comparado com o modelo fenomenológico. Para que o modelo fosse fidedigno em toda a faixa de operação, um esquema de controle adaptativo foi adotado. Os pesos da rede foram atualizados *on-line* utilizando a janela móvel para a limitação do tamanho do padrão de treinamento. Assim, pode-se treinar a rede entre cada instante de amostragem. Para evitar a necessidade do acoplamento de um outro algoritmo de controle para gerar os padrões de treinamento *on-line*, as ações de controle são calculadas através de otimização da função objetivo geralmente usadas nos controladores preditivos.

O próximo capítulo traz uma breve explicação sobre a teoria do algoritmo de controle preditivo e adaptativo, assuntos nos quais o trabalho encontra-se fundamentado.

# Capítulo 4

## Fundamentação Teórica

---

O objetivo deste capítulo é fornecer uma base teórica para os principais temas necessários à implementação do algoritmo de controle utilizado neste trabalho. A filosofia do controlador preditivo é apresentada de forma geral, passando pela função custo e seus parâmetros, até a obtenção da lei de controle. Este tópico é, basicamente, uma tradução livre de trechos do livro Model Predictive Control in the Process Industry, (CAMACHO e BORDONS, 1995). Na seqüência, faz-se uma descrição do controlador adaptativo e suas classificações.

### 4.1 O Controle Preditivo

O controle preditivo (MPC) não é uma estratégia de controle específica, mas um grande espectro de métodos de controle desenvolvidos em torno de certas idéias comuns. Estes métodos de projeto competem com os controladores lineares, os quais têm praticamente a mesma estrutura e apresentam graus de liberdade semelhantes. As idéias que aparecem em maior ou menor intensidade em toda a família de controladores preditivos são:

1. Usar explicitamente um modelo para produzir a saída do processo para instantes de tempos futuros (horizonte de predição);

2. Calcular uma seqüência de ações de controle que minimizam uma certa função objetivo;
3. Estratégia retrocedente, tal que, a cada instante, o horizonte é deslocado para o futuro, envolvendo a aplicação do primeiro sinal de controle da seqüência calculada, a cada passo de tempo.

Os vários algoritmos MPC diferem entre si apenas no modelo usado para representar o processo e os ruídos e a função custo a ser minimizada. Este tipo de controlador é de natureza tão ampla que muitos trabalhos têm sido desenvolvidos, tendo ampla aceitação no mundo acadêmico e na indústria.

O MPC apresenta uma série de vantagens sobre outros métodos, como por exemplo:

- a) É atrativo para equipes técnicas com conhecimentos limitados em controle de processos, por apresentar conceitos intuitivos, além da sua sintonia ser relativamente simples;
- b) Pode ser usado para controlar uma grande variedade de processos, desde aqueles com dinâmica relativamente simples até as mais complicadas, incluindo sistemas com grande tempo morto ou fases não uniformes ou instáveis;
- c) São facilmente estendidos a problemas multivariáveis;
- d) Tem compensação intrínseca para o tempo morto;
- e) Introduce o controle *feedforward* de uma forma natural para compensar distúrbios medidos;
- f) Aplica-se bem quando as referências futuras são conhecidas;
- g) É uma metodologia totalmente aberta baseada em certos princípios básicos, permitindo futuras extensões.

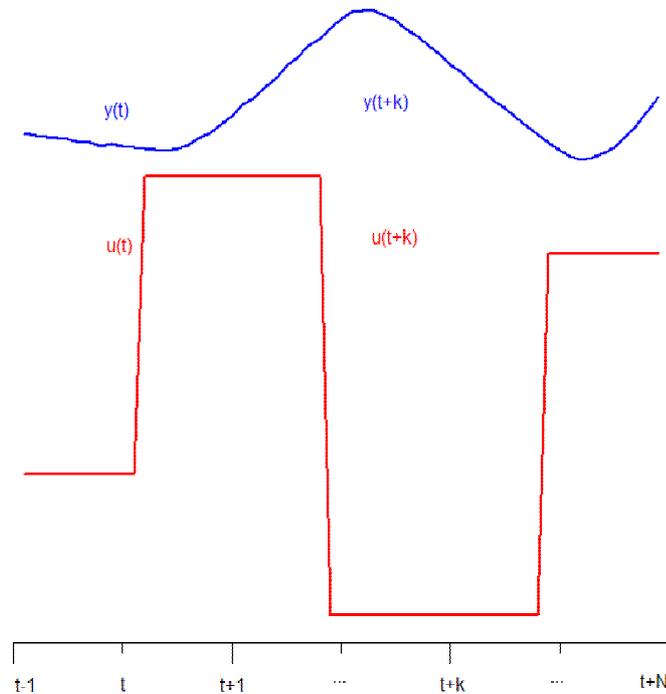
Apesar da lei de controle resultante ser de implementação relativamente fácil e requerer pouco esforço computacional, sua derivação é mais complexa do que a dos controladores clássicos PID. Se a dinâmica do processo não se modifica ao longo da operação, a derivação do controlador pode ser feita a priori, mas no caso do controlador adaptativo, todo o cálculo computacional deve ser efetuado a cada intervalo de amostragem. Apesar disto, com a capacidade de processamento dos computadores atuais, este não é o principal problema para aplicações industriais. O grande esforço é em conseguir obter um modelo que represente apropriadamente a dinâmica do processo. O projeto do algoritmo é baseado em um conhecimento prévio do modelo. É óbvio que os benefícios do controlador irão depender diretamente das discrepâncias existentes entre o processo real e o modelo adotado.

#### 4.1.1 A Estratégia do MPC

A metodologia de todos os controladores pertencentes à família MPC é caracterizada pela seguinte estratégia, representada na Figura 4-1.

- a) As saídas futuras para um determinado horizonte de predição  $N_2$ , chamado de horizonte de predição, são estimadas a cada instante de tempo  $t$  usando o modelo do processo.
- b) O conjunto de sinais das ações futuras do controlador é calculado por otimização, atendendo a um determinado critério, de forma a manter o processo o mais perto possível da trajetória de referência  $y_{ref}(k)$  (a qual pode ser o próprio *set point* ou uma aproximação do mesmo). Este critério toma, em geral, a forma de uma função quadrática do erro entre o valor predito para a saída do processo e a trajetória de referência proposta. O esforço do controlador é, muitas vezes, incluído na função objetivo. Uma

solução explícita pode ser obtida se o critério é quadrático, o modelo é linear e não existem restrições; caso contrário um método de otimização iterativo tem que ser usado.



**Figura 4-1** - Estratégia do controlador preditivo (MPC).

- c) O primeiro sinal da seqüência das ações de controle  $u(k)$  é enviado ao processo, enquanto o restante da seqüência é descartada.

Para implementar esta estratégia, a estrutura básica apresentada na Figura 4-2 é usada. Um modelo é usado para prever as saídas futuras da planta, baseado nos seus valores presente e passado e nas ações de controle futuras propostas pela otimização. Estas ações são calculadas pelo otimizador tomando em consideração a função custo, assim como as restrições impostas ao sistema.

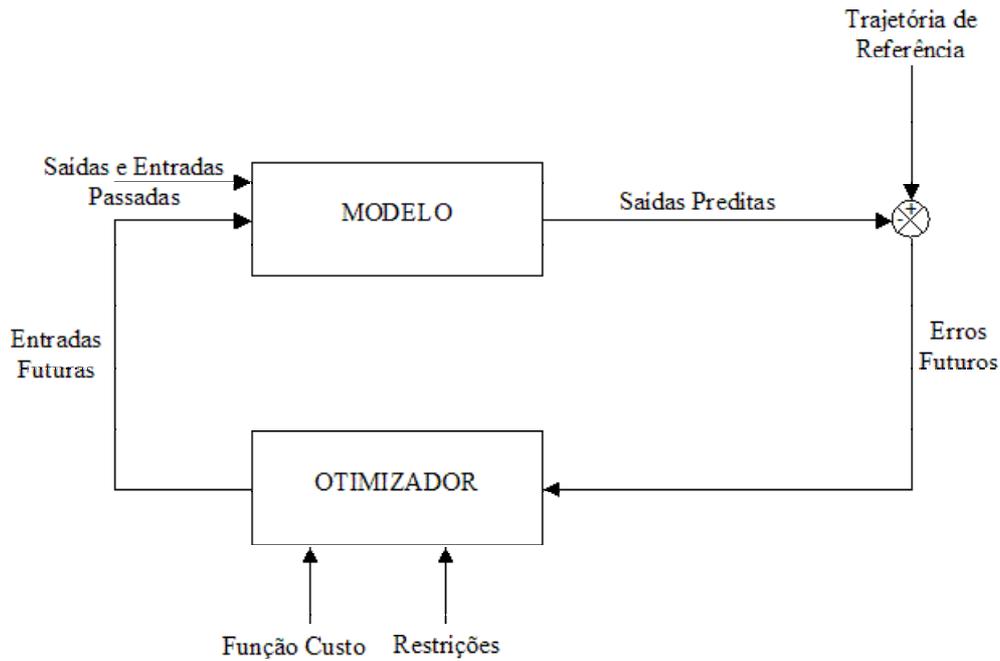


Figura 4-2 - Estrutura básica de um algoritmo de controle preditivo.

O modelo do processo tem um papel decisivo no desempenho do controlador. O modelo escolhido deve ser capaz de capturar a dinâmica do processo de forma a prever precisamente as saídas futuras, assim como ser simples na sua implementação e entendimento. Como o MPC não é uma técnica única, mas um conjunto de diferentes metodologias, existem vários tipos de modelos usados, nas mais diferentes formulações.

#### 4.1.2 A Função Objetivo

Os vários algoritmos MPC propõem diferentes funções custo para obter a lei de controle. O objetivo principal é que a saída futura ( $y$ ) no horizonte considerado deve seguir um determinado sinal de referência ( $y_{ref}$ ) e, ao mesmo tempo, o esforço do controlador ( $\Delta u$ ) necessário para isto deve ser penalizado. A expressão geral para tal função objetivo deve ser:

$$J(N_1, N_2, \dots, N_u) = E \left\{ \sum_{k=N_1}^{N_2} \delta(k) [y(k) - y_{ref}(k)]^2 + \sum_{j=1}^{N_u} \lambda(k) [\Delta u(k-1)]^2 \right\} \quad (4-1)$$

Em alguns algoritmos, o segundo termo, que considera o esforço do controlador, não é levado em conta, enquanto que em outros (UPC – *Unified Predictive Control*) os valores do sinal do controlador, e não o seu incremento, também aparece diretamente na formulação da função custo. As considerações que podem ser efetuadas na função custo são apontadas nos sub-itens a seguir.

#### 4.1.2.1 Parâmetros

$N_1$  e  $N_2$  são o valor mínimo e o valor máximo do horizonte de predição da função custo e  $N_u$  é o horizonte de controle, o qual não é necessariamente coincidente com o horizonte máximo, como será visto depois. O significado de  $N_1$  e  $N_2$  é intuitivo. Eles marcam os limites dos instantes no qual é desejado que a saída do processo siga a referência. Então, se um valor muito alto para  $N_1$  for adotado é porque não é importante que existam erros nos primeiros instantes, o que irá provocar uma resposta suave para o processo. Nota-se que em processos com um tempo morto  $d$  não existe razão para  $N_1$  ser menor do que  $d$ , porque a saída não começará a evoluir até o instante  $t + d$ . Além disto, se o processo possui resposta inversa este parâmetro irá permitir que os primeiros instantes da resposta inversa sejam eliminados da função objetivo. Os coeficientes  $\delta(k)$  e  $\lambda(k)$  são seqüências que consideram o comportamento futuro. Usualmente valores constantes ou seqüências exponenciais são considerados. Por exemplo, é possível obter um peso exponencial para  $\delta(k)$  no horizonte usando:

$$\delta(k) = \kappa^{N_2 - k} \quad (4-2)$$

Se  $\kappa$  está entre 0 e 1 significa que os erros mais distantes do instante atual  $t$  sofrerão uma penalização maior do que os mais próximos, resultando em um controlador mais suave e com menos esforço. Por outro lado, se  $\kappa > 1$ , os primeiros erros estarão sujeitos a uma maior penalização, gerando um controlador mais instável. Em PFC (*Predictive Functional Control*) o erro é contado apenas em certos pontos (*coincidence point*); pode-se obter facilmente este comportamento para a função estabelecendo valores iguais a um aos elementos da seqüência  $\delta(k)$ , nos pontos desejados e zero para os outros. Todos estes valores podem ser usados como parâmetros de ajuste do controlador para cobrir uma vasta gama de opções.

#### 4.1.2.2 Trajetória de Referência

Uma das vantagens do controle preditivo é que se a trajetória de referência for conhecida a priori, o sistema pode reagir antes que as mudanças sejam efetivamente implementadas, evitando-se com isto os efeitos do retardo na resposta do processo. A evolução futura da referência  $r(k)$  é conhecida em muitas aplicações como robótica, processos servo ou bateladas. Na minimização, a maioria dos métodos usa uma trajetória de referência que não coincide necessariamente com a referência real. Ela é, normalmente, uma aproximação suave do valor atual da saída  $y(t)$  em direção à referência conhecida por meio de um sistema de primeira ordem:

$$y_{ref}(t) = y(t) \quad (4-3)$$

$$y_{ref}(k) = \alpha y_{ref}(k-1) + (1-\alpha)r(k) \quad k = 1, \dots, N \quad (4-4)$$

$\alpha$  é um parâmetro entre 0 e 1 (quanto mais próximo de 1 mais suave será a aproximação), sendo um valor ajustável e que irá influenciar na resposta dinâmica do sistema.

Uma outra estratégia é usada no PFC, muito aplicada para *set point* variável:

$$y_{ref}(k) = r(k)\alpha^k (y(k) - r(k)) \quad (4-5)$$

#### 4.1.2.3 Restrições

Na prática todos os processos estão sujeitos a restrições. Os atuadores têm um campo limitado de ação, assim como uma determinada taxa de variação, como por exemplo, as válvulas que estão limitadas por sua posição totalmente aberta ou fechada e pela taxa de resposta, que é o tempo para a sua abertura ou fechamento. Razões construtivas, de segurança ou ambientais ou até mesmo faixa de leitura dos sensores podem impor limites nas variações do processo, como por exemplo, níveis de tanque, vazões em tubulações, valores máximos para pressões ou temperaturas. Faz-se necessário então, a introdução destas possíveis restrições na função objetivo a ser minimizada. Muitos algoritmos de controle preditivo trazem, intrinsecamente, restrições (MAC – *Model Algorithmic Control*, DMC – *Dinamic Matrix Control*) e têm vasta aplicação industrial. Normalmente, os limites na amplitude e na taxa de variação do sinal de controle e os limites na saída do processo são considerados:

$$u_{\min} \leq u(t) \leq u_{\max} \quad \forall t \quad (4-6)$$

$$du_{\min} \leq u(t) - u(t-1) \leq du_{\max} \quad \forall t \quad (4-7)$$

$$y_{\min} \leq y(t) \leq y_{\max} \quad \forall t \quad (4-8)$$

A adição destas restrições na função objetivo torna a minimização mais complexa, tal que a solução não pode ser obtida explicitamente como nos casos sem restrições.

#### 4.1.2.4 Restrições de Sobre Elevação

Em alguns processos a sobre elevação (*overshoot*) não é desejável por diferentes razões.

Restrições para a sobre elevação são de fácil implementação. Sempre que uma mudança é produzida no *set point*, e o mesmo se mantém constante por um período de tempo suficientemente longo, as seguintes restrições são adicionadas ao sistema de controle:

$$y(k) \leq y_{ref}(k) \quad k = N_{01}, \dots, N_{02} \quad (4-9)$$

Onde  $N_{01}$  e  $N_{02}$  definem o horizonte onde a sobre elevação não pode ocorrer.

#### 4.1.2.5 Comportamento Monotônico

Alguns sistemas de controle tendem a exibir oscilações não desejáveis na variável controlada antes de atingir o *set point*, conhecidas como *kickback*. Pode-se adicionar restrições ao sistema de controle para evitar este tipo de comportamento, impondo um comportamento monotônico à variável de saída. Cada vez que o *set point* muda, novas restrições são adicionadas ao sistema de controle, como as que seguem:

$$u(k) \leq u(k+1) \quad se \quad y(k) < y_{ref}(k) \quad (4-10)$$

$$u(k) \geq u(k+1) \quad se \quad y(k) > y_{ref}(k) \quad (4-11)$$

### 4.1.3 Obtenção da Lei de Controle

Os valores de  $u(k)$  são obtidos através da minimização da equação funcional  $J$ , equação (4-1). Para isto, as saídas preditas  $\hat{y}(k)$  são calculadas em função dos valores passados das entradas e saídas e dos sinais de controle futuros, fazendo uso do modelo

escolhido e substituindo-as na função custo, obtendo assim um expressão cuja minimização leva aos valores procurados. Uma solução analítica pode ser obtida pelo critério quadrático se o modelo for linear e não existirem restrições. De outra forma, um método de otimização iterativo deve ser usado.

#### **4.1.4 Modelos para o MPC**

Pelo que foi apresentado, até então, percebe-se que o ponto mais importante do controle preditivo é o modelo do processo. Os modelos podem ser subdivididos em função de suas várias características. Como o MPC requer a solução de um modelo para prever as saídas futuras do processo, a forma do modelo selecionado vai repercutir também no desempenho do método. Algumas categorias de modelos serão discutidas nos próximos sub-itens.

##### *4.1.4.1 Linear ou Não Linear*

A resposta de sistemas dinâmicos lineares obedece ao princípio da superposição, isto é, a resposta do sistema a uma combinação linear de entradas é igual a uma combinação linear de suas respostas a cada entrada separadamente. Muitos sistemas de engenharia aproximam-se deste comportamento para pequenos desvios na entrada. As técnicas de controle linear são as primeiras a serem testadas na maioria das aplicações de controle, sendo satisfatórias para a maior parte delas, principalmente aquelas que envolvem manter o processo no estado estacionário em um ponto de operação. Modelos lineares são extensivamente usados nas aplicações industriais do MPC.

Modelos não lineares não têm características específicas, exceto a de não se incluírem no caso linear. Isto torna difícil a sua generalização, já que os modelos não lineares podem ter qualquer característica. Em contraposição às aplicações dos modelos

lineares, os modelos não lineares são utilizados em processos que envolvem grandes variações nas condições de operação e em processos com acentuadas não linearidades (HENSON e SEBORG, 1997).

#### 4.1.4.2 *Contínuo ou Discreto*

A maioria das leis físicas usadas pelos engenheiros no desenvolvimento dos modelos é apresentada na forma de equações diferenciais, tendo o tempo como variável independente. Uma representação típica é da forma:

$$\dot{y} = f(y, u) \quad (4-12)$$

Antes do uso difundido dos computadores digitais, modelos em equações diferenciais eram as ferramentas centrais dos pesquisadores e engenheiros de controle para o estudo da dinâmica de sistemas.

Com o advento dos computadores digitais o estudo de equações diferenças assumiu um novo significado. Pode-se escrever uma equação diferença não linear como  $y_{k+1} = f(y_k, u_k)$ . Como o MPC tem sido implementado através de computadores digitais, as equações diferenças têm sido preferidas em relação às equações diferenciais. Modelos em equações diferenciais têm sido discretizados para permitir a sua solução computacional.

#### 4.1.4.3 *Parâmetros Distribuídos ou Parâmetros Agrupados*

Um modelo com parâmetros distribuídos envolve equações diferenciais parciais, ao invés de equações diferenciais ordinárias. Um exemplo de um modelo com parâmetros distribuídos pode ser o de um reator com escoamento empistonado, no qual as mudanças das concentrações das espécies químicas no reator estão sujeitas a variações

espaciais e no tempo. Os conceitos básicos do MPC permitem que o mesmo seja perfeitamente aplicável a modelos com parâmetros distribuídos, apesar da sua complexidade de solução.

#### *4.1.4.4 Determinístico ou Estocástico*

Todos os processos físicos estão sujeitos a distúrbios não preditos. Estes distúrbios podem afetar o projeto e operação do MPC de, ao menos, duas formas distintas:

- a) Na identificação do modelo do processo um modelo é selecionado baseado em resultados experimentais. O processo de seleção usa considerações (implícitas ou explícitas) sobre os distúrbios para selecionar e avaliar o modelo. Estas considerações têm um impacto direto sobre o modelo selecionado.
- b) Depois que a fase de identificação do modelo está completa, as considerações sobre os distúrbios são as vezes descartadas e o projeto do controlador pode ser baseada no seu modelo nominal. Se o modelo do processo nos permite prever as variações estatísticas do processo baseadas em considerações sobre os efeitos randômicos no modelo, dizemos que o modelo é estocástico.

#### *4.1.4.5 Entrada-Saída ou Espaço de Estado*

Como indicado pelo nome, modelos entrada-saída fornecem uma relação entre a entrada e a saída do processo sem referências às variáveis internas do processo. Como a maioria dos modelos estado de espaço é baseada em balanços de calor, massa e momento, cada estado tem um significado físico. Os estados também podem ser encontrados com um modelo entrada-saída através de manipulações matemáticas e variáveis intermediárias.

Um caso especial do modelo entrada-saída é a rede neural artificial, a qual tem sido usada em diversas aplicações de engenharia, incluindo o controle preditivo.

#### *4.1.4.6 Fenomenológicos ou “Caixa Preta”*

Modelos que são derivados a partir de balanços de calor, massa e momento são, geralmente, chamados de fenomenológicos ou fundamentais, em contraste com outro esquema de modelagem que ajusta um conjunto de dados a uma função arbitrária. Ambas as abordagens têm sido usadas em aplicações de controle preditivo.

As diferenças nesta classe de modelos, fenomenológicos ou “caixa preta”, estão na sua capacidade de extrapolação e no seu custo de obtenção. Um modelo fenomenológico, a princípio, pode ser usado em uma ampla faixa de aplicação, mesmo sem experiências operacionais anteriores, desde que as considerações assumidas no seu desenvolvimento permaneçam válidas. Por outro lado, modelos do tipo “caixa preta” não têm a capacidade de extrapolar com segurança na obtenção de valores fora das condições operacionais em que os dados foram coletados. Porém, a calibração e validação de modelos do tipo “caixa preta” são muito mais simples e menos custosos de se atingir do que os modelos fenomenológicos.

As diversas classes de modelos apresentados dificilmente conseguem representar o comportamento do processo através de uma vasta faixa de operação. Além disto, alterações no processo como inscrustração em trocadores de calor, perda de seletividade/atividade de catalisadores, usualmente requerem ajustes nos parâmetros do modelo para garantir a sua fidedignidade. As técnicas de adaptação são as mais recomendadas para estas situações e será o assunto da próxima seção.

## 4.2 Controlador Adaptativo

Os controladores adaptativos são sistemas de controle que automaticamente ajustam seus parâmetros de modo a compensar mudanças no processo ou ambiente. Os algoritmos dos controladores adaptativos diferenciam-se no modo como a adaptação é feita (*Scheduling* ou otimização *on-line*) e quais parâmetros são adaptados.

Os esquemas de controle adaptativo fornecem abordagens sistemáticas e flexíveis para lidar com incertezas, não linearidades e parâmetros de processo variáveis com o tempo. Conseqüentemente, sistemas de controle adaptativo oferecem potencial de melhoria para controle de processos difíceis, onde o processo é pouco entendido ou mudam de forma não preditível.

O início das pesquisas nesta área data dos anos 50. As principais dificuldades para o seu desenvolvimento eram a falta de uma teoria e limitações de *hardware* (“muito entusiasmo, pouco *hardware* e teoria não existente”) (ÄSTROM, 1983). A década de 60, nesta área, caracterizou-se pelo desenvolvimento de estratégias de projeto para controle adaptativo sustentadas por uma base teórica sólida, estruturada pela introdução de conceitos de controle moderno, especialmente da teoria de estabilidade. A década de 70 trouxe mais alguns incrementos teóricos para o controlador adaptativo como sistemas auto-ajustáveis e a disponibilidade de *hardwares* baratos para o controle digital.

É conveniente distinguir entre duas categorias gerais de aplicações de controle adaptativo. A primeira categoria consiste em situações onde as mudanças no processo podem ser antecipadas ou medidas diretamente. Se o processo é razoavelmente bem conhecido, então é possível ajustar os parâmetros do controlador de uma forma sistemática (chamada de adaptação programada ou *gain scheduling*), à medida que as condições do processo mudam ou distúrbios entram no sistema. A segunda categoria consiste de situações onde as mudanças no processo podem ser medidas ou previstas.

Nesta situação mais difícil, a estratégia de controle adaptativo deve ser implementada de uma forma *feedback*, desde que existe pouca oportunidade para estratégias do tipo *feedforward*, como na adaptação programada. Muitos destes controladores são referidos como controladores auto-ajustáveis; eles são geralmente implementados através de controle por computador digital.

Os subitens seguintes irão tratar destas subclasses do algoritmo de controle adaptativo.

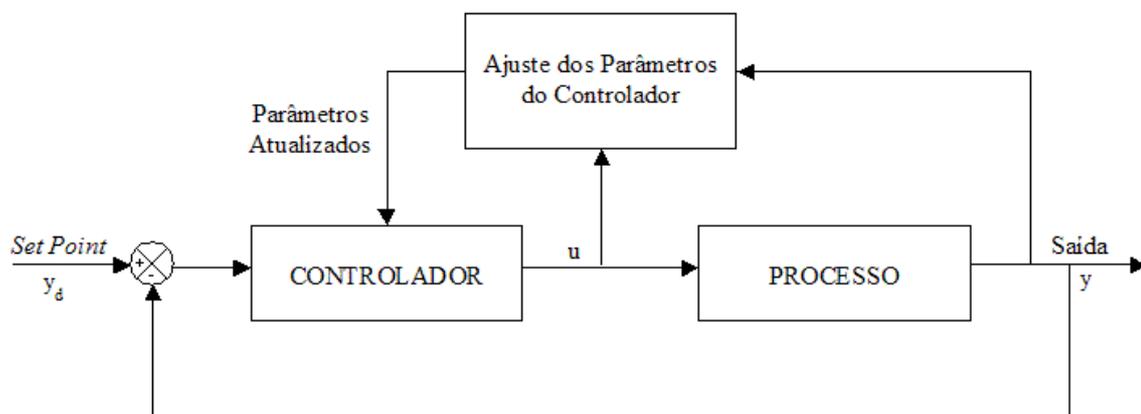
#### **4.2.1 Adaptação Programada**

Se um processo opera dentro de uma faixa de condições, melhorias no controle podem ser obtidas utilizando-se diferentes conjuntos de parâmetros para o controlador, para cada condição de operação. Alternativamente, uma relação pode ser desenvolvida entre os parâmetros do controlador e as variáveis do processo. A adaptação programada é limitada a aplicações onde a dinâmica do processo depende de medidas. O tipo mais comum de adaptação programada é o *Gain Scheduling*, onde o ganho do controlador é ajustado tal que o ganho da malha aberta permaneça constante.

Neste algoritmo existe um conhecimento a priori e uma fácil quantificação das variáveis responsáveis pelas mudanças nas características do processo. As mudanças requeridas para os parâmetros do controlador são pré-programadas. Este tipo de controlador adaptativo é ilustrado na Figura 4-3. Nele, à medida que as variáveis de entrada/saída do processo mudam significativamente, as informações são enviadas ao controlador e seus parâmetros são ajustados de acordo com a programação. Na prática, o procedimento reduz-se a uma tabela de parâmetros que dependem da faixa de operação do processo.

### 4.2.2 Controlador Auto-Ajustável

Se a medida do processo não pode ser medida nem antecipada, a adaptação programada não pode ser usada. Uma aproximação alternativa é atualizar os parâmetros do modelo do processo à medida que novos dados são adquiridos (estimativa *on-line*) e então, basear os cálculos de controle no modelo atualizado. Por exemplo, os parâmetros do controlador podem ser expressos como uma função dos parâmetros do modelo do processo e atualiza estes parâmetros *on-line*, quando os dados de entrada/saída do processo são obtidos. Este tipo de controlador é referido como auto-ajustável ou auto-adaptativo. Controladores auto-ajustáveis são implementados, geralmente, conforme a Figura 4-4.

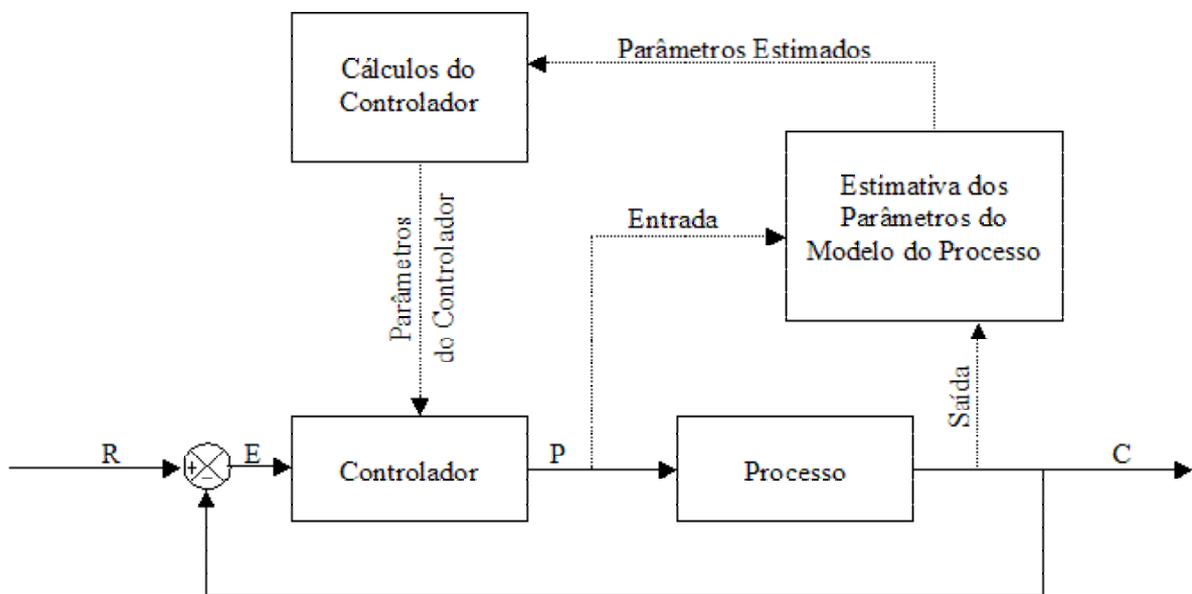


**Figura 4-3** - Diagrama de blocos representando a estrutura do algoritmo de controle com adaptação programada.

Na Figura 4-4 três conjuntos de cálculos são empregados: estimativa dos parâmetros do modelo do processo, cálculo dos parâmetros do controlador e implementação dos parâmetros na malha de controle. A maioria das técnicas para estimativa de parâmetros em tempo real requer que um sinal externo seja ocasionalmente introduzido para permitir uma estimativa precisa dos parâmetros do modelo. Tal sinal de

entrada pode ser deliberadamente introduzido no *set point* ou adicionado na saída do controlador.

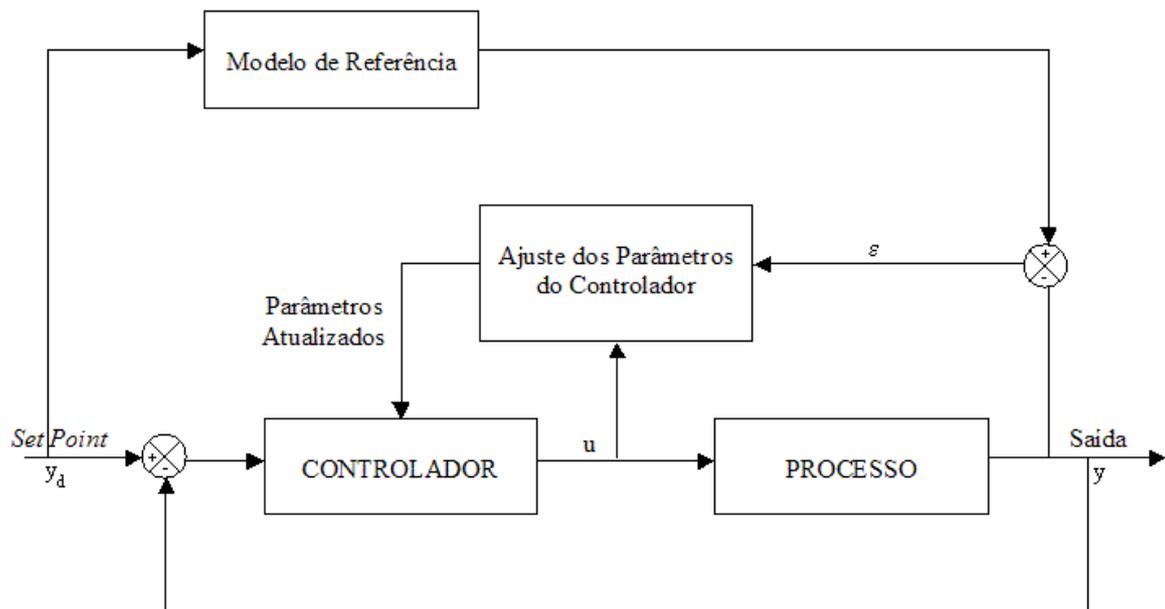
O primeiro tipo de controlador adaptativo auto-ajustável, chamado de *Self-Tuning Regulator*, foi proposto em 1973 por Åström e Wittenmark e desde então tem sido implementado em diversas aplicações industriais (SEBORG et al, 1989). Modificações subseqüentes, como o *Self-Tuning Controller* e o *Generalized Predictive Controller* também têm sido usados.



**Figura 4-4** - Diagrama de blocos representando o algoritmo de controle adaptativo auto-ajustável.

A estratégia de controle adaptativa conhecida como MARC, *Model Reference Adaptive Control*, tenta obter uma resposta em malha fechada que seja o mais próximo possível de uma resposta desejada (referência). Esta estrutura de controle está ilustrada na Figura 4-5. O componente chave do algoritmo MRAC é o modelo de referência que consiste em um modelo em malha fechada representando como o processo deve responder a uma mudança no *set point*. O modelo pode ser uma simples trajetória ou um modelo mais sofisticado. A saída do modelo é comparada com a saída do processo e o erro observado é utilizado para promover algum esquema de adaptação, fazendo com que

os parâmetros do controlador sejam ajustados de modo a reduzir este erro a zero. O esquema adaptativo pode ser algum algoritmo de otimização dos parâmetros do controlador que reduz a integral dos quadrados dos erros ou algum outro procedimento semelhante.



**Figura 4-5** - Diagrama de blocos representando a estrutura do algoritmo de controle adaptativo com modelo de referência.

A diferença básica entre o controlador adaptativo com modelo de referência e o controlador adaptativo auto-ajustável é que este último usa a entrada e a saída do processo para estimar, recursivamente, *on-line*, os parâmetros do modelo do processo. Então, à medida que o processo muda as suas características com o ponto de operação ou com o tempo, os parâmetros do modelo são continuamente atualizados. O modelo atualizado é utilizado para recalculer os parâmetros do controlador. O controlador pode ser um PID ou um modelo preditivo (MPC).

Desde que o modelo estimado determina a eficácia do controlador, a característica essencial para o controlador auto-ajustável é a sua robustez na identificação do modelo. Isto requer um bom algoritmo para a estimativa dos parâmetros.

O tema controle adaptativo é de grande interesse na atualidade, como pode ser comprovado pela revisão bibliográfica apresentada no capítulo 3. Muitos algoritmos novos estão em desenvolvimento, mas necessitam de testes em campo para que possam ter aceitação industrial. Está claro, ainda, que as técnicas digitais são necessárias para a implementação de controladores auto-ajustáveis devido à sua complexidade.

No próximo capítulo será apresentada a metodologia adota neste trabalho, onde um controlador preditivo auto-ajustável é implementado para o controle de um reator de pirólise. O modelo não linear adotado é uma rede neural, a qual tem os seus parâmetros ajustados *on-line* para que a mesma consiga prever com fidelidade toda a faixa de operação do processo, sem *offset* e de forma estável.

# Capítulo 5

## Metodologia

---

**I**niciou-se este trabalho através da montagem do aparato experimental. Foram montados dois reatores de pirólise, em escalas diferentes. No primeiro deles, de 0.5 L, foram realizadas as calibrações dos sensores e testes iniciais de pirólise. Entretanto, devido às suas dimensões reduzidas, os efeitos térmicos gerados pelas reações que ocorriam no reator não foram significativos. A sua capacidade de processamento de resíduos era reduzida e, portanto, o calor absorvido pela reação era insignificante frente ao calor fornecido para manter a temperatura do reator nos valores especificados. Assim sendo, um reator de 8 L, processando 1000 g de resíduo foi implementado, garantindo que os efeitos térmicos e cinéticos fossem perceptíveis no sistema reacional (Anexo A1).

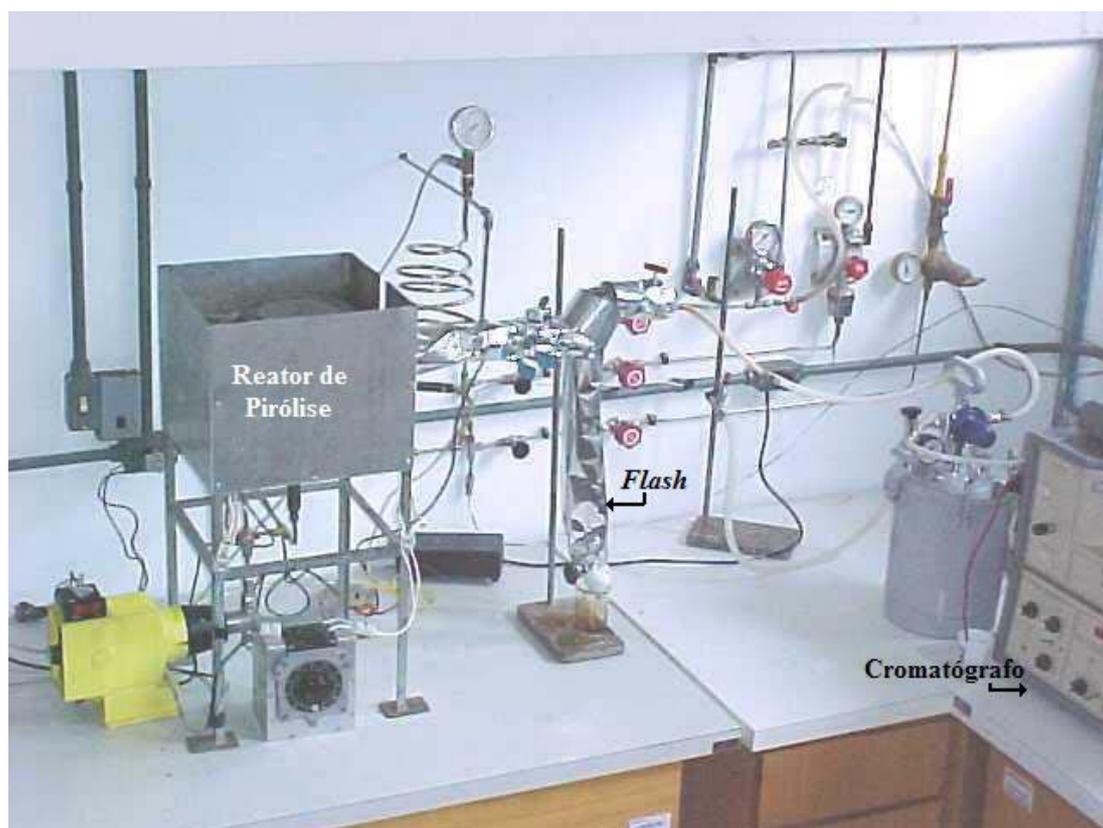
Neste capítulo, faz-se a apresentação do sistema desenvolvido, a disposição e calibração da instrumentação utilizada no sistema de controle digital, os procedimentos adotados nas corridas experimentais, além do algoritmo de controle proposto e sua sintonia.

### 5.1 Local de Trabalho: Laboratório de Reatores

O Laboratório de Reatores está instalado no Departamento de Engenharia Química, integrando o Centro de Ciências Exatas e Tecnologia da Universidade de Caxias

do Sul. Neste laboratório vem sendo desenvolvido, em especial, um processo para pirólise de resíduos industriais. O grupo de pesquisa vinculado a este laboratório iniciou as pesquisas no ano de 1997.

A Figura 5-1 apresenta uma visão parcial do laboratório, constando de reator de pirólise de 0.5 L, separador *flash*, módulo de potência, um computador, capela, cromatógrafo a gás e integrador.



**Figura 5-1** - Vista parcial do sistema de pirólise de 0.5 L do Laboratório de Reatores do Departamento de Engenharia Química da Universidade de Caxias do Sul.

O novo sistema desenvolvido, com um reator de 8 L, pode ser visto na Figura 5-2. Fazendo uma comparação com o sistema menor, a instrumentação e os equipamentos de análise são os mesmos, mas toda a tubulação, reator e separador *flash* foram redimensionados para a nova escala de processamento.



Figura 5-2 - Foto do sistema de pirólise com reator de 8 L.

## 5.2 Aparato Experimental

Nessa etapa foram desenvolvidos o projeto, montagem e entendimento dos princípios de funcionamento de cada equipamento pertencente aos sistemas de reação e de análise. O sistema reacional foi desenvolvido em escala de bancada, consistindo de reator, separador *flash* e sistema de aquisição de dados usado para coletar *on-line* valores de temperatura, pressão e manipular a taxa de aquecimento do reator. Dois reatores de pirólise foram construídos. O primeiro em menor escala opera em alta pressão, sendo denominado de retorta, foi utilizado na primeira etapa deste trabalho. A implementação de um algoritmo de controle preditivo baseado em redes neurais foi desenvolvido utilizando este reator. Um segundo reator pirolítico foi construído com volume aproximadamente 10 vezes maior que o primeiro e utilizado em testes mais consistentes,

uma vez que a retorta não foi sensível à energia de reação, devido à pequena quantidade de resíduo que o mesmo comportava, funcionando praticamente como um forno.

Os dois sistemas utilizados nos experimentos serão descritos em detalhes a seguir, fazendo uma descrição pormenorizada dos itens que o compõe, assim como o procedimento operacional adotado em ambos os casos.

### 5.2.1 Sistema Operacional I: Retorta

Uma vista parcial deste processo já foi anteriormente apresentado na Figura 5-1. Um fluxograma do processo pode ser visualizado na Figura 5-3.

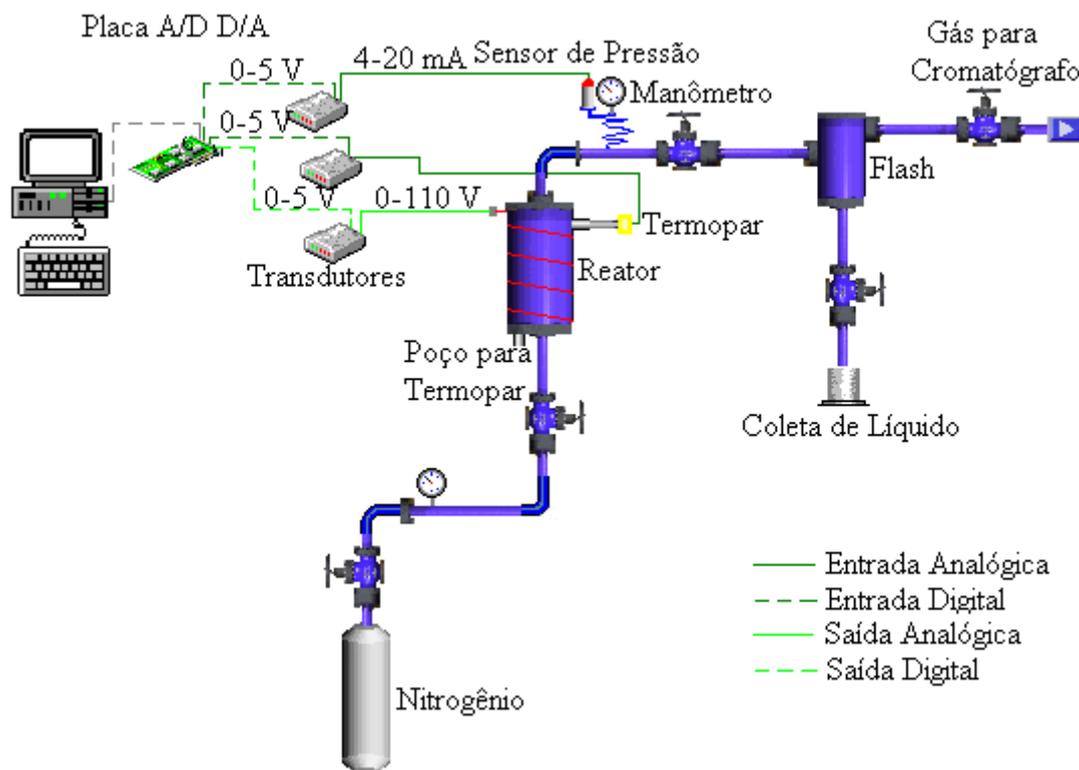
Os principais equipamentos utilizados neste sistema estão listados abaixo:

1. Reator de 0.5 L;
2. Separador Flash;
3. Resistência elétrica de 14  $\Omega$ ;
4. Válvulas e tubulações de  $\frac{1}{4}$  in.

A instrumentação necessária para o monitoramento e controle do processo de pirólise é:

- a) Termopar tipo J;
- b) Condicionador de sinal Ultra Slimpack G428 transformando o sinal do sensor de temperatura para a faixa de tensão entre 0 e 5 V.;
- c) Transdutor de pressão com leitura mínima de 0 bar e um *span* igual a 15 bar. A saída do transdutor era em corrente, variando de 4 a 20 mA;
- d) Transdutor corrente/tensão para o sinal do transdutor de pressão, condicionando o sinal para uma faixa de 0 a 5 V;
- e) Módulo de potência com entrada de 0-5 V e saída de 0-110V;

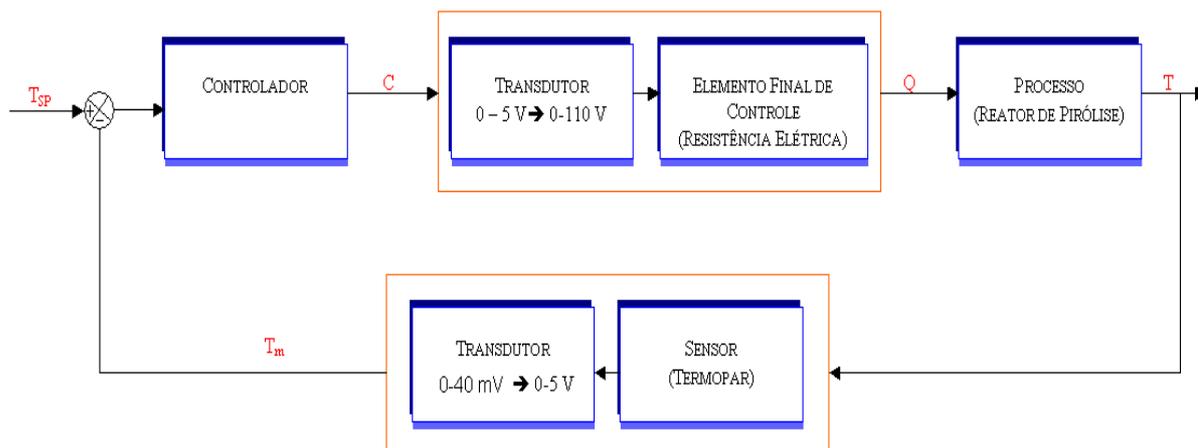
- f) Placa de aquisição de dados CIO-DAS Jr 08, com oito entradas analógicas e duas saídas analógicas de  $\pm 5$  V;
- g) Computador com processador Pentium 100 MHz.



**Figura 5-3** - Fluxograma do processo de pirólise.

O fluxo de informações entre as variáveis do processo, instrumentação e controlador é melhor visualizado no diagrama de blocos exibido na Figura 5-4. A temperatura do processo ( $T$ ) é lida através de um termopar inserido em um poço lateral do reator. O sinal do termopar é amplificado a valores adequados para a placa de aquisição de dados ( $T_m$ ). Este sinal é enviado para a placa, onde o sinal analógico é convertido em digital. O algoritmo de controle calcula a ação de controle ( $C$ ) baseado no estado do processo. O valor calculado pelo controlador é um sinal digital, sendo este convertido na placa de aquisição de dados para valores que variam entre 0 e 5 V. Entretanto, este sinal precisa ser amplificado para que a taxa de calor fornecida ao processo seja suficiente para

manipular a temperatura do reator. Um módulo de potência amplifica linearmente a tensão de saída emitida pelo controlador para uma faixa de 0 a 110 V. Esta tensão elétrica é aplicada na resistência que envolve o reator, fornecendo o fluxo de calor (Q) necessário para conduzir a temperatura do reator aos valores especificados.



**Figura 5-4** - Diagrama de blocos do sistema de controle de temperatura do reator de pirólise.

### 5.2.2 Sistema Operacional II: Reator de Pirólise

Dois itens diferenciam basicamente o sistema reacional I do sistema reacional II: suas dimensões e suas resistências à pressão. O reator aqui utilizado tem um volume de 8 L e conseqüentemente, todos os equipamentos a jusante têm que atender à demanda devido ao aumento da capacidade de processamento. O separador *flash* desta vez necessita de um sistema de refrigeração. Uma serpentina de cobre, com diâmetro de 3/4 in, com circulação interna de água, possibilita a condensação do óleo combustível produzido.

A instrumentação é a mesma, sendo que o poço para leitura de temperatura é agora localizado na tampa superior do reator, a tensão elétrica na resistência varia de 0 a 220 V e o processador do computador foi um Pentium II 300 MHz.

### **5.2.3 Operação dos Aparatos Experimentais**

A diferença fundamental entre o modo de operação dos dois sistemas operacionais é que o primeiro opera em modo batelada e o segundo em modo semibatelada.

Em ambos os casos, o resíduo a ser pirolisado foi alimentado por sua abertura superior. Os testes foram realizados com 20 g de resíduo na retorta e 1000 g no reator de pirólise. Após o carregamento, o reator é fechado e alimentado com nitrogênio por dois motivos: verificar possíveis vazamentos no sistema e criar uma atmosfera isenta de oxigênio, evitando-se a formação de dioxinas e furanos. Em seguida, abre-se a válvula de saída de gases, eliminando o nitrogênio presente. Neste momento a reação está pronta para ser iniciada.

Na retorta o reator permanece fechado e à medida que a reação evolui, os gases produzidos vão provocando a pressurização do reator. Ao final do processo o reator é aberto e os produtos são recolhidos, configurando-se em uma operação em batelada.

No reator de pirólise à medida que a reação evolui e os gases são produzidos provocando a pressurização do reator, abre-se a válvula de saída dos gases para aliviar a pressão do reator, configurando-se em uma operação semibatelada.

O prosseguimento das reações de pirólise passa a ser conduzido pelo algoritmo de controle. Os algoritmos de controle implementados, juntamente com uma descrição detalhada dos códigos computacionais, serão apresentados nos itens seguintes.

## **5.3 Os Algoritmos de Controle**

Três algoritmos de controle foram implementados: um controlador do tipo retroalimentação digital, utilizado para efeito de comparação, um algoritmo de controle preditivo e um algoritmo de controle preditivo adaptativo. O método de otimização

*backpropagation* foi empregado tanto para o cálculo das ações de controle como para o treinamento *on-line* da rede neural (modelo do processo). Os controladores MPC utilizaram como modelo do processo uma rede neural *feedforward* com três camadas e com 3 neurônios na camada de entrada, 5 na camada intermediária e 1 na camada de saída. Uma descrição mais completa do modelo e dos algoritmos de controle implementados é o assunto dos próximos tópicos.

### **5.3.1 O Modelo do Processo**

O modelo do processo foi expresso através de redes neurais multicamadas. A rede adotada possuía três neurônios na camada de entrada, cinco neurônios na camada intermediária e um neurônio na camada de saída.

No primeiro caso estudado, o reator de 0.5 L, a rede tinha pesos fixos, os quais eram determinados *off-line*.

No segundo caso, o reator de 8 L, os pesos iniciais da rede eram obtidos *off-line*, mas dois procedimentos distintos foram adotados: no primeiro deles os pesos foram mantidos constantes, configurando-se um controlador preditivo; no segundo procedimento os pesos eram ajustados *on-line* através do treinamento da rede com padrões obtidos durante as corridas. O número de elementos do padrão era fixo, porém tinham seus valores alterados a cada instante de amostragem pela técnica da Janela Móvel, que será discutida mais a frente.

### **5.3.2 O Controlador Proporcional – Integral – Derivativo (PID)**

O algoritmo de controle digital com realimentação é uma emulação do algoritmo de controle PID (proporcional – integral – derivativo). Este assunto está bem fundamentado e descrito na literatura, podendo ser encontrado em diversos livros sobre

controle de processo (SMITH e CORRIPIO, 1997). Nesta seção será feita uma apresentação sucinta do algoritmo de controle digital *feedback* e do método para a sua sintonia adotado neste trabalho. O algoritmo de controle adotado contém um filtro para atenuar ruídos no termo derivativo.

O algoritmo é baseado na função de transferência de um controlador clássico PID, o qual segue a equação ( 5-1).

$$\frac{U(s)}{E(s)} = K_C \left[ 1 + \frac{1}{\tau_I s} + \frac{\tau_D s}{\eta \tau_D s + 1} \right] \quad (5-1)$$

Onde  $U(s)$  é a saída do controlador,  $E(s)$  é o erro, calculado como o valor do *set point* menos a variável controlada, de acordo com a equação ( 5-2) e o termo  $\frac{1}{\eta \tau_D s + 1}$  é uma função de transferência primeira ordem com ganho unitário e constante de tempo  $\eta \tau_D$ . Este termo age como um filtro, o qual não afeta a performance do controlador, desde que a sua constante de tempo  $\eta \tau_D$  seja pequena. Valores típicos para  $\eta$  oscilam na faixa de 0.05 a 0.2.

$$E(s) = R(s) - Y(s) \quad (5-2)$$

A equação ( 5-1) pode ser escrita em uma forma discreta, de acordo com as equações ( 5-3) e ( 5-4).

$$Y_n = \frac{\alpha \tau_D}{\alpha \tau_D + T} Y_{n-1} + \frac{\tau_D}{\alpha \tau_D + T} (E_n - 2E_{n-1} + E_{n-2}) \quad (5-3)$$

$$\Delta U_n = K_C \left[ E_n - E_{n-1} + \frac{T}{\tau_I} E_n + Y_n \right] \quad (5-4)$$

A saída do controlador é então calculada por um acumulador padrão:

$$U_n = U_{n-1} + \Delta U \quad (5-5)$$

Na equação ( 5-4) o termo  $Y_n$  é o termo derivativo com o filtro, calculado pela equação ( 5-3).

O parâmetro  $\eta$  deve ser obtido por tentativa e erro, iniciando-o com um valor igual a um décimo do tempo derivativo  $\tau_D$ . Para o ajuste dos outros parâmetros ( $K_C, \tau_I, e \tau_D$ ) utilizou-se o método ITAE (*Integral of the Time-Weighted Absolute Value of the Error*), para controladores analógicos. Está aproximação é válida para sistemas com amostragens rápidas, ou seja, menor que um décimo da constante de tempo dominante do sistema e a faixa de  $0.1 \leq \frac{\theta}{\tau_P} \leq 1.0$  (LOPEZ et al., 1967). Os parâmetros

estimados para o controlador PID são obtidos em função do tipo de distúrbio a que o processo está submetido (problema servo ou regulador). As equações para o sistema submetido aos problemas do tipo servo e regulador são apresentadas nas Tabela 5-1 e Tabela 5-2.

**Tabela 5-1** - Fórmulas para sintonia de controladores PID pelo método ITAE submetidos a mudanças no *set point*.

---


$$K_C = \frac{0.965}{K_P} \left( \frac{\theta}{\tau_P} \right)^{-0.855} \quad (5-6)$$


---

$$\tau_I = \frac{\tau_P}{0.796 - 0.147 \frac{\theta}{\tau_P}} \quad (5-7)$$


---

$$\tau_D = 0.308 \tau_P \left( \frac{\theta}{\tau_P} \right)^{0.9292} \quad (5-8)$$


---

**Tabela 5-2** - Fórmulas para sintonia de controladores PID pelo método ITAE submetidos um problema regulador.

$$K_C = \frac{1.357}{K_P} \left( \frac{\theta}{\tau_P} \right)^{-0.947} \quad (5-9)$$

$$\tau_I = \frac{\tau_P}{0.842} \left( \frac{\theta}{\tau_P} \right)^{0.738} \quad (5-10)$$

$$\tau_D = 0.381 \tau_P \left( \frac{\theta}{\tau_P} \right)^{0.995} \quad (5-11)$$

A sintonia do controlador com ações proporcional e integral são dadas na Tabela 5-3.

**Tabela 5-3** - fórmulas para a sintonia de controladores PI pelo método ITAE submetidos a um problema servo.

$$K_C = \frac{0.965}{K_P} \left( \frac{\theta}{\tau_P} \right)^{-0.855} \quad (5-12)$$

$$\tau_I = \frac{\tau_P}{0.796 - 0.147 \frac{\theta}{\tau_P}} \quad (5-13)$$

Foram utilizados os parâmetros obtidos para o problema servo, equações ( 5-6), ( 5-7) e ( 5-8) para o controlador PID e as equações ( 5-12) e ( 5-13) para o controlador PI.

### 5.3.3 O Controlador Preditivo

O algoritmo de controle preditivo adotou uma rede neural recursiva como modelo para descrever o comportamento dinâmico do processo (Figura 5-5). A rede é treinada *off-line* e é utilizada explicitamente para prever o comportamento dinâmico do sistema, através de um horizonte de predição estipulado. Foi desenvolvido um código computacional, em linguagem Delphi, para o treinamento *offline*. A cada intervalo de amostragem o algoritmo deve encontrar uma seqüência de ações de controle ótimas

(dentro de um horizonte de controle determinado) através da minimização da função objetivo:

$$J = \delta \sum_{k=1}^{N_s} (T_{ref_k} - T_k)^2 + \lambda \sum_{k=1}^{N_u} \Delta u_k^2 \quad (5-14)$$

A trajetória de referência é definida pela equação ( 5-15 ):

$$T_{ref_{k+1}} = \alpha T_{ref_k} + (1 - \alpha) T_{SP} \quad (5-15)$$

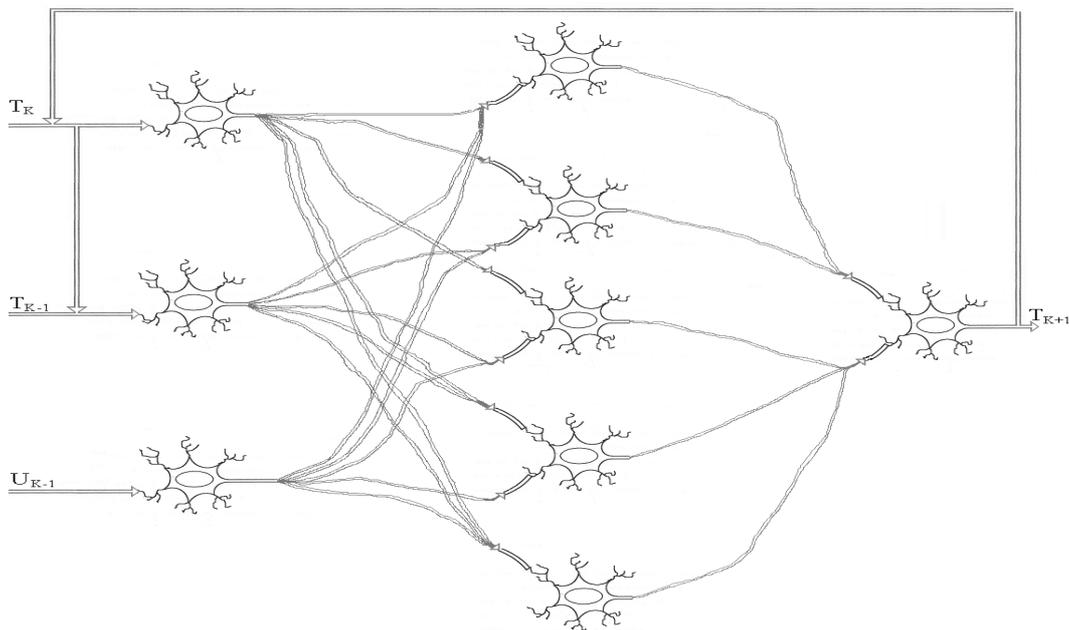
Onde o valor de  $T_{ref_1}$  é o valor da temperatura no instante  $k$ .

O valor de  $\alpha$ , o qual está na faixa de 0 a 1, determina a velocidade de transição entre a temperatura atual e a temperatura do set point. Valores de  $\alpha$  próximos a um faz com que a transição seja conservativa, enquanto valores próximos a zero aproximam a referência de uma perturbação tipo degrau.

Foi adotado como modelo para o processo uma rede neural multicamada conforme esquematizado na Figura 5-5. A camada de entrada da rede é composta por três neurônios. As variáveis associadas a estes neurônios são a temperatura do reator nos instantes  $k$  e  $k-1$ , e a tensão de saída do controlador no instante  $k-1$ . Foi adotada como função de ativação dos neurônios a função sigmoideal.

A camada intermediária possui cinco neurônios e a camada de saída apenas um. A saída da rede é a temperatura predita para o instante  $k+1$ . Como a rede é dinâmica, poderá estimar as temperaturas futuras através de um intervalo de tempo pré-definido. Para isto, utiliza a sua estrutura recursiva e ao realimentar a saída da rede à posição que entrava a temperatura do reator no instante  $k$ , e deslocando esta para a posição da temperatura em  $k-1$ . A entrada do processo passa a ser  $U_k$ . Então, ocorre um deslocamento da rede no tempo e a saída será a temperatura estimada para o instante  $k+2$ . Este procedimento pode ser repetido até completar o horizonte de predição

desejado. Entretanto, deve-se ter uma estimativa para as seqüências de controle dentro deste intervalo de tempo.



**Figura 5-5** - Representação esquemática de uma rede neural completamente recorrente.

O método empregado para resolver o problema de encontrar o mínimo para a equação (5-14) é iterativo, uma vez que para obter a seqüência ótima das ações de controle faz-se necessário o conhecimento prévio das temperaturas futuras previstas pela rede neural. Entretanto, a estimativa destas temperaturas exige o conhecimento das ações de controle futuras, objetivo do problema. Assim, inicia-se o cálculo com a seqüência de controle obtida na amostragem anterior, prosseguindo, iterativamente, para obter as ações de controle ótimas. O método de otimização adotado foi o método do gradiente (*backpropagation*).

### 5.3.4 O Controlador Preditivo Adaptativo

Uma outra estratégia de controle foi proposta, de forma a eliminar problemas de *offset* encontrados no controlador preditivo. A rede neural foi treinada *on-line* com o intuito de conseguir representar adequadamente o comportamento do processo no estado

estacionário, uma vez que o treinamento capta bem a dinâmica do processo, mas não representa de forma precisa o estado estacionário, gerando os *offsets*.

O modelo inicial é a rede treinada *off-line*. Para o treinamento *on-line* é utilizado um conjunto com dimensão a ser definida. Este padrão de treinamento vai sendo renovado a cada instante de amostragem, através do procedimento conhecido como janela móvel (BREUSEGEM et al., 1991), mantendo a sua dimensão constante. Uma ilustração do procedimento pode ser visto na Figura 5-6. No instante  $k$ , temos um padrão de treinamento composto por 5 conjuntos de amostragens (entende-se por conjunto de amostragem como os dados de entrada e saída da rede, obtidos num tempo específico). Este padrão será chamado de janela de treinamento. Como o tamanho da janela é fixo, no instante de amostragem seguinte, esta janela apenas se desloca, descartando o conjunto de amostragem mais antigo e adicionando o mais recente. Assim, a cada instante de amostragem a rede é treinada com um padrão diferente. Uma taxa de aprendizagem baixa é usada. O objetivo desse procedimento é que a atualização dos pesos se dê de forma lenta e com isso uma condição favorável à estabilidade do sistema seja mantida. O algoritmo do controlador preditivo adaptativo é apresentado na Figura 5-7.

$k$	$T_k$	$T_{k-1}$	$U_{k-1}$	$T_{k+1}$
1	0.5455	0.5494	0.4400	0.5435
2	0.5435	0.5455	0.4400	0.5431
3	0.5431	0.5435	0.4400	0.5380
4	0.5380	0.5431	0.4400	0.5344
5	0.5344	0.5380	0.8000	0.5346
6	0.5346	0.5344	0.8000	0.5350
7	0.5350	0.5346	0.8000	0.5419
8	0.5419	0.5350	0.8000	0.5494

$k$	$T_k$	$T_{k-1}$	$U_{k-1}$	$T_{k+1}$
1	0.5455	0.5494	0.4400	0.5435
2	0.5435	0.5455	0.4400	0.5431
3	0.5431	0.5435	0.4400	0.5380
4	0.5380	0.5431	0.4400	0.5344
5	0.5344	0.5380	0.8000	0.5346
6	0.5346	0.5344	0.8000	0.5350
7	0.5350	0.5346	0.8000	0.5419
8	0.5419	0.5350	0.8000	0.5494

Figura 5-6 - Definição do padrão de treinamento utilizando o procedimento da janela móvel.

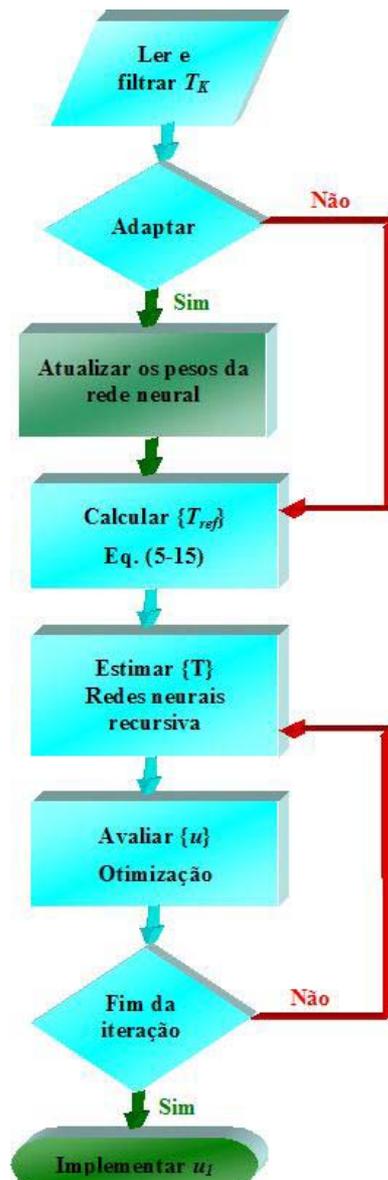


Figura 5-7 - Fluxograma do algoritmo do controlador preditivo e adaptativo.

Na próxima seção será feita uma breve descrição do código computacional, desenvolvido neste trabalho, para o sistema de controle digital.

## 5.4 O Código Computacional para o Sistema de Controle Digital

Os dois reatores utilizados neste trabalho foram controlados por meio de um *software* de controle digital desenvolvido neste trabalho. Foi adicionado o módulo

adaptativo para o segundo reator, com o intuito de, principalmente, eliminar o *offset* observado em todas as corridas conduzidas pelo controlador preditivo.

O programa desenvolvido possui um módulo para configuração do sistema de aquisição de dados, conforme pode ser visto na Figura 5-8, com especificação dos canais analógicos de leitura, a seleção da variável lida em cada canal, a unidade da variável e a curva de calibração (linear). Neste mesmo módulo é realizada a seleção dos canais de saída, definindo-se também o canal analógico de saída, a variável manipulada e a curva de calibração. Por fim, seleciona-se qual o tipo de placa utilizada.

No modo de execução do programa, pode ser definido ainda, se o sistema está em malha aberta ou malha fechada. Em malha aberta (Figura 5-9), a entrada do sistema deve ser definida manualmente, estabelecendo-se o valor da tensão elétrica na saída da placa de aquisição de dados (0 a 5 V).

Entradas Analógicas		LINEARIZAÇÃO: $y = ax + b$		Unidades	
		a	b		
<input checked="" type="checkbox"/>	Canal 0	Variáveis	197.69	-29.05	Unidades
<input type="checkbox"/>	Canal 1	Concentração			Unidades
<input type="checkbox"/>	Canal 2	Nível			Unidades
<input type="checkbox"/>	Canal 3	pH			Unidades
<input type="checkbox"/>	Canal 4	Pressão			Unidades
<input type="checkbox"/>	Canal 5	Temperatura			Unidades
<input type="checkbox"/>	Canal 6	Vazão			Unidades
<input type="checkbox"/>	Canal 7	Variáveis			Unidades

Saídas Analógicas		LINEARIZAÇÃO: $y = ax + b$		
		a	b	
<input checked="" type="checkbox"/>	Canal 0	Variáveis	1	0
<input type="checkbox"/>	Canal 1	Variáveis		

Faixa da Placa de Aquisição de Dados: [ ] Número da Placa: 0 [ ] Validar

**Figura 5-8** - Módulo de configuração da placa de aquisição de dados.

Quando operando em malha fechada, deve-se especificar qual o modo de controle a ser utilizado: Controlador PID, Controlador Preditivo ou Controlador Preditivo e Adaptativo (Figura 5-10). Para o controlador PID, deve ser especificado os valores dos seus parâmetros ( $K_C$ ,  $\tau_I$  e  $\tau_D$ ), além do *set point*.

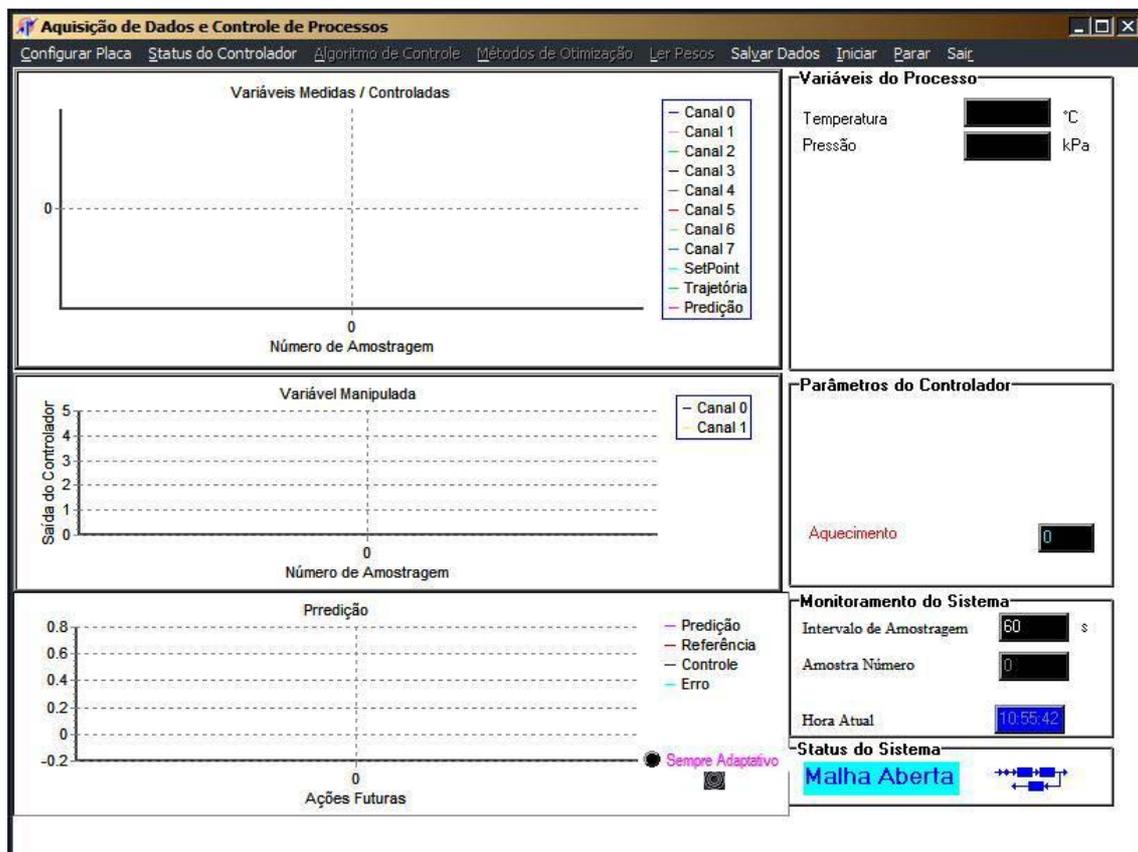
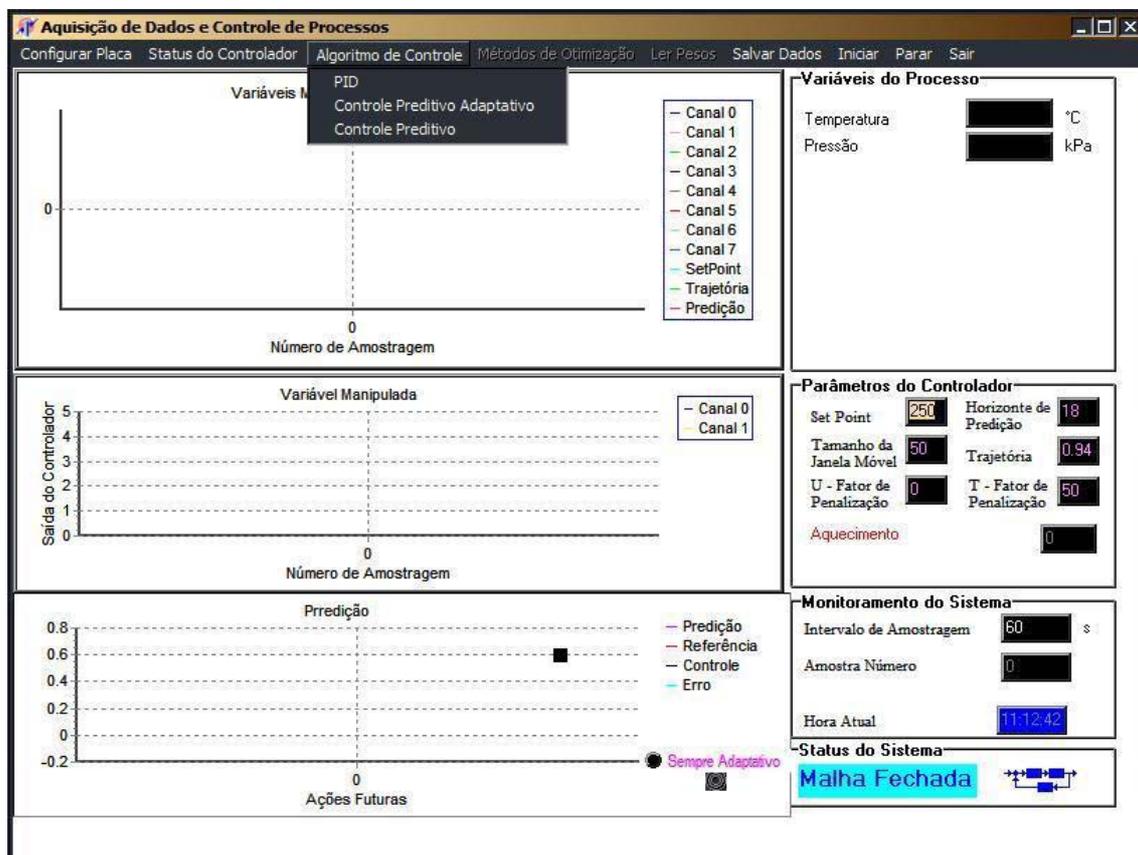


Figura 5-9 - Código computacional para o controle digital operando em malha aberta.

Outras duas opções estão disponíveis para o usuário: o controlador preditivo e o controlador preditivo adaptativo. As informações necessárias para o controlador preditivo adaptativo são aquelas que aparecem na Figura 5-10: *set point*, horizonte de predição, tamanho da janela móvel, fator de ajuste da trajetória ( $\alpha$ ), fatores de penalização para a variável manipulada e para o erro. Os mesmos parâmetros são necessários para o controlador preditivo, exceção feita ao tamanho da janela móvel. É utilizado o mesmo método de otimização, seja para o cálculo das ações de controle, seja para o treinamento

*on-line* da rede neural. Deve-se selecionar então, o método de otimização a ser utilizado, estando implementado apenas o método do gradiente. Os pesos iniciais da rede também devem ser fornecidos através de um arquivo de dados. Existe ainda, a opção de armazenar os resultados em um arquivo a ser definido pelo usuário.

A adaptação dos pesos da rede não é iniciada logo que o programa entra em execução. Deve-se esperar que seja gerado um número mínimo de dados para o padrão de treinamento. Este número deve ser, no mínimo, igual ao tamanho da janela móvel.



**Figura 5-10** - Seleção do algoritmo de controle a ser usado.

Existem duas opções no programa: colocar o controlador em modo sempre adaptativo, ou seja, uma vez atingido o número de pontos definidos para iniciar a adaptação o controlador permanece sempre em modo adaptativo. A outra alternativa é que sempre que ocorre uma alteração no *set point* o controlador retoma os pesos iniciais,

reiniciando a adaptação apenas quando um número de pontos, após a alteração do *set point*, for igual ao número de pontos definidos.

O código computacional, desenvolvido em linguagem Delphi, pode ser visto no Anexo A 2.

Os algoritmos de controle PID, preditivo e preditivo adaptativo descritos neste capítulo foram aplicados nos reatores de pirólise de resíduos industriais operando em modo semibatelada. O controlador PID serviu como parâmetro de comparação, uma vez que o mesmo é o controlador mais empregado em aplicações industriais. Utilizou-se como critério de performance, para esta comparação, o ITAE – *Integral of the Time-Weighted Absolute Value of the Error*, o mesmo critério adotado na sintonia do controlador PID. Os resultados experimentais obtidos são apresentados e discutidos no próximo capítulo. O capítulo 7 traz as principais conclusões obtidas com o desenvolvimento deste trabalho, além de apontar oportunidades para trabalhos futuros.

# Capítulo 6

## Resultados e Discussões

---

**N**este capítulo são apresentados os resultados da aplicação do algoritmo de controle preditivo e preditivo adaptativo, comparando-os com o controlador clássico. Os resultados são apresentados para os dois sistemas: a retorta e o reator de pirólise descritos no capítulo anterior. Para a retorta apenas um estudo preliminar foi realizado, uma vez que os efeitos térmicos da reação não foram perceptíveis no sistema, devido à sua pequena capacidade de processamento, associada a elevada massa do reator, dotando-o de uma grande capacidade para acúmulo de calor. Para o reator de pirólise são apresentados os resultados da identificação do sistema, caracterizando-o como um sistema de primeira ordem com tempo morto, mas com parâmetros variáveis de acordo com o ponto de operação, destacando assim a sua não linearidade. Serão apresentados alguns testes realizados para determinação dos parâmetros dos controladores do tipo retroalimentação, preditivo e preditivo adaptativo. Finaliza-se o capítulo apresentando testes comparativos dos controladores durante a pirólise de borra de tinta. O processamento foi em regime semibatelada. O controlador conduziu a temperatura do reator para dois níveis, sendo que, durante esse período a pressão do reator foi sucessivamente reduzida, através da liberação parcial dos produtos obtidos, acarretando fortes distúrbios no processo.

## 6.1 Controle da Retorta

O trabalho foi inicialmente desenvolvido em uma retorta de 0.5 L. Foi proposto um algoritmo de controle preditivo para este sistema e o controlador do tipo retroalimentação foi usado como parâmetro de comparação. Foi utilizado nestes testes um intervalo de amostragem de 10 segundos.

### 6.1.1 Controlador do Tipo Retroalimentação

O algoritmo de controle clássico do tipo retroalimentação, na sua versão digital, foi testado na retorta. Os testes realizados não apresentaram diferenças significativas para o reator com ou sem resíduo, devido à grande capacitância térmica do reator. Os resultados serão apresentados a seguir.

#### 6.1.1.1 Identificação do Sistema

A etapa de identificação do sistema é de suma importância no projeto de controladores, seja para o controle clássico, seja para algoritmos de controle avançado. Uma boa determinação do modelo do sistema permite o uso das técnicas de sintonia de controladores vistas brevemente na seção 5.3.4. A importância de um modelo que represente a dinâmica do processo com fidedignidade, quando utilizando um algoritmo de controle preditivo, já foi discutido no capítulo 4.

Uma das formas mais utilizadas para a identificação de modelos é o teste a degrau, o qual consiste em dar uma perturbação degrau conhecida no processo e verificar a resposta do mesmo. Existem diversas formas de resolver o problema de ajuste do modelo, variando de procedimentos gráficos até códigos sofisticados de regressão. Um

*software* que realiza bem a tarefa de ajuste de modelos é o *Digest*<sup>TM1</sup> (COOPER e BIESZCZAD, 1994). Este *software* pode importar arquivos ASCII contendo os dados dinâmicos. Estes dados devem estar na forma tabular com as variáveis em colunas separadas por tabulações, espaços ou vírgulas. Em seguida deve-se fazer a seleção das variáveis classificadas em tempo, variável manipulada e a variável medida. Os modelos lineares disponíveis no *Digest*<sup>TM</sup> incluem sistemas de primeira ordem, primeira ordem mais tempo morto, segunda ordem e segunda ordem mais tempo morto.

O *Digest*<sup>TM</sup> então, ajusta o ganho do processo, a(s) constante(s) de tempo e o tempo morto (se aplicável) aos dados, através da minimização do somatório do quadrado dos erros entre a saída do processo e a resposta predita pelo modelo. O *Digest*<sup>TM</sup> opera de acordo com as seguintes considerações:

1. O processo está no estado estacionário antes de ser submetido à perturbação;
2. O primeiro dado no arquivo é uma boa média do valor da variável medida no estado estacionário inicial;
3. O incremento de tempo entre os dados deve ser constante.

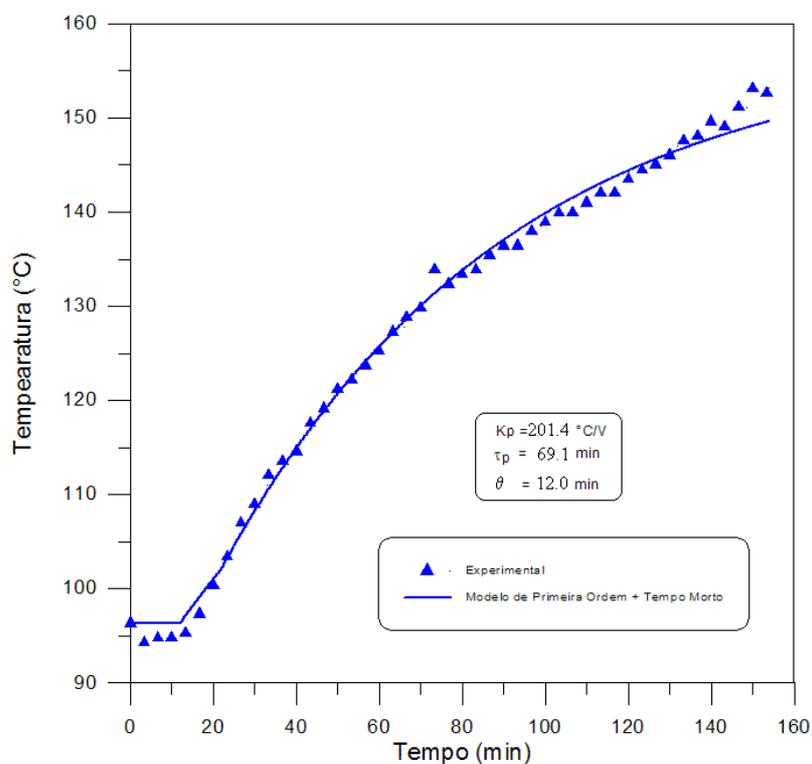
A Figura 6-1 apresenta os resultados de um teste a degrau implementado na potência de aquecimento da retorta, através da variação da tensão elétrica aplicada na sua resistência. O degrau teve uma amplitude de 0.3 V, passando inicialmente de 0.7 V para 1.0 V. A temperatura do reator é a variável de resposta. O ajuste dos parâmetros efetivado no *Digest*<sup>TM</sup>, forneceu um ganho do processo de 201.4 °C/V, uma constante de tempo de 69.1 minutos e um retardo dinâmico de 12.0 minutos. Estes resultados são apresentados na Tabela 6-1.

---

<sup>1</sup> Copyright © 1994, 1992 Douglas J. Cooper – All Rights Reserved.

### 6.1.1.2 Sintonia do Controlador

O próximo passo é usar os parâmetros do modelo dinâmico encontrados, nas correlações apresentadas na capítulo anterior, afim de obter o ajuste do controlador. O *Digest<sup>TM</sup>* contém um bom número de correlações, incluindo IMC (*Internal Model Control*), Cohen-Coon, IAE (*Integral of Absolute Error*) e o ITAE (*Integral of Time Weighted Absolute Error*). Os ajustes fornecidos para este teste a degrau foram: ganho do controlador igual a 0.08, tempo integral igual a 62.0 minutos e tempo derivativo igual a 1.2 minutos. Estes resultados são sumarizados na Tabela 6-2.



**Figura 6-1** - Validação do modelo de primeira ordem mais tempo morto para a retorta.

**Tabela 6-1** - Parâmetros do modelo do processo (primeira ordem mais tempo morto) obtidos pelo *Digest<sup>TM</sup>*.

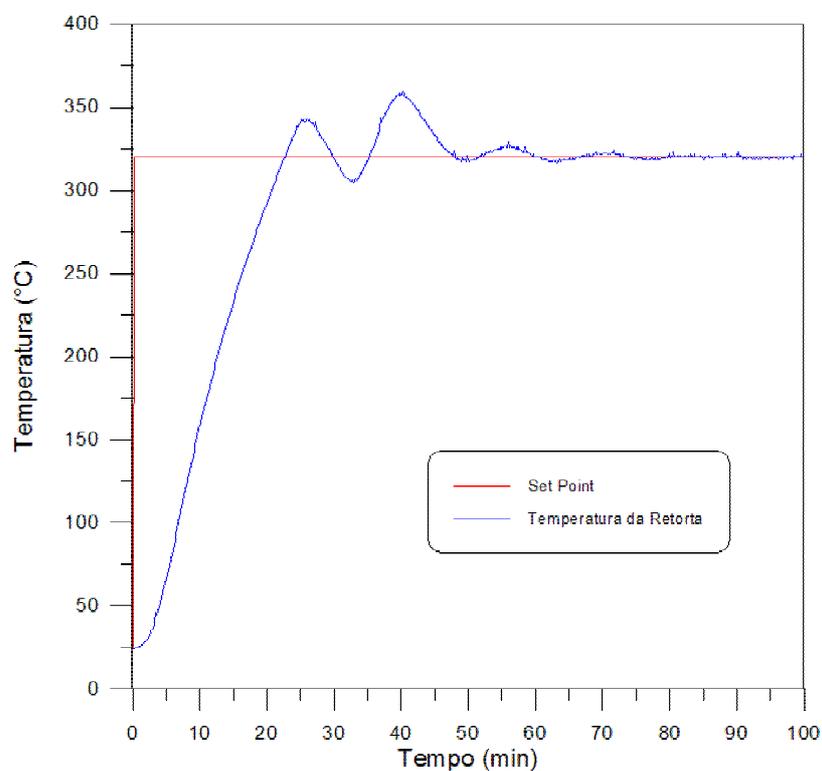
$K_p$ (°C/V)	$\tau_p$ (min)	$\theta$ (min)
201.4	69.1	12.0

**Tabela 6-2** - Parâmetros do controlador obtidos pelo método IAE (*Integral of Absolute Error*).

$K_C$	$\tau_I$ (min)	$\tau_D$ (min)
0.08	62.0	1.2

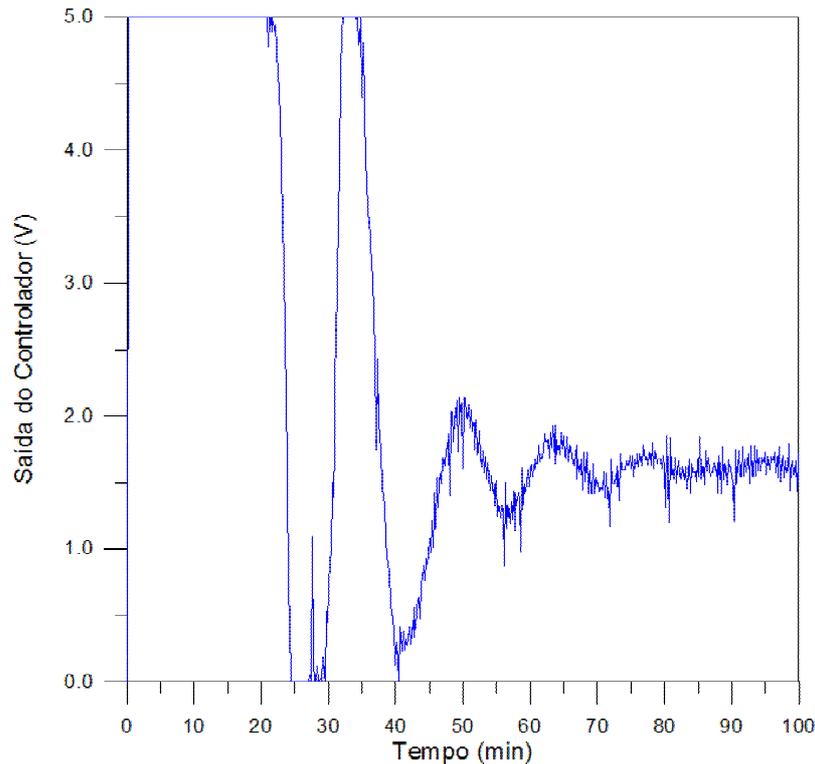
### 6.1.1.3 Teste do Controlador do Tipo Retroalimentação

Foi realizado um teste em planta, para analisar a performance do controlador do tipo retroalimentação obtido em um problema do tipo servo. A Figura 6-2 e a Figura 6-3 apresentam os resultados. A retorta, inicialmente a temperatura ambiente, deveria ter sua temperatura conduzida pelo controlador até 320°C.



**Figura 6-2** - Comportamento dinâmico do controlador do tipo retroalimentação a uma perturbação no *set point*.

Foi observado um acentuado *overshoot*, onde a temperatura atinge um máximo de 360°C, 40°C acima do *set point* (overshoot de 12.5%). Pode ser observado ainda, que o controlador não apresenta *offset*, estabilizando a temperatura no valor do *set point* em pouco mais de uma hora.



**Figura 6-3** - Esforço do controlador do tipo retroalimentação para condizir o processo de pirólise a um novo *set point*.

Com o intuito de melhorar o desempenho do controlador foi proposto o algoritmo de controle preditivo, descrito no Capítulo 5. A seção seguinte apresenta o desempenho deste algoritmo em um teste semelhante ao aplicado para o controlador do tipo retroalimentação.

### 6.1.2 Controlador Preditivo

A estratégia de controle adotada consiste em utilizar um modelo para o processo que prediga o comportamento da temperatura do reator num horizonte de controle pré-definido e obtenha uma seqüência de ações de controle que minimizem a função custo:

$$J = \delta \sum_{k=1}^{N_2} (T_{ref_k} - T_k)^2 + \lambda \sum_{k=1}^{N_u} \Delta u_k^2 \quad (6-1)$$

Com a trajetória definida por:

$$T_{ref_{k+1}} = \alpha T_{ref_k} + (1 - \alpha) T_{SP} \quad (6-2)$$

Foi adotado um modelo empírico. Uma rede neural com 3 neurônios na entrada, 5 neurônios na camada intermediária e 1 neurônio na saída foi empregado como modelo para o processo. Para que a rede atuasse de forma preditiva, a rede era recursiva, sendo a rede realimentada pela sua saída, de forma sucessiva, até que todo o horizonte de predição fosse coberto.

#### 6.1.2.1 *Treinamento da Rede Neural*

Na fase de treinamento realizou-se experimentos variando a potência de aquecimento do reator de forma que a rede pudesse captar a relação existente entre a temperatura do reator e a saída do controlador. Como foi empregado uma função sigmoideal como função de ativação, a temperatura do reator, assim como a saída do controlador, foram normalizadas entre 0.2 e 0.8. Nos treinamentos, a cada padrão apresentado, a saída da rede era alimentada recursivamente à mesma, de forma a força-la a ter um comportamento preditivo. A temperatura normalizada predita pela rede era comparada com os valores experimentais. Para cada padrão este procedimento era repetido por um número de vezes igual ao horizonte de predição, ao final do qual, um novo padrão era apresentado. Desta forma, a rede era treinada de forma a minimizar o erro entre os valores preditos e o padrão de treinamento.

#### 6.1.2.2 *Sintonia do Controlador*

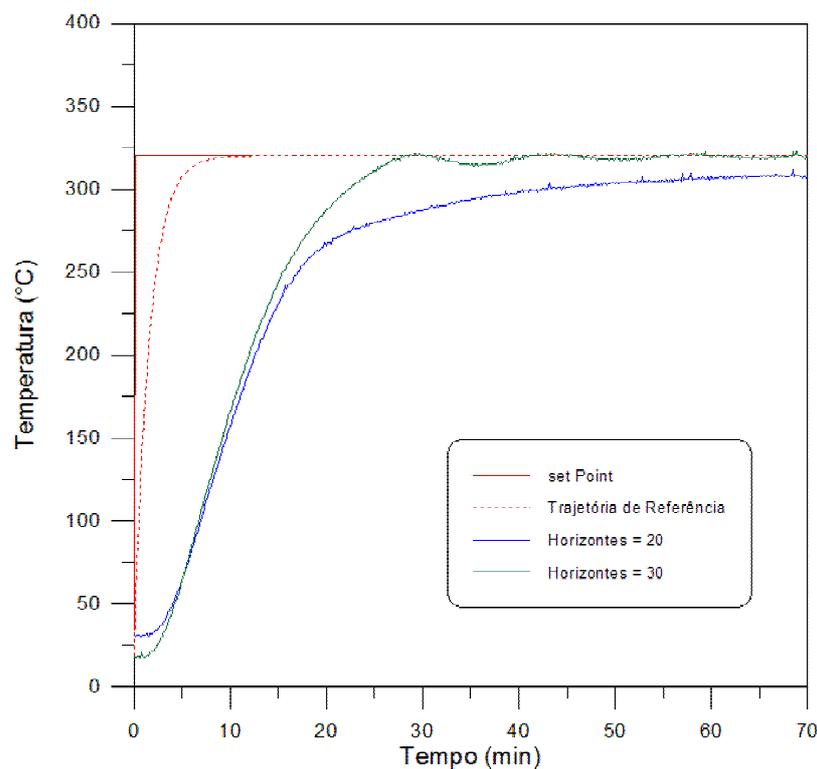
O objetivo do controlador era atingir e permanecer no *set point*, de forma rápida, estável, sem *offset* e com o menor esforço do controlador possível. Desta forma, os parâmetros de ajustes possíveis no controlador eram  $\delta$  (penalização do erro),  $\lambda$

(penalização do esforço do controlador) e  $\alpha$  (definição da trajetória de referência), além dos horizontes de predição e controle. Os parâmetros utilizados neste trabalho estão sumarizados na Tabela 6-3. O valor do horizonte de predição foi sempre igual ao do horizonte de controle. Entretanto, uma análise da sua influência na resposta do controlador foi realizada.

**Tabela 6-3** - Parâmetros do controlador preditivo.

$\delta$	$\lambda$	$\alpha$
2.5	0.1	0.9

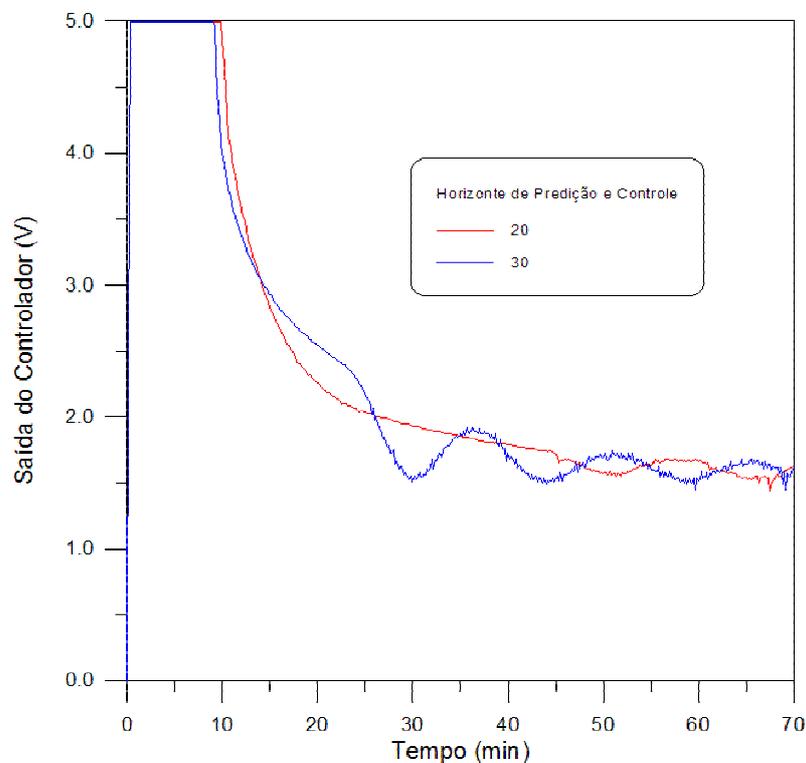
As Figuras 6-4 e 6-5 apresentam o desempenho do controlador preditivo ao conduzir o processo da temperatura ambiente até 320°C, para diferentes horizontes de predição e controle.



**Figura 6-4** - Comparação da performance do controlador preditivo para diferentes horizontes de predição e controle.

Observa-se claramente que para um horizonte de predição e controle de 30 instantes de amostragem, o sistema apresenta melhor performance, com pouco overshoot,

estável e sem offset. Para um horizonte de predição e controle igual a 20 instantes de amostragem a resposta é muito lenta, gerando um offset no processo. Foi utilizado como índice de performance, o critério adotado na sintonia do controlador do tipo retroalimentação, ou seja, a integral dos erros absolutos (IAE). Os índices relativos (razão entre o índice obtido no algoritmo de controle em questão e o índice obtido pelo controlador preditivo com horizontes de predição e controle iguais a 30) são apresentados na Tabela 6-4. Para o problema servo o controlador com horizontes iguais a 30 foi superior a todas as outras alternativas.

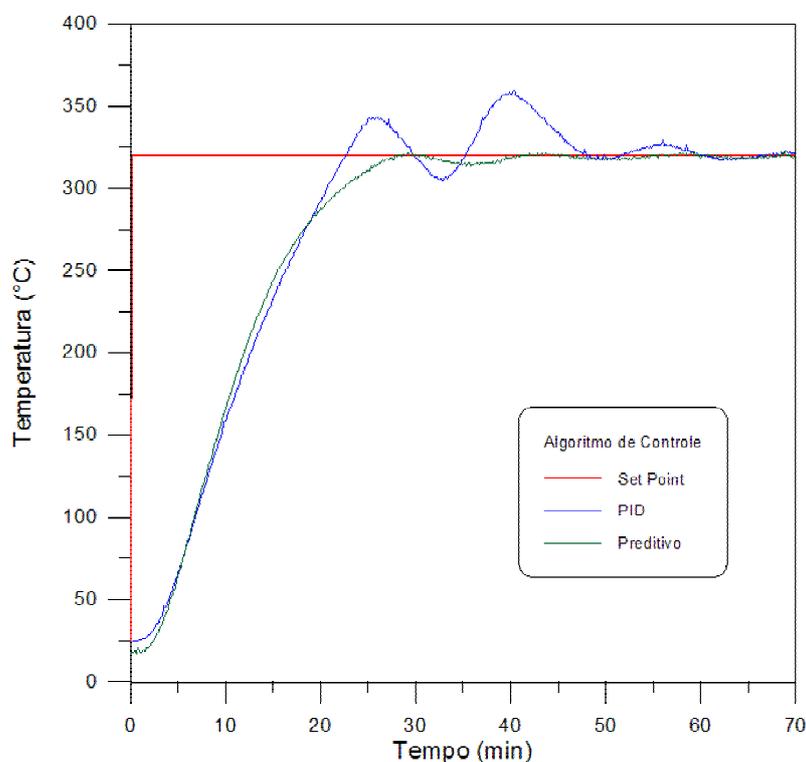


**Figura 6-5** - Esforço do controlador preditivo para diferentes horizontes de predição e controle.

### 6.1.3 Comparação Entre os Controladores

A Figura 6-6 e a Figura 6-7 apresentam uma comparação da dinâmica dos controladores a uma perturbação degrau no *set point*. Fica evidente, nestas figuras, a melhor performance do controlador preditivo, o qual apresenta *overshoot* desprezível frente aos apresentados pelo controlador do tipo retroalimentação. Além disto, o tempo

para estabilizar a temperatura no valor do *set point* também foi reduzido significativamente. A Tabela 6-4 aponta que o índice de performance do controlador do tipo retroalimentação é 10 % maior do que o do controlador preditivo, com horizontes de predição e controle iguais a 30, quantificando assim a superioridade deste último.

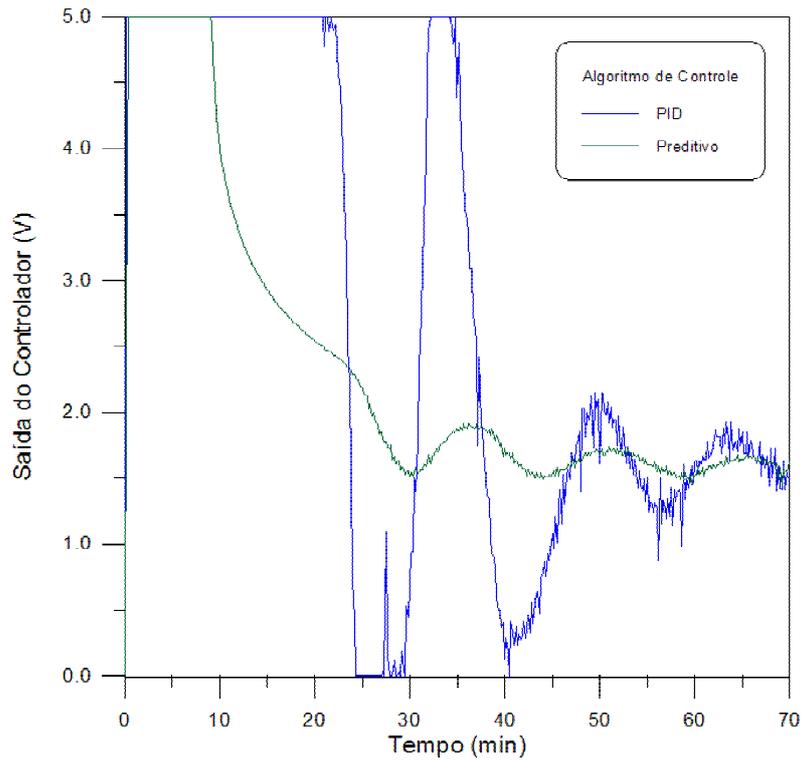


**Figura 6-6** - Comparação entre o algoritmo de controle do tipo retroalimentação e o Controlador preditivo com horizontes de controle e predição iguais a 30.

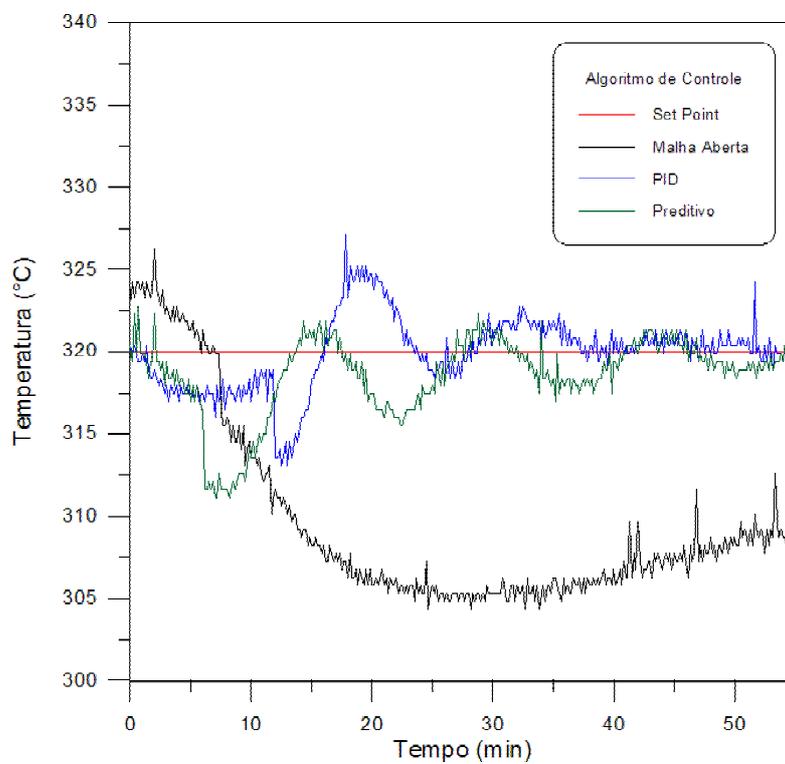
**Tabela 6-4** - Comparação entre os critérios de desempenho relativos para os algoritmos de controle.

Critério de Desempenho	IAE	
	Problema Servo	Problema Regulador
Algoritmo de Controle Retroalimentação	1.10	0.86
Preditivo (horizontes iguais 20)	1.31	8.06
Preditivo (horizontes iguais 30)	1.00	1.00

Um outro teste foi implementado, agora através de um problema regulador. O processo foi submetido a uma perturbação que consistiu em, durante 10 minutos, submeter a retorta a uma jato de ar comprimido. A Figura 6-8 e a Figura 6-9 apresentam uma comparação entre as estratégias de controle utilizadas. Com o intuito de qualificar o efeito do distúrbio é apresentada também a resposta do processo em malha aberta.

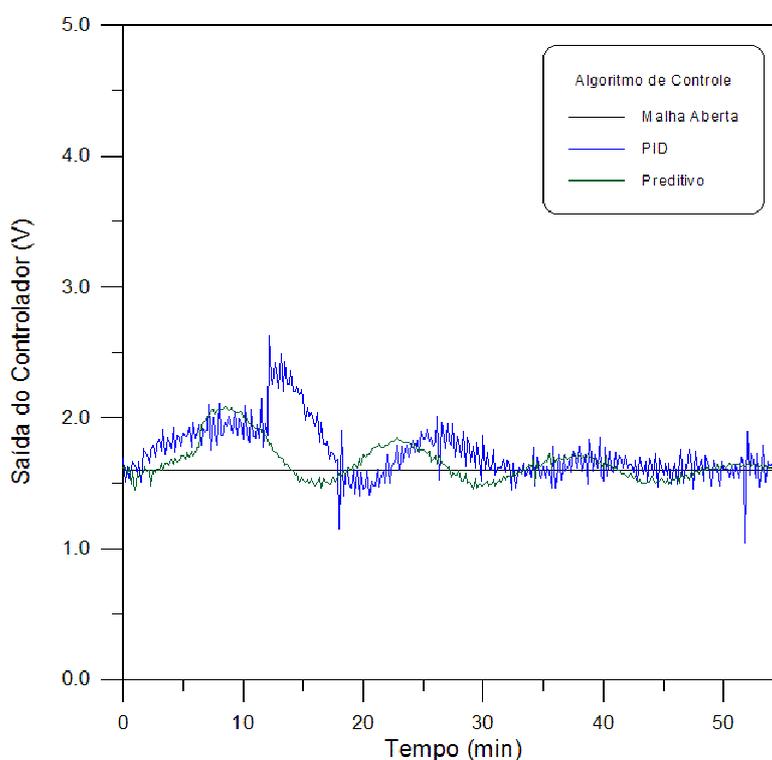


**Figura 6-7** - Comparação do esforço dos controladores do tipo retroalimentação e preditivo para conduzir a temperatura do reator da temperatura ambiente até 320°C.



**Figura 6-8** - Comparação da performance dos algoritmos de controle, quando o processo é submetido a uma perturbação.

Observa-se, mais uma vez, o bom desempenho do controlador preditivo com horizontes iguais a 30. O sistema de controle conseguiu minimizar os efeitos do distúrbio, os quais foram prontamente eliminados. Entretanto, está não é uma particularidade do controlador preditivo uma vez que o controlador do tipo retroalimentação também apresentou, sob o ponto de vista qualitativo, uma performance semelhante. A Tabela 6-4 compara os índices de performance relativos, apontando uma pequena superioridade do controlador do tipo retroalimentação.



**Figura 6-9** - Esforço de diferentes controladores para suprimir o efeito de distúrbios no processo.

Entretanto, a análise do desempenho dos controladores ficou prejudicada em função dos ruídos na variável medida e da ausência de efeitos térmicos devidos à reação de pirólise. Um reator com dimensões ampliadas foi implementado com o objetivo de amplificar este último efeito e algumas correções foram adotadas para reduzir o ruído, conforme será apresentado na próxima seção.

## 6.2 Controle do Reator de Pirólise

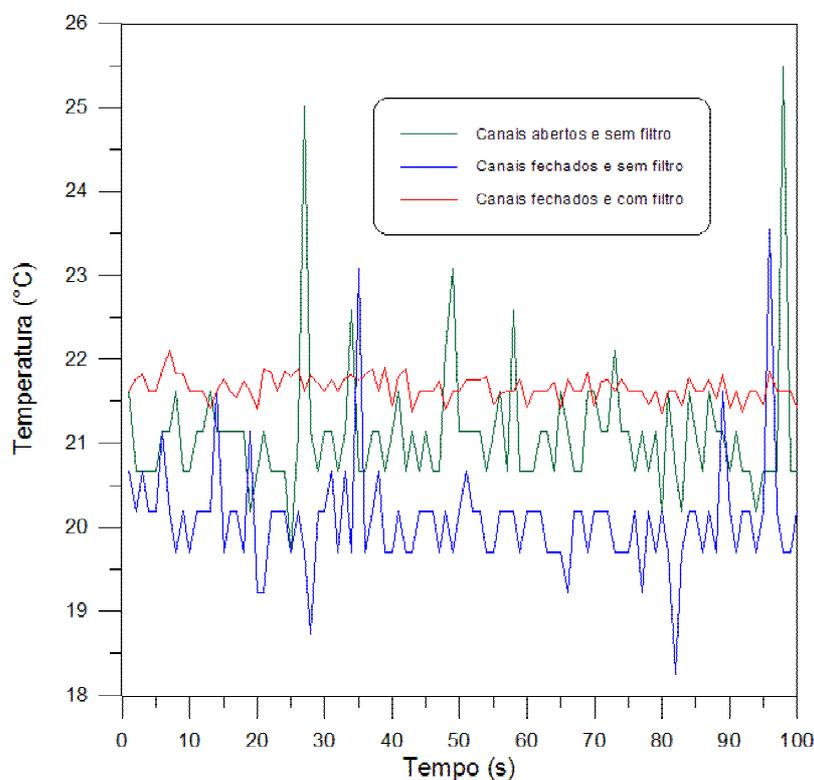
Um novo sistema foi desenvolvido, conforme apresentado no Capítulo 5. Um reator de 8 L foi utilizado. Nesta etapa do trabalho, foi desenvolvido um controlador preditivo e adaptativo e o controlador do tipo retroalimentação foi adotado como parâmetro de comparação para a performance do controlador proposto. Foram utilizados nesses testes, intervalos de amostragens de 60 segundos.

### 6.2.1 Redução dos Ruídos

A eliminação de ruídos é importante, tanto no processo de identificação do sistema como na análise do desempenho dos controladores. O fabricante da placa de aquisição de dados utilizada sugere que os canais de leitura analógica não utilizados estejam aterrados. A Figura 6-10 apresenta a diferença de comportamento na leitura da temperatura do reator para três configurações distintas: os canais abertos e sem filtro para a temperatura lida, os canais aterrados e sem filtro para a temperatura e os canais aterrados e com filtro. Foi utilizado como filtro a média móvel, cuja descrição pode ser encontrada em diversos livros de controle de processos (SEBORG et al., 1989). A leitura foi realizada no reator a temperatura ambiente.

Observa-se pelo gráfico que a medida da temperatura apresenta ruídos muito fortes. É bem verdade que o ganho do condicionador de sinal utilizado é muito pequeno ( $0.00714 \text{ V/}^\circ\text{C}$ ), haja visto que a faixa de leitura de temperatura é muito grande. A faixa de temperatura na entrada do condicionador de sinal varia de 0 a  $700^\circ\text{C}$ . O sinal de saída da mesma varia de 0 a 5V. Assim, o valor da temperatura medida é muito sensível ao sinal de entrada da placa, conforme indicado pelo ganho do condicionador, ou seja, uma variação de  $0.00714 \text{ V}$  corresponde a uma variação de  $1^\circ\text{C}$  na temperatura lida. Fica evidente, que o comportamento apresentado na Figura 6-10 para os canais aterrados e

com filtro tem um ótimo desempenho frente às restrições impostas. Vale ressaltar que a faixa para a leitura da temperatura não poderia ser outra em face da grande variabilidade das condições operacionais.



**Figura 6-10** - Análise dos efeitos do curto-circuito nos canais analógicos de leitura não utilizados e do filtro sobre os ruídos, na leitura da temperatura do reator.

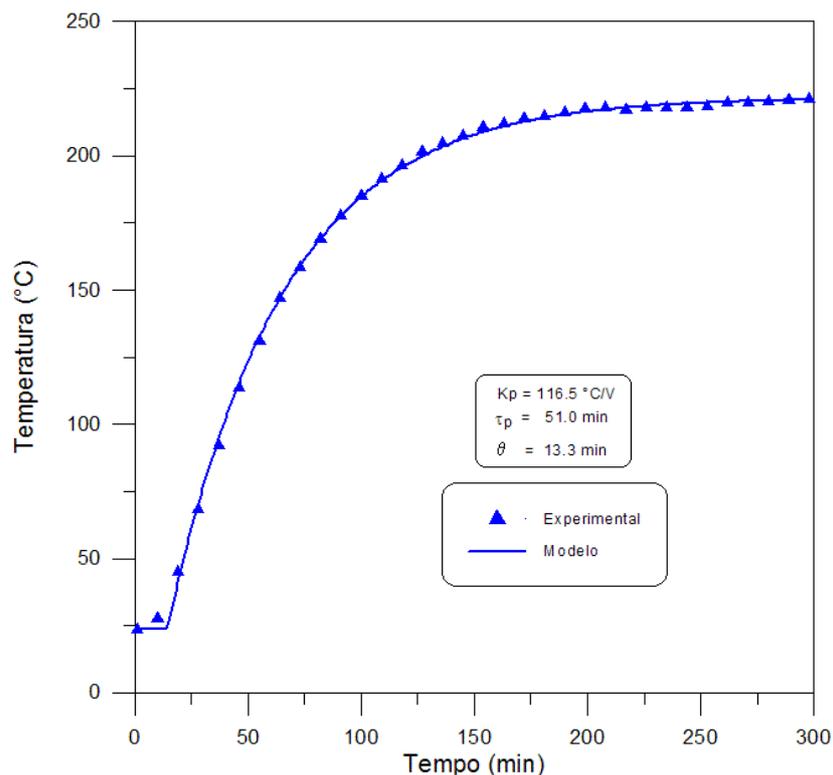
Ao trabalhar com os canais não utilizados sem terra e sem filtro para a temperatura lida, a temperatura apresentou uma variação de  $6^{\circ}\text{C}$  entre o máximo e o mínimo valor lido, no intervalo de tempo considerado. Com a colocação do aterramento dos canais não utilizados, observa-se uma diminuição discreta da variabilidade de leitura e a temperatura passa a oscilar com uma variação de  $5.3^{\circ}\text{C}$ . Entretanto, com a adição do filtro para a temperatura houve uma significativa redução do ruído, limitando sua variação a  $0.8^{\circ}\text{C}$ . Obviamente esta última foi a configuração adotada no trabalho.

## 6.2.2 Identificação do Sistema

A etapa de identificação do sistema foi iniciada através de testes a degrau. Com o sistema inicialmente em um estado estacionário, perturbou-se o sistema através de uma variação degrau no sinal de saída da placa de aquisição de dados, utilizado para o aquecimento do reator.

Entretanto, foram realizados quatro testes para comprovar a não linearidade do processo. Observa-se a variação de todos os parâmetros em função do ponto de operação, incluindo o tempo morto. O primeiro teste pode ser visto na Figura 6-11. O reator, inicialmente à temperatura ambiente, sofre uma perturbação na variável manipulada, alterando-se a tensão de saída da placa de aquisição de dados de 0 para 1.7 V.

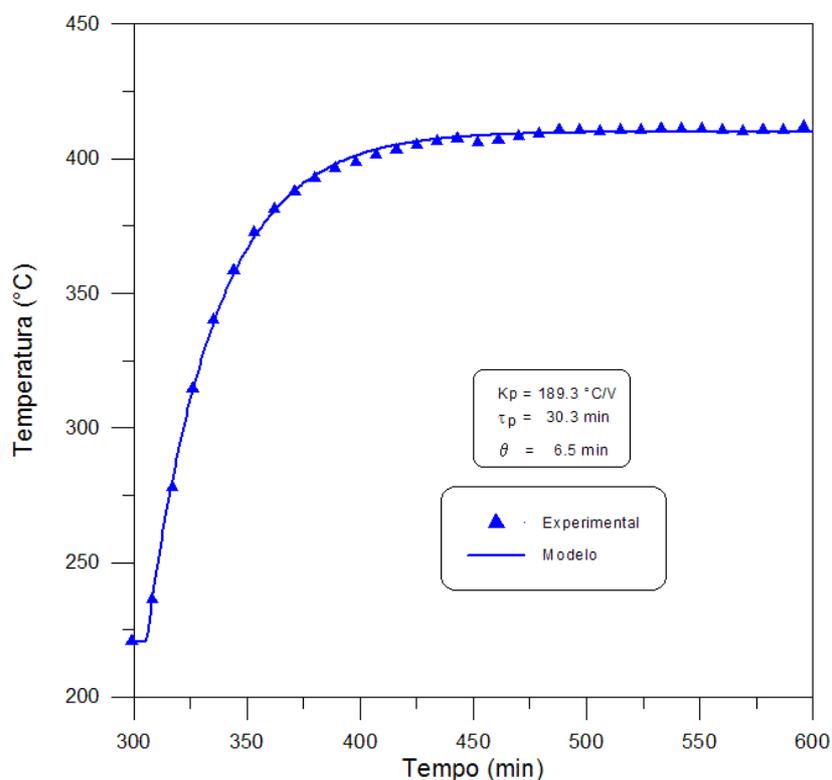
Mais outros três degraus foram efetuados no reator de pirólise, com o objetivo de verificar as alterações na dinâmica do processo, para pontos de operação e até mesmo caminhos diferentes (aquecimento ou resfriamento). Com o processo no estado estacionário e uma tensão na saída do controlador igual a 1.7 V, perturbou-se o sistema, alternado este sinal de 1.7 V para 2.7 V. Os resultados são vistos na Figura 6-12. O ajuste destes dados a um modelo de primeira ordem mais tempo morto resultou num ganho do processo de 189.3 °C/V, uma constante de tempo de 30.3 minutos e um tempo morto de 6.5 minutos. Fica evidente a não linearidade do processo. O ganho resultante é mais que 60% maior que o obtido no ajuste anterior, apresentado na Figura 6-11. A constante de tempo sofre uma redução da mesma ordem, sendo o tempo morto reduzido para menos da metade.



**Figura 6-11** - Comparação dos resultados obtidos com o teste a degrau no reator de pirólise com o modelo de primeira ordem mais tempo morto. Os parâmetros obtidos foram  $K_p = 116.5 \frac{^\circ\text{C}}{\text{V}}$ ,  $\tau_p = 51.0 \text{ min}$  e  $\theta = 13.3 \text{ min}$

Um terceiro degrau, modificando a saída do controlador de 2.7 para 1.7 V foi realizado. O objetivo deste ensaio era verificar as alterações na dinâmica do sistema devido à rota ao qual o processo é conduzido. Nota-se que o processo realiza o sentido inverso daquele apresentado na Figura 6-12. Como o resfriamento do processo é através de convecção livre, em um reator semi isolado, o esperado era que a dinâmica desta rota fosse mais lenta do que a de aquecimento, o que foi comprovado comparando os resultados da Figura 6-12 e da Figura 6-13. O ganho não é alterado, havendo um pequeno acréscimo na constante de tempo, passando de 30.3 minutos na etapa de aquecimento para 40.4 minutos no resfriamento. O parâmetro mais sensível é o tempo morto, que foi reduzido para praticamente a metade. Isto torna-se mais gritante quando faz-se uma

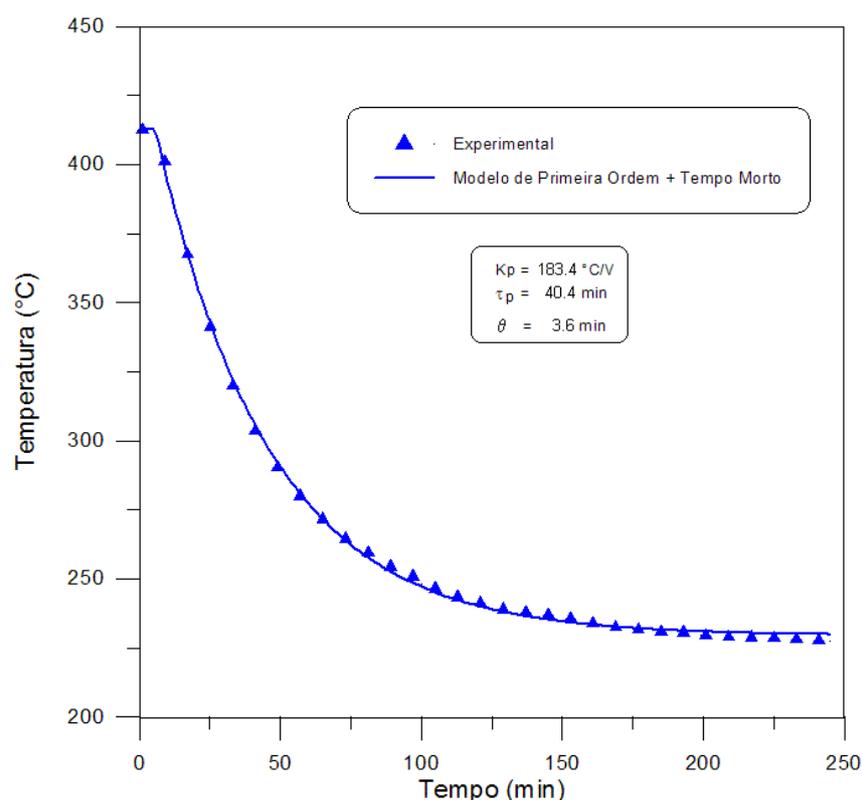
comparação e do aquecimento de 0 para 1.7 V (Figura 6-11) com o resfriamento. O tempo morto desta última rota é praticamente a quarta parte do primeiro teste.



**Figura 6-12** - Comparação dos resultados obtidos com o teste a degrau no reator de pirólise com o modelo de primeira ordem mais tempo morto. Os parâmetros obtidos foram  $K_p = 189.3 \frac{^\circ\text{C}}{\text{V}}$ ,  $\tau_p = 30.3 \text{ min}$  e  $\theta = 6.5 \text{ min}$ .

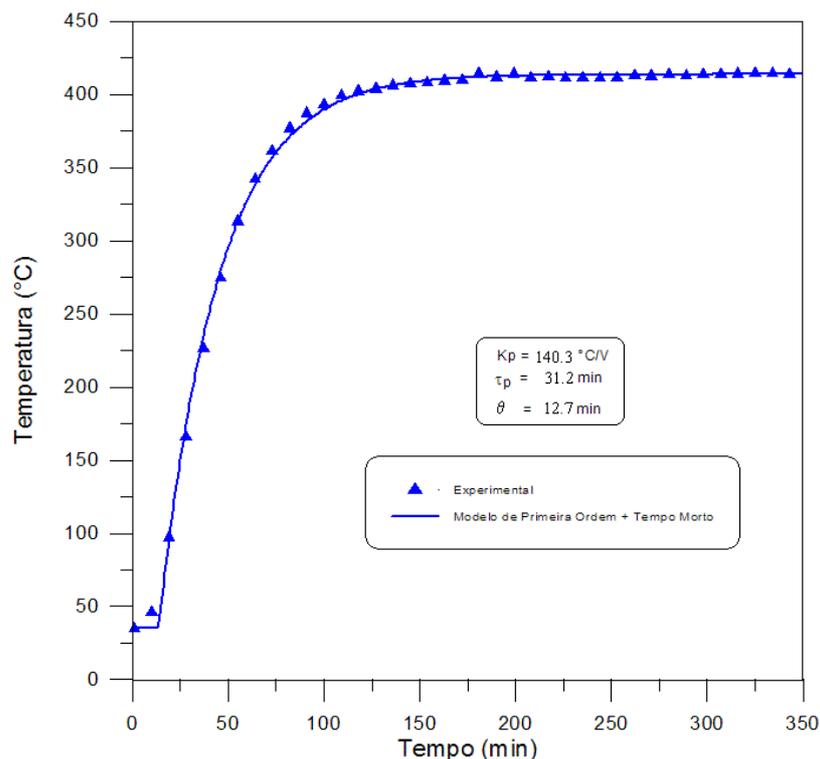
Um último ensaio foi realizado com o intuito de verificar a dinâmica do processo em todo o intervalo, ou seja, da temperatura ambiente até algo em torno de 400°C. Para isto, o processo foi submetido a uma perturbação degrau na saída do controlador, alterando-a de 0 para 2.7 V. Conforme pode ser visto na Figura 6-14, o ganho do controlador ficou em 140.3 °C/V, um valor intermediário, quando comparado com os degraus de 0 a 1.7 V e de 1.7 a 2.7 V. A constante de tempo do processo (31.2 minutos) parece estar fortemente relacionada com a tensão final, a qual o processo é submetido, pois apresenta praticamente o mesmo valor do que o obtido no teste em que a perturbação degrau modificou a tensão de 1.7 para 2.7 V. O tempo morto encontrado foi 12.7

minutos, praticamente o mesmo que o obtido no primeiro ensaio, quando aquecendo o reator da temperatura ambiente através de um degrau de 1.7 V na tensão de saída do controlador. O que se pode concluir é que o tempo morto obtido no modelo é na verdade uma aproximação de vários sistemas em série. Como na partida todo o sistema tem que ser aquecido (resistência, lã de rocha, paredes do reator, etc.) o retardo dinâmico fica mais acentuado, resultando num tempo morto aproximado também maior.



**Figura 6-13** - Comparação dos resultados obtidos com o teste a degrau no reator de pirólise com o modelo de primeira ordem mais tempo morto. Os parâmetros obtidos foram  $K_p = 183.4 \frac{^\circ\text{C}}{\text{V}}$ ,  $\tau_p = 40.4 \text{ min}$  e  $\theta = 3.6 \text{ min}$ .

Um resumo dos parâmetros ajustados para os testes efetuados podem ser vistos na Tabela 6-5. Como foi visto, a função de transferência muda em função do ponto de operação, assim como devido a rota do processo. Isto irá afetar diretamente a sintonia do controlador do tipo retroalimentação, haja visto que a mesma depende dos parâmetros do modelo adotado. Este assunto será discutido no próximo tópico.



**Figura 6-14** - Comparação dos resultados obtidos com o teste a degrau no reator de pirólise com o modelo de primeira ordem mais tempo morto. Os parâmetros obtidos foram  $K_p = 140.3 \frac{^{\circ}\text{C}}{\text{V}}$ ,  $\tau_p = 31.2 \text{ min}$  e  $\theta = 12.7 \text{ min}$ .

**Tabela 6-5** - Compilação dos parâmetros do modelo de primeira ordem mais tempo morto para os diversos testes a degrau implementados.

Faixa de Temperatura (°C)	Degrâu (V)	$K_p$ (°C/V)	$\tau_p$ (min)	$\theta$ (min.)
25 – 225	0.0 – 1.7	116.5	51.0	13.3
225 – 400	1.7 – 2.7	189.3	30.3	6.5
225 – 400	2.7 – 1.7	183.4	40.4	3.6
25 – 400	0.0 – 2.7	140.3	31.2	12.7

### 6.2.3 Ajuste do Controlador do Tipo Retroalimentação

O controlador do tipo retroalimentação é sem dúvida o algoritmo de controle mais utilizado nos processos químicos industriais, por sua versatilidade e facilidade de implementação e ajuste, além de existir uma sólida teoria disponível sobre o mesmo. Pode ser encontrado comercialmente em versões analógicas. Só é justificável a sua

substituição por algoritmos de controle avançado, quando a performance do controlador do tipo retroalimentação não é adequada. Por isso, o controlador do tipo retroalimentação é empregado aqui como um comparativo para a performance do algoritmo proposto.

Neste trabalho optou-se por ajustar o controlador do tipo retroalimentação pelo método ITAE (*Integral of the Time-Weighted Absolute Value of the Error*), uma vez que o mesmo é apontado como um dos mais indicados para o propósito. As equações usadas para a sintonia do controlador PID, quando o processo é submetido a mudanças no *set point* estão na Tabela 5.1.

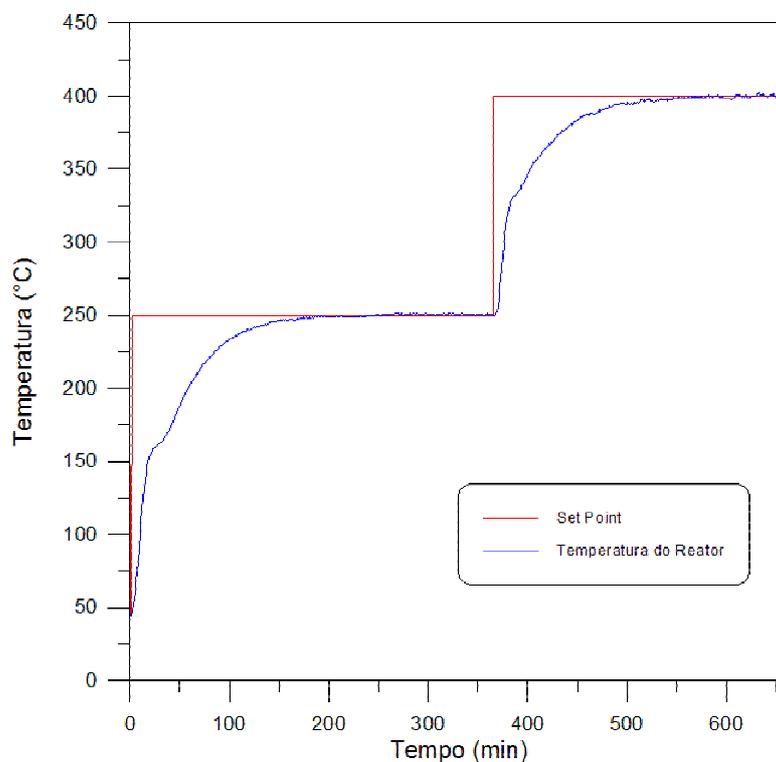
A Tabela 6-6 traz os parâmetros do controlador PID para os diversos modelos apresentados na seção anterior. Observa-se uma grande variação dos parâmetros do controlador. O ganho varia de 0.15 a 0.42, sendo o último portanto, praticamente três vezes maior que o primeiro. O tempo integral também apresenta variações significativas, passando por valores que vão de 39.64 até 67.31, um acréscimo de cerca de 70%. Já a constante de tempo derivativo tem uma faixa que vai de 1.32 a 4.51, ou seja, um acréscimo por um fator maior do que três. Optou-se pelo o controlador com os parâmetros que estão na faixa da temperatura ambiente até 400°C, uma vez que os parâmetros do modelo são os valores intermédio para os diferentes testes.

O primeiro teste foi realizado dando partida ao processo à temperatura ambiente e submetendo-o a um problema servo. Assim, o *set point* é alterado, na forma de uma função degrau, inicialmente para 250°C. Após a estabilização da temperatura no valor do *set point* promove-se uma nova perturbação para 400°C e aguarda-se até que o processo estabilize novamente. Os parâmetros usados para controlador PID foram

$K_c = 0.015 \frac{V}{^\circ C}$ ,  $\tau_I = 42.26$  min e  $\tau_D = 4.17$  min. O parâmetro  $\eta$  utilizado no filtro da ação derivativa (equação 5-1) foi igual a 0.9. Os resultados estão plotados na Figura 6-15 e Figura 6-16.

**Tabela 6-6** - Sintonia do controlador PID pelo método ITAE para perturbações no *set point*. Cálculos efetuados para os diversos modelos da seção anterior.

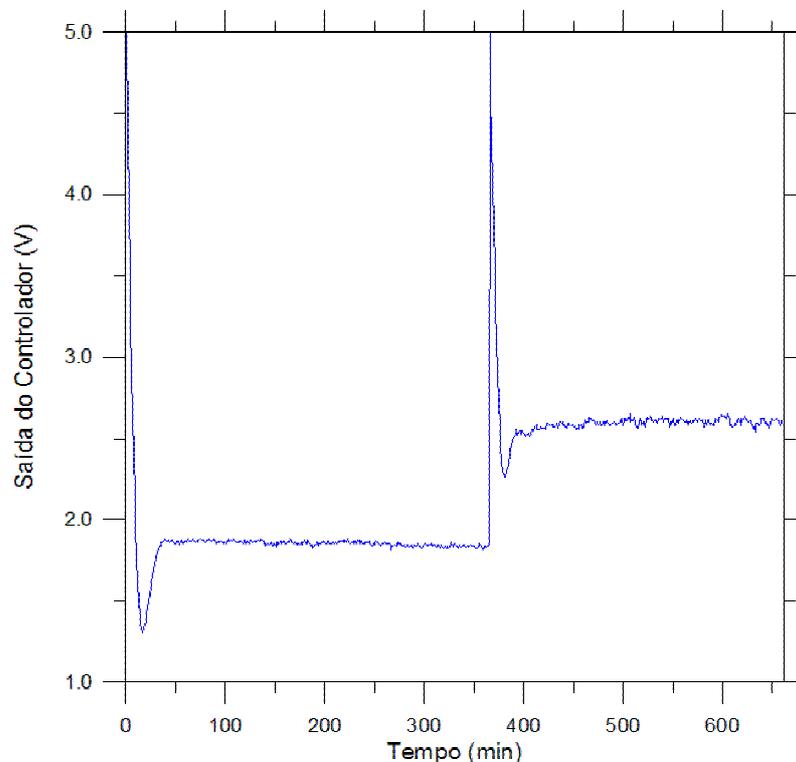
Faixa de Temperatura (°C)	Processo			Controlador PID		
	$K_p$ (°C/V)	$\tau_p$ (min)	$\theta$ (min)	$K_C$ (V/°C)	$\tau_I$ (min)	$\tau_D$ (min)
25 – 225	116.5	51.0	13.3	0.026	67.31	4.51
225 – 400	189.3	30.3	6.5	0.019	39.64	2.23
400 – 225	183.4	40.4	3.6	0.042	51.60	1.32
<b>25 – 400</b>	<b>140.3</b>	<b>31.2</b>	<b>12.7</b>	<b>0.015</b>	<b>42.26</b>	<b>4.17</b>



**Figura 6-15** - Resultado de um sistema servo com controlador PID.  $K_C = 0.015 \frac{V}{^\circ C}$ ,  $\tau_I = 42.26$  min,  $\tau_D = 4.17$  min e  $\alpha = 0.9$ .

Apesar da boa estabilidade apresentada pelo controlador PID, a sua ação foi extremamente conservativa e com isto a resposta do processo foi muito lenta, levando um tempo excessivo para atingir o valor do *set point*, em ambas as perturbações (da temperatura ambiente até 250°C e de 250°C para 400°C). O tempo para atingir o *set*

point inicial (um degrau de 225°C) foi de cerca de 200 minutos, aproximadamente o mesmo valor obtido para o degrau seguinte, com amplitude de 150°C.



**Figura 6-16** - Esforço do controlador PID para conduzir o processo da temperatura ambiente até 250°C e em seguida, até 400°C.

A presença do filtro na ação derivativa é um fator importante na performance do controlador PID. Um teste para comprovar sua influência na ação do controlador PID também foi implementado. Utilizou-se o mesmo controlador do teste anterior, isto é, com

$$K_C = 0.015 \frac{V}{^\circ C}, \tau_I = 42.26 \text{ min e } \tau_D = 4.17 \text{ min, porém com o valor de } \eta \text{ igual a } 0.1.$$

Como pode ser visto na Figura 6-17 ao reduzir a ação do filtro na ação derivativa ( $\alpha$  igual a 0.1) o controlador apresentou um comportamento muito inferior ao controlador com um filtro com ação mais acentuada ( $\alpha$  igual a 0.9). Para o controlador com menor filtro é possível observar um *kickback* nas duas perturbações, sendo que no degrau em que o set point passa de 250°C para 400°C este fenômeno foi mais acentuado.

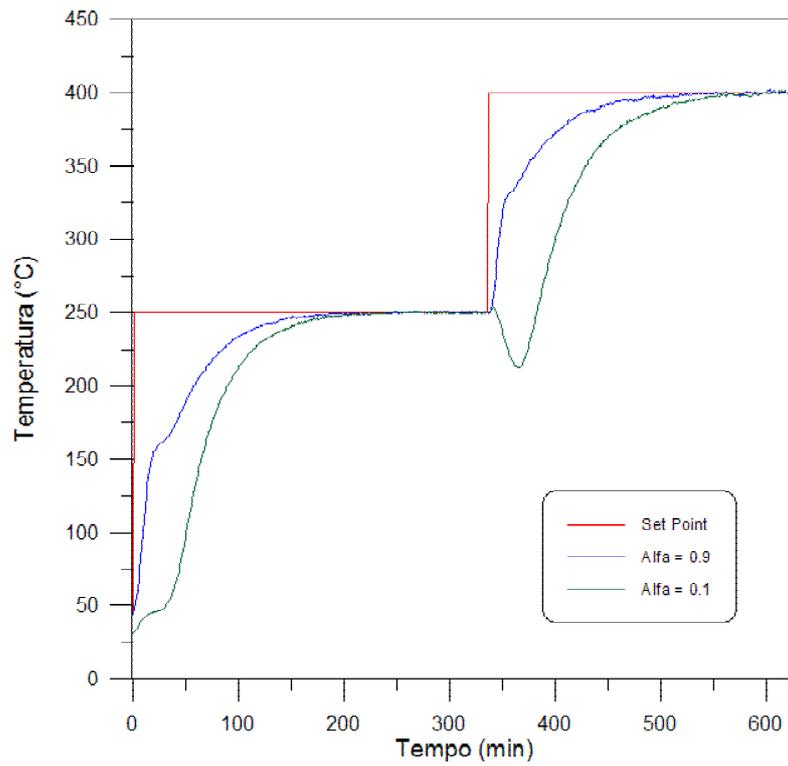


Figura 6-17 - Comparação da performance do controlador PID para diferentes filtros na ação derivativa.

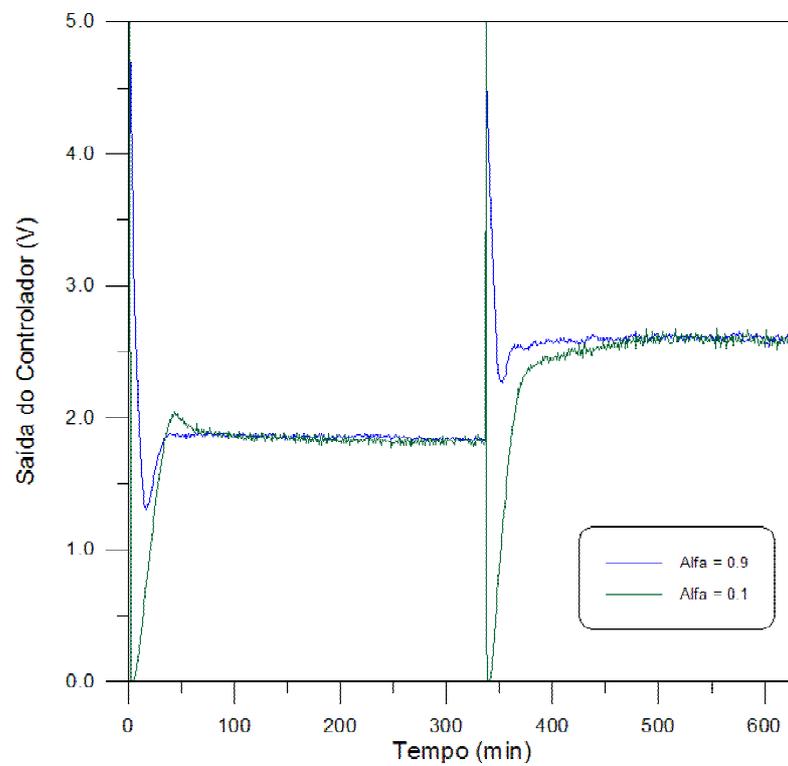
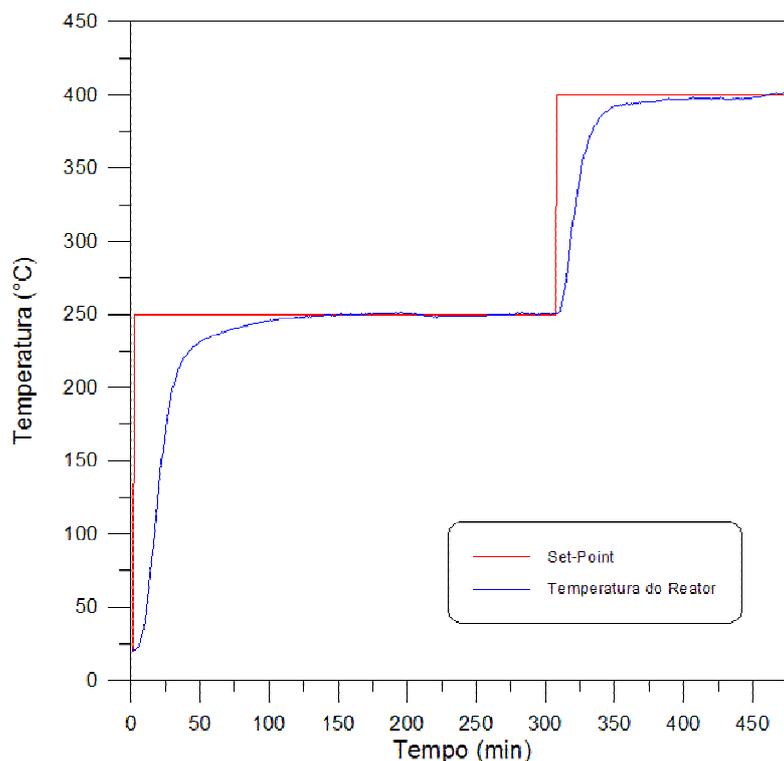


Figura 6-18 - Esforço do controlador PID para diferentes filtros na ação derivativa.

A literatura sugere valores para a constante de tempo do filtro entre 0.20 e 0.05. Nos testes implementados, o melhor valor obtido ficou em 0.90, um valor bem acima do limite sugerido.

Devido à ação extremamente conservativa do controlador PID, optou-se por avaliar a performance de um controlador PI frente as mesmas perturbações que incidiram sobre o controlador PID. De acordo com as técnicas de projeto de controladores clássicos apresentadas no Capítulo 5 os parâmetros do controlador PI para o sistema em questão são  $K_c = 0.010$  e  $\tau_I = 32.40$  min. Os testes realizados são apresentados na Figura 6-19 e Figura 6-20.

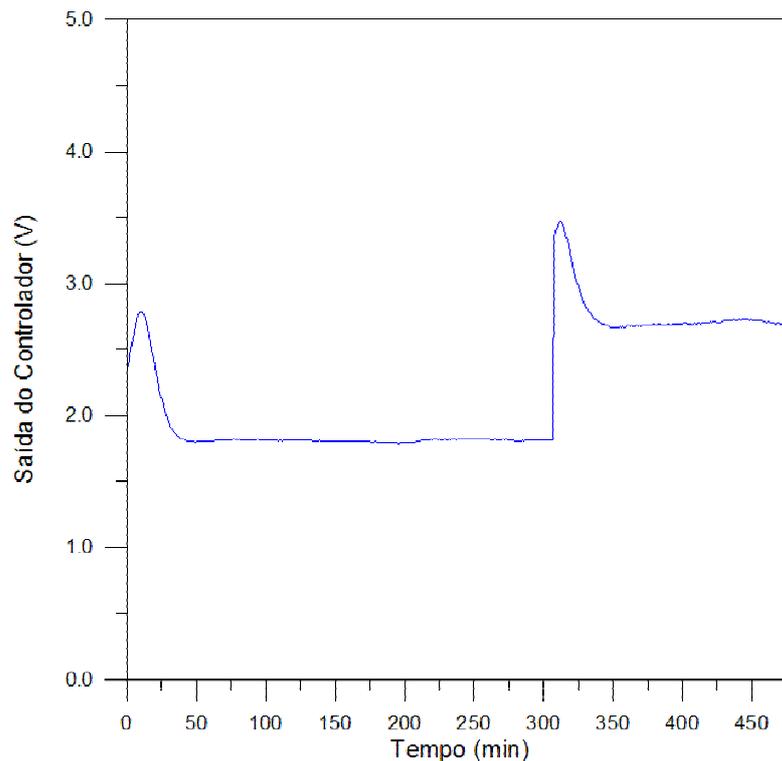


**Figura 6-19** - Comportamento da temperatura do reator à perturbações degrau no *set point*, para um controlador PI.

Observa-se claramente que o controlador PI mostrou uma resposta dinâmica superior ao controlador PID na tentativa de fazer com o processo passe da sua condição inicial (temperatura ambiente) para 250°C e ali permaneça, sendo submetido em seguida a

uma nova alteração do *set point* (Figura 6-21 e Figura 6-22). Para que a análise da performance fique evidenciada de forma quantitativa, foi adotado o índice de performance ITAE, o mesmo empregado no cálculo dos parâmetros do controlador.

$$I = \int_0^t t|e(t)|dt \quad (6-3)$$



**Figura 6-20** - Esforço do controlador PI para conduzir o processo da temperatura ambiente até 250°C e em seguida, até 400°C.

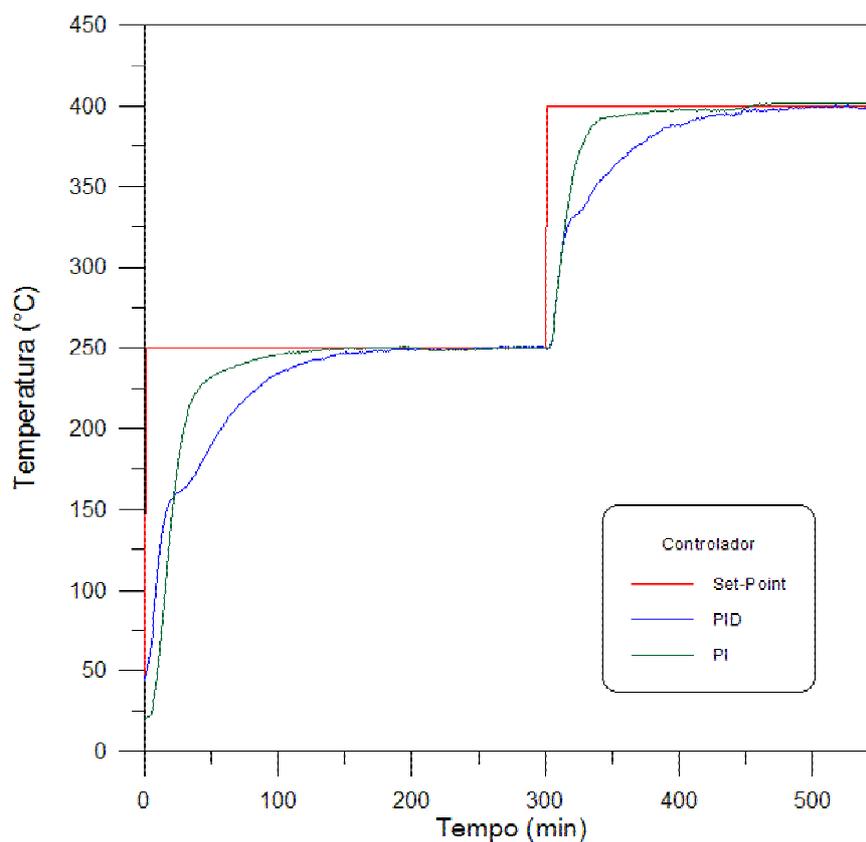
O índice de performance foi normalizado em função do valor obtido para o controlador PI, de forma a que os valores apresentados indiquem a relação entre as performances. A Tabela 6-7 confronta os valores obtidos pelo controlador PI e o PID, para as alterações no *set point* da temperatura ambiente para 250°C e de 250°C para 400°C. Fica evidente a superioridade do controlador PI frente ao PID, este último atingindo um índice de performance superior a duas vezes o índice do controlador PI.

**Tabela 6-7** - Índices de performance ITAE relativos entre os controladores PI e PID no controle da temperatura de um reator de pirólise.

<i>Set Point</i>	250°C	400°C
Controlador PI	1.00	1.00
Controlador PID	2.24	2.40

Diante destes resultados, o controlador PI, com  $K_c = 0.010$  e  $\tau_I = 32.40$  min, foi adotado como controlador a ser utilizado para efeito de comparação com os algoritmos propostos.

A seguir é apresentado os resultados obtidos para o ajuste do controlador preditivo e os motivos que justificam o uso de uma estratégia adaptativa.



**Figura 6-21** - Comparação da dinâmica do processo ao ser conduzido para diferentes *set points* por controladores PI e PID.

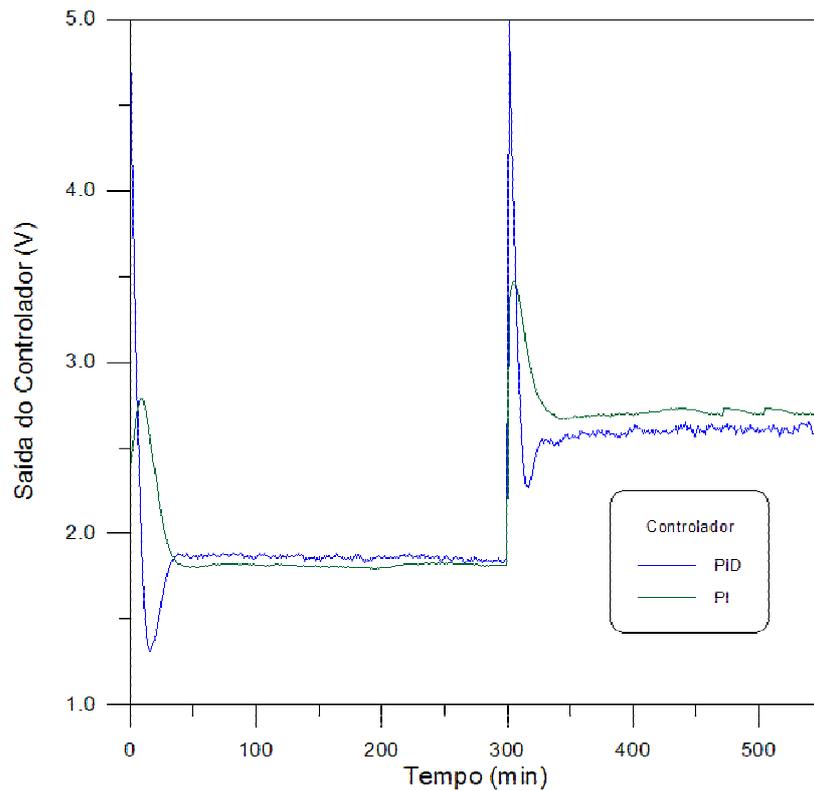


Figura 6-22 - Esforço dos controladores PI e PID frente a problemas servo.

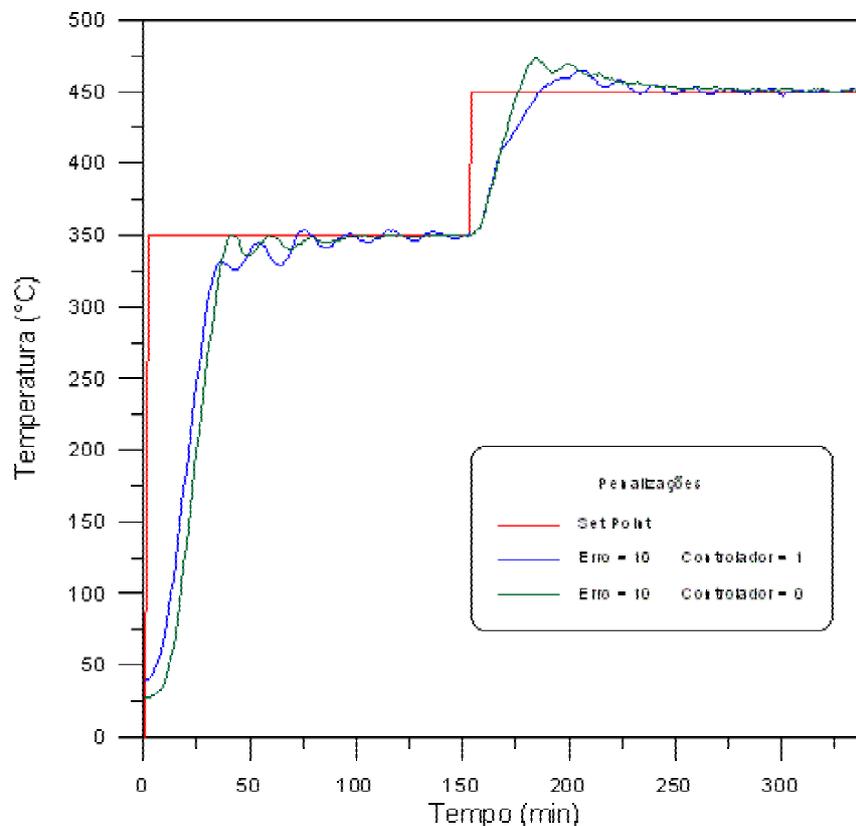
### 6.3 Ajuste do Controlador Preditivo

De acordo com o algoritmo do controlador preditivo apresentado no capítulo 5, os graus de liberdade presentes neste controlador são  $\delta$ ,  $\lambda$ ,  $N_u$ ,  $N_2$  e  $\alpha$ . Para a sintonia do controlador uma análise da sensibilidade desses parâmetros foram implementadas, tendo em conta os efeitos esperados para cada um deles.

O parâmetro  $\lambda$  é responsável pela penalização da variável manipulada e assim, quanto maior o valor de  $\lambda$  mais suave deve ser as variações da ação de controle. A Figura 6-23 e a Figura 6-24 apresentam o comportamento do controlador para  $\lambda = 1$  e  $\lambda = 0$ .

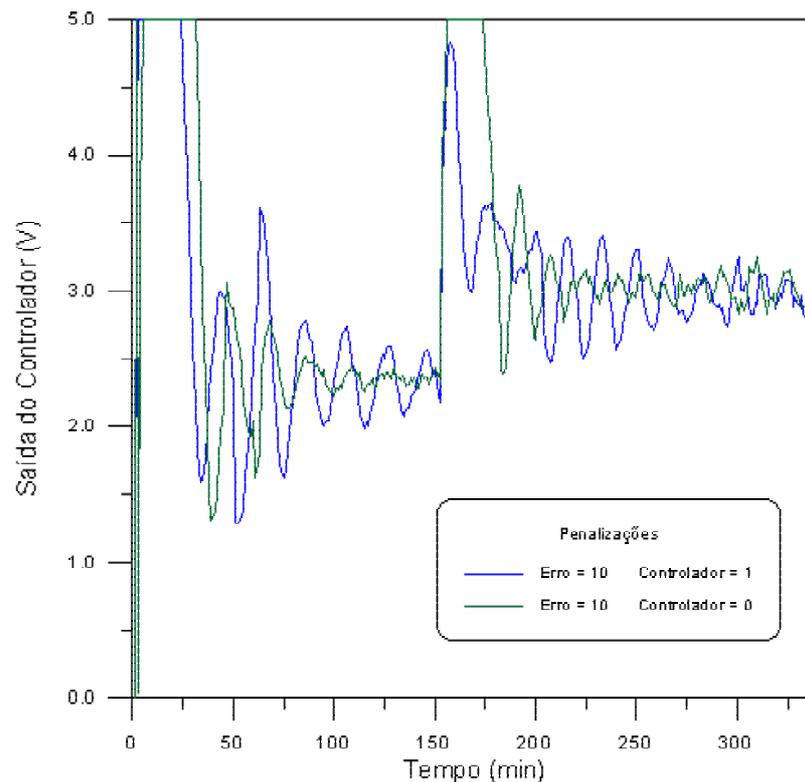
Uma análise qualitativa da resposta do sistema de controle às perturbações submetidas ao *set point* indica que a penalização acabou gerando um comportamento

mais oscilatório da variável controlada do que quando foi anulada a penalização do esforço do controlador.



**Figura 6-23** - Desempenho do controlador para diferentes fatores de penalização no esforço do controlador. Horizonte de Predição igual a 10 e de controle igual a 1.

Observando o comportamento da ação de controle foi possível perceber que a penalização suavizou excessivamente a ação de controle, fazendo com que a mesma obtenha este indesejável comportamento oscilatório. Adotou-se, assim, um controlador com  $\lambda$  igual a zero, ou seja, sem penalizações na variação da ação do controlador. Na verdade, ao se adotar uma estratégia de controle preditiva em que as ações de controle são obtidas por otimização, já era esperado que as penalizações para este termo da função objetivo fossem pequenos (QUIN e BADGWELL, 2003).



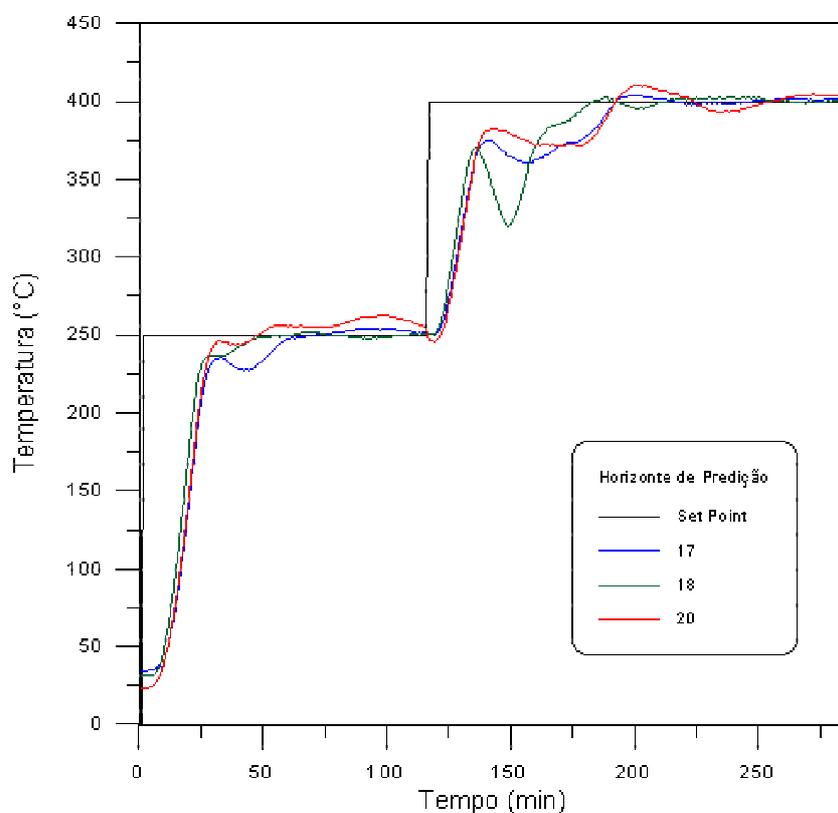
**Figura 6-24** - Esforço do controlador para diferentes penalizações impostas nas variações da ação de controle. Horizonte de Predição igual a 10 e de controle igual a 1.

O parâmetro  $\delta$ , responsável pela penalização do erro, foi variado de 1 até 50, para avaliar o efeito deste parâmetro na resposta do controlador. Com apenas este fator de penalização na função objetiva, e com um algoritmo de controle que obtém a seqüência ótima de controle, a qual minimiza esta função custo, o valor de  $\delta$  não apresentou efeito significativo na resposta do controlador. Adotou-se um fator de penalização igual a 50.

Neste trabalho o horizonte de controle foi inicialmente fixado em  $N_u = 1$ , e apenas no caso de não haver uma resposta dinâmica do controlador satisfatória, este parâmetro seria alterado.

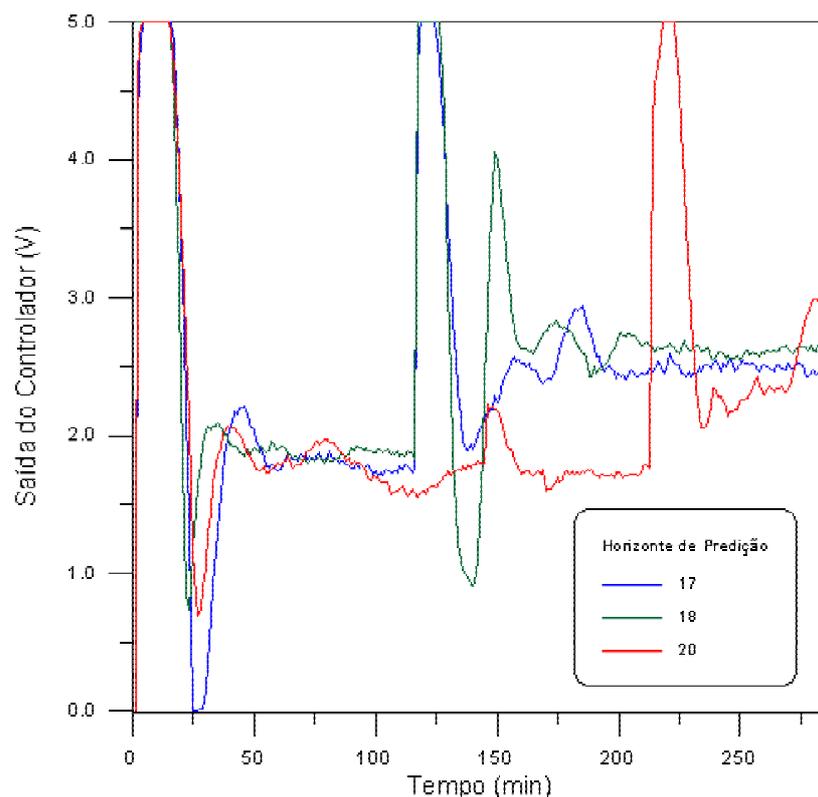
O horizonte de predição foi outra variável estudada. Como a rede utilizada foi completamente recursiva, o horizonte de predição deve ser previamente definido, pois esse é um dos parâmetros necessários para o treinamento da rede neural, uma vez que a mesma passa por um treinamento recursivo. Utilizou-se, na fase de treinamento,

horizontes de predição iguais a 5, 10, 15 e 20. Desta forma, os pesos a serem utilizados nos testes dos controladores são escolhidos entre estes conjuntos. Para horizontes de predição menor ou igual a 5 utilizou-se os pesos obtidos no treinamento com horizonte de predição igual a 5. Para horizontes de predição entre 5 e 10 empregou-se os pesos obtidos no treinamento com horizonte de predição igual a 10 e assim sucessivamente. Os testes realizados para diferentes horizontes de predição são apresentados na Figura 6-25 e Figura 6-26.



**Figura 6-25** - Desempenho do controlador preditivo com horizonte de controle igual a 1 e diferentes horizontes de predição.

Uma análise qualitativa das Figura 6-25 e Figura 6-26 indica uma melhor performance do controlador com horizonte de predição igual 18, apesar do acentuado *kickback* apresentado, quando o controlador está conduzindo o processo para o *set point* de 400°C. O problema do *kickback* será discutido posteriormente.



**Figura 6-26** - Esforço do controlador preditivo para horizonte de controle igual a 1 e diferentes horizontes de predição.

Em relação ao valor de  $\alpha$ , o qual irá definir a trajetória de referência, existem diversas propostas na literatura especializada, onde  $\alpha$  é apresentado como uma função do tamanho do degrau provocado no *set point*, algumas vezes função da constante de tempo dominante do processo, ou ainda, uma função específica do tempo. Neste trabalho optou-se por trabalhar com dois valores para  $\alpha$ . Um valor inicial igual a 0.90, quando o processo encontra-se ainda bem afastado do *set point* e um outro valor, mais conservativo, igual a 0.94 quando a temperatura do processo se aproxima do valor desejado. O objetivo do acréscimo no valor de  $\alpha$  é permitir uma aproximação mais suave, quando o processo encontra-se próximo ao *set point*, reduzindo assim o overshoot. Os valores aplicados para  $\alpha$  forneceram uma trajetória de referência aceitável para o processo de pirólise.

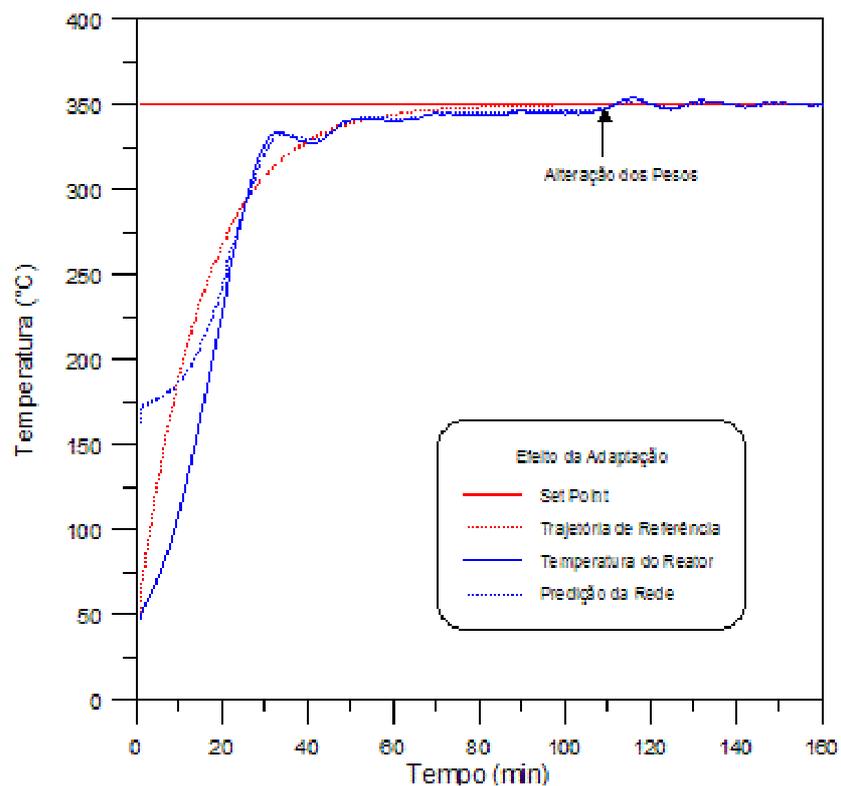
Após terem sido definidos os valores dos parâmetros do controlador preditivo realizaram-se testes, ainda com o reator vazio, para observar o comportamento dinâmico

destes controlador. A Figura 6-27 e Figura 6-28 apresentam um dos resultados, mostrando claramente um indesejável *offset* no processo.

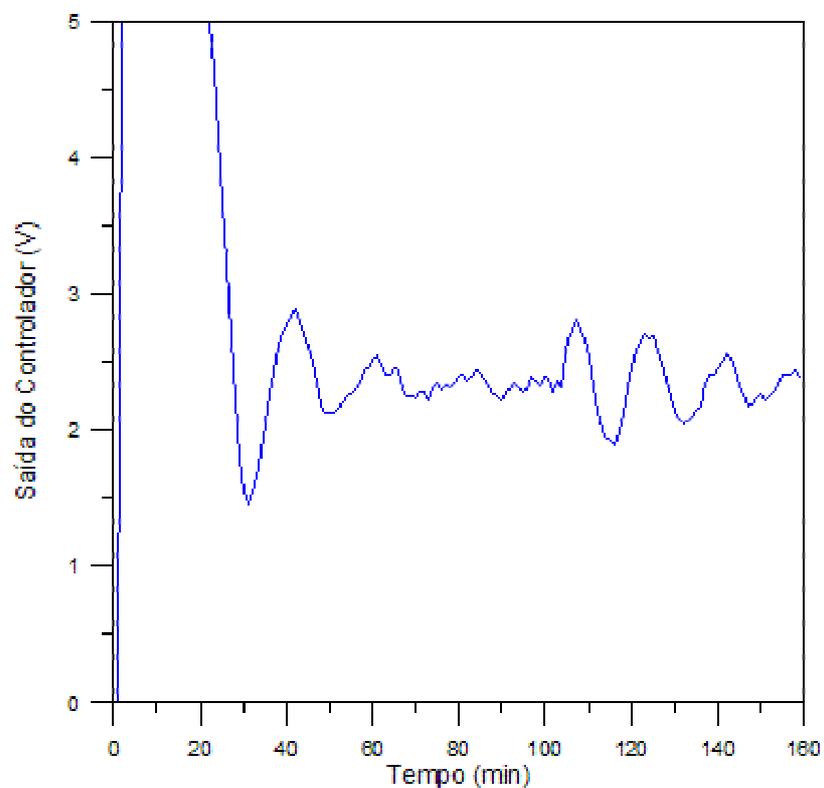
Pode-se concluir que o controlador preditivo com redes neurais como modelo para o processo apresenta *offset*. Conforme foi visto no Capítulo 3, a rede neural dinâmica, apesar de representar de forma adequada o comportamento dinâmico do sistema, tem dificuldades na representação do estado estacionário. Esta característica é que impõe ao controlador um desvio permante em relação ao *set point*. A inserção de uma ação integral para eliminar o *offset* não obteve sucesso, pois à medida em esta ação conduzia o processo ao valor do *set point*, a rede neural deslocava o processo do valor desejado. Desta forma, o resultado obtido foi um sistema com oscilação imposta por estas duas ações conflitantes. Alguns trabalhos na literatura sugerem o “desligamento” progressivo do controlador baseado em redes neurais em situações semelhantes a esta (CHEN e NARENDRA, 2001).

A comprovação de que o problema do *offset* é devido à dificuldade da rede neural em prever o comportamento do estado estacionário do processo é verificada na Figura 6-27 e Figura 6-28. Uma rede neural foi treinada *on-line* sendo utilizado como padrão um conjunto de dados do processo quando o controlador tentava mante-lo em 350°C. A alteração dos pesos fez com que o controlador conduzisse a temperatura do reator a 350°C (valor especificado para o *set point*).

Apesar do sucesso na eliminação do *offset*, o controlador apresentou um comportamento oscilatório e para que o controlador preditivo e adaptativo tivesse um desempenho mais favorável uma análise de sensibilidade paramétrica foi imprescindível. Esta análise e o ajuste do controlador preditivo e adaptativo auto-ajustável é assunto do próximo tópico.



**Figura 6-27** - Eliminação do *offset* mediante alteração dos pesos da rede neural através do treinamento *on-line*.



**Figura 6-28**- Ações do controlador submetido a trocas dos pesos para eliminação do *offset*.

## 6.4 Ajuste do Controlador Preditivo e do Controlador Preditivo Adaptativo

Como pôde ser visto na seção anterior, uma adaptação *on-line* dos pesos da rede neural, utilizando como padrão de treinamento dados do processo próximos ao *set point*, conseguiu eliminar o *offset*, apesar de trazer alguma instabilidade para o processo.

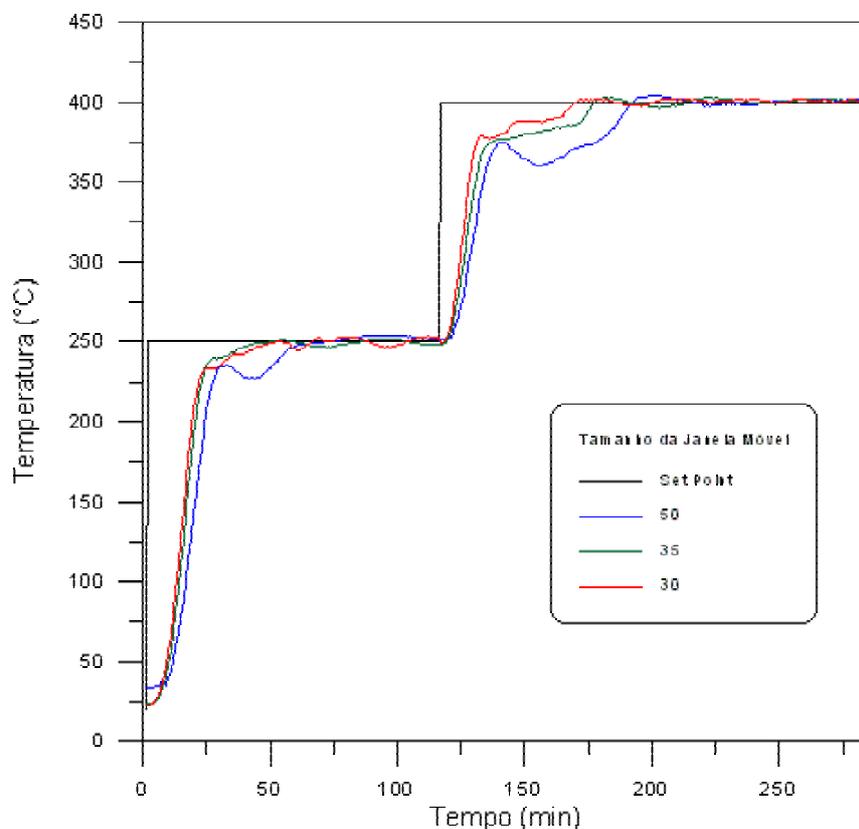
Frente a este panorama foi proposta um algoritmo de controle preditivo adaptativo, onde os pesos da rede neural são treinados *on-line* e o padrão de treinamento é um conjunto dos últimos dados do processo. O número de elementos do padrão é um valor pré-fixado pelo tamanho da janela móvel.

O tamanho da janela móvel é um fator importante para o desempenho do controlador preditivo adaptativo. Com poucos dados disponíveis para o treinamento, a rede neural não consegue prever o comportamento futuro da saída do processo, comprometendo o algoritmo de controle. Valores muito grandes tendem a fazer com que a rede neural continue a captar valores passados do processo, prejudicando a performance do controlador frente a distúrbios. Além disto, o número de épocas de treinamentos deve ser reduzido de forma a implementá-lo dentro do intervalo de amostragem. A Figura 6-29 e Figura 6-30 ilustram a análise deste comportamento.

Como não é possível fazer apenas uma análise qualitativa para os resultados obtidos, principalmente para janelas móveis com tamanhos 35 e 30, o ITAE será usado para quantificar a performance do controlador nos testes realizados. Os resultados são apresentados na Tabela 6-8.

Observa-se uma pequena variação nos valores obtidos para o critério de desempenho adotado (ITAE). Os valores relativos apresentados estão baseados nos valores obtidos para uma janela móvel com tamanho igual a 35. O péssimo desempenho do controlador que utiliza um padrão para treinamento *on-line* composto por 50 pontos

deve-se sobretudo, ao elevado tempo necessário para iniciar o treinamento da rede. Isto porque, para iniciar o treinamento deve-se esperar que ao menos um número de pontos iguais ao tamanho da janela tenha sido armazenado.



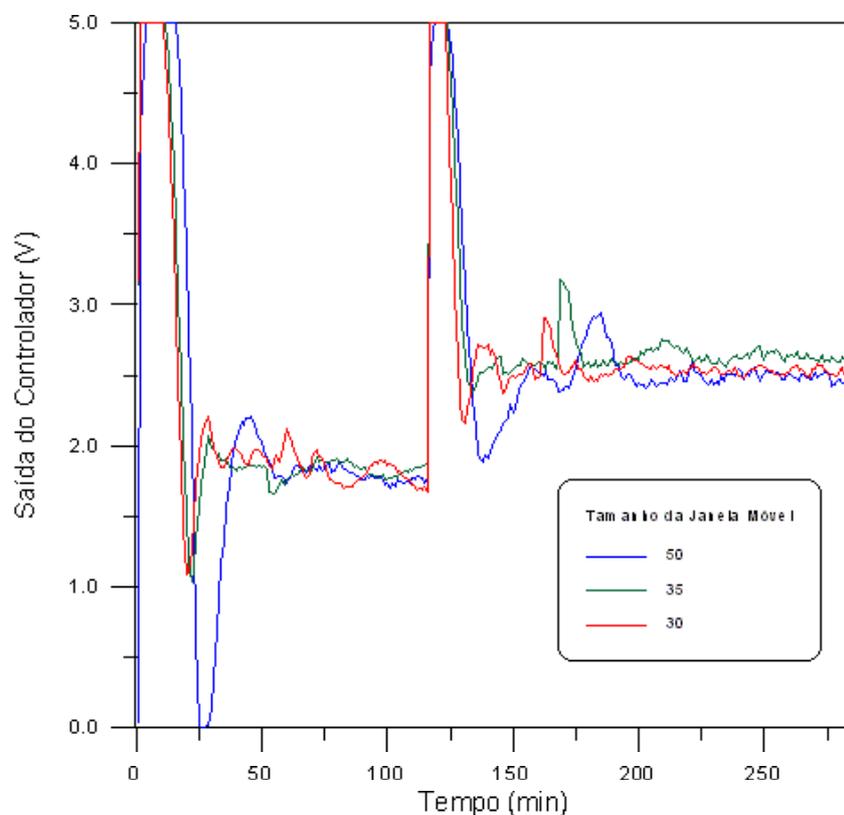
**Figura 6-29** - Influência do tamanho da janela móvel no desempenho do controlador preditivo com horizonte de controle igual a 1 e de previsão igual a 18.

**Tabela 6-8** - Análise comparativa dos critérios de desempenho (ITAE) do controlador preditivo com diferentes tamanhos de janelas móveis.

Set Point (°C)	Tamanho da Janela Móvel				
	50	45	40	35	30
250	1.70	0.97	1.04	1.00	1.05
400	1.86	1.30	1.03	1.00	0.65

Com uma variação no tamanho da janela de 45 até 30 não se observa variações significativas nos valores do critério de desempenho, ao menos para o caso do controlador

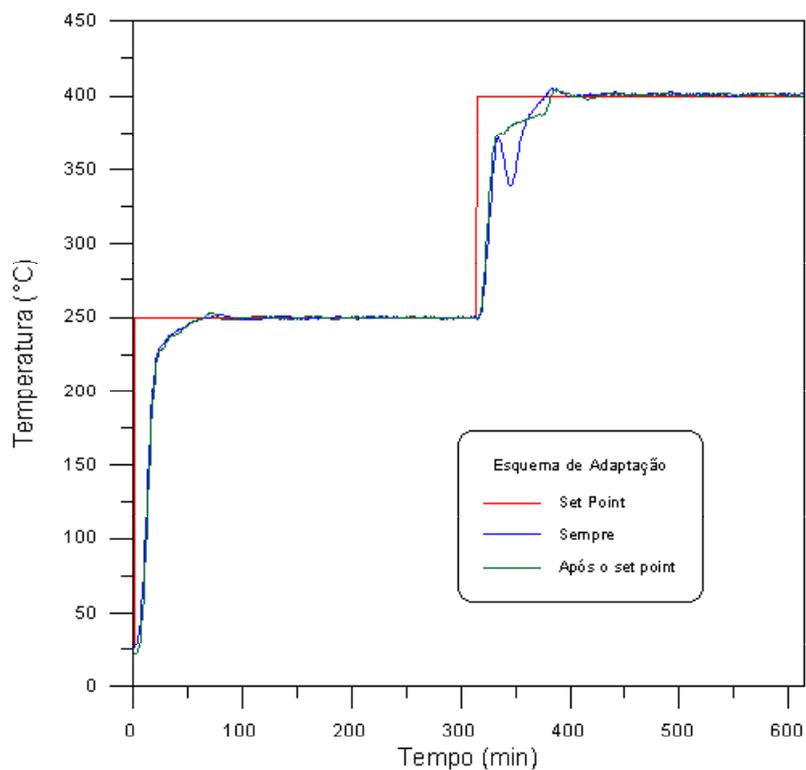
estar conduzindo o processo até 250°C. Observa-se uma performance ligeiramente superior para um tamanho de janela igual a 45. Uma análise qualitativa do esforço do controlador indica, entretanto, que o controlador com janela igual a 30 apresenta uma indesejável oscilação. Ao adotar um número menor de pontos para o treinamento, o controlador torna-se mais instável devido à maior variabilidade dos pesos. Pode-se notar que mesmo quando analisando a tarefa do controlador de conduzir o processo até 400°C, o esforço do controlador com tamanho de janela igual a 30 é maior, apresentando uma maior oscilação. Isto entretanto, não é contabilizado no critério de desempenho ITAE e o seu índice de desempenho é significativamente menor. Uma quantificação do esforço do controlador efetuado através do cálculo do somatório do quadrado da sua variação indica que o controlador com janela igual a 30 apresenta um esforço de cerca de 20% maior do que o controlador com tamanhos de janela 35 e 40 (desempenho muito próximos em todos os critérios).



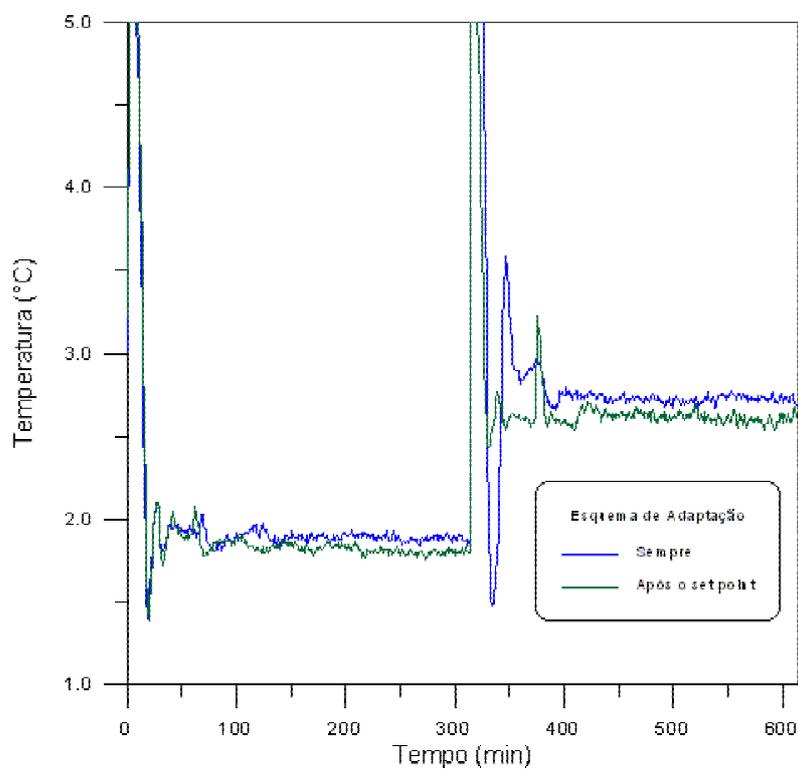
**Figura 6-30** - Influência do tamanho da janela móvel no esforço do controlador preditivo com horizonte de controle igual a 1 e horizonte de predição igual a 18.

Com base nos resultados apresentados até então, foi adotado um controlador preditivo e adaptativo auto-ajustável com os seguintes parâmetros:  $\delta = 50$ ,  $\lambda = 0$ ,  $N_u = 1$ ,  $N_2 = 18$ ,  $\alpha = 0.90$  e tamanho da janela igual a 35. Apesar dos desempenhos dos controladores com tamanhos de janela iguais a 35 e 40 terem sido muito semelhantes, adotou-se o controlador com janela igual a 35 com a intenção de obter um melhor desempenho frente a distúrbios do processo, uma vez que com um menor padrão de treinamento o modelo pode ser adaptado mais rapidamente à dinâmica do sistema, enquanto padrões maiores carregam consigo um maior histórico do processo, dificultando a adaptação a distúrbios.

Um problema observado nos resultados apresentados é um *kickback*, quando o processo aproxima-se de 400°C. Suspeitou-se que este problema era oriundo do esquema de adaptação. Ao iniciar um teste do controlador, o algoritmo de adaptação só entrava em operação quando passava um período de tempo igual a 1.25 vezes o tamanho da janela móvel. A idéia era que houvesse um número suficiente de dados armazenados para preencher o padrão de treinamento. Adotou-se um tempo ligeiramente maior para que fossem descartados os dados iniciais, quando o processo ainda não respondeu às ações de controle, devido ao seu elevado retardo dinâmico. A partir daí duas opções se descortinam: continuar, indefinidamente com o processo de adaptação, ou parar de adaptar quando uma nova perturbação é induzida no *set point*. O *kickback* ocorria quando se esolia a primeira opção. As Figuras apresentam uma comparação da performance do controlador com estas duas estratégias de adaptação. Nota-se que parando de adaptar o modelo quando o *set point* é alterado, e só retomando a adaptação quando for transcorrido um tempo igual a 1.25 vezes o tamanho da janela móvel, o problema do *kickback* é eliminado.



**Figura 6-31-** Efeito do esquema de adaptação na eliminação do *kickback*. Controladores preditivos e adaptativos com horizonte de predição igual a 45 e horizonte de controle igual a 1.



**Figura 6-32 -** Esforço do controlador com diferentes esquemas de adaptação, na tentativa de eliminar o *kickback*.

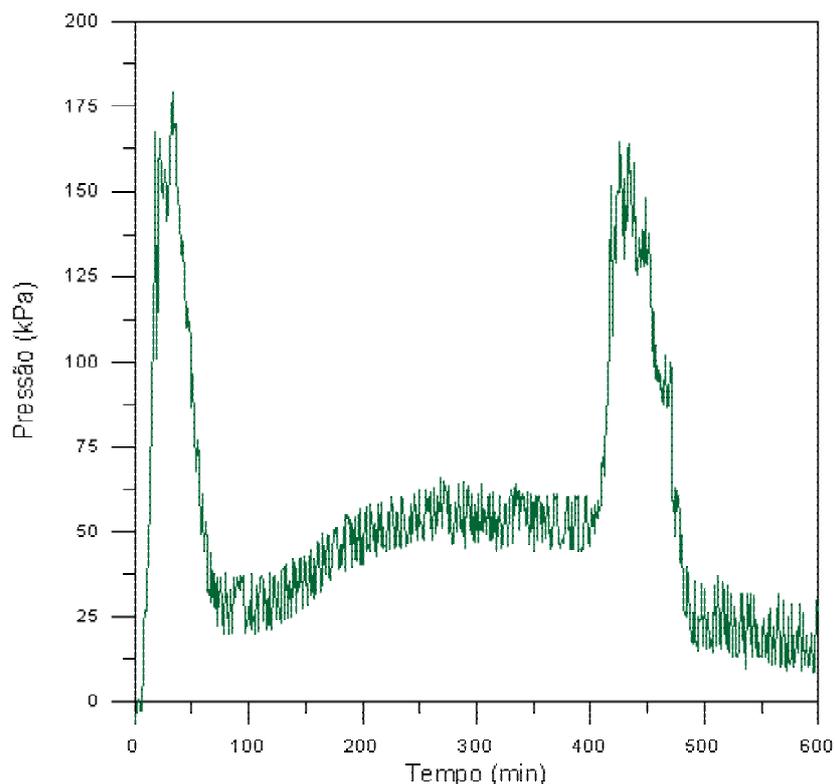
## 6.5 Comparação dos Algoritmos de Controle

Esta seção mostra o desempenho dos algoritmos de controle do tipo retroalimentação, projetado na seção 6.2, e do algoritmo de controle preditivo adaptativo apresentado na seção 6.4. Os resultados aqui apresentados referem-se ao controlador conduzindo a temperatura de reação de pirólise de borra de tinta para os *set points* de 250°C e em seguida para 400°C. Durante este processo a reação de pirólise vai ocorrendo e gases são produzidos no reator, elevando a sua pressão. Diversos pulsos foram submetidos ao processo, abrindo-se-se a válvula de saída do reator para aliviar a pressão do mesmo. Este procedimento acarretou um distúrbio não medido no processo, que é a saída de produtos, acarretando uma diminuição da temperatura. O efeito deste distúrbio vai depender da temperatura reacional no momento da perturbação e da composição dos gases presentes, uma vez que a quantidade de energia perdida será função da capacidade calorífica da mistura (dependente da composição da mistura), da temperatura de reação e da quantidade de gás que efetivamente deixa o reator.

A Figura 6-33 apresenta um caso típico dos distúrbios que assolam o processo durante a reação de pirólise de borra de tinta.

O algoritmo de controle preditivo adaptativo discutido nesta seção foi avaliado e teve sua performance comparada com um controlador do tipo retroalimentação, durante uma reação de pirólise da borra de tinta. A Figura 6-34 e 6-35 apresentam estes resultados.

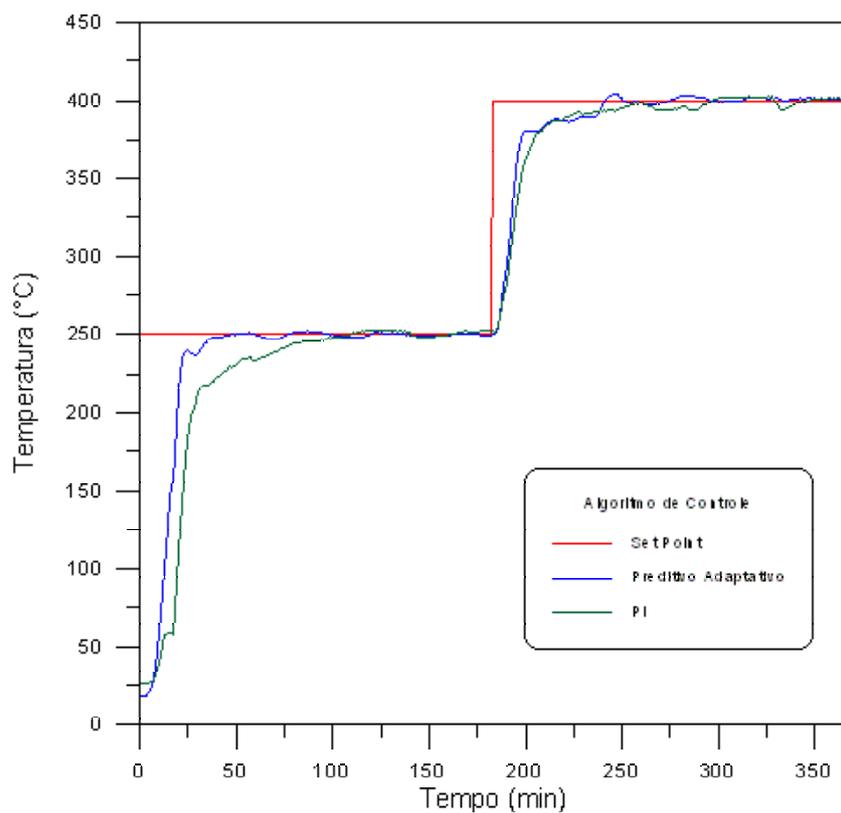
Nota-se claramente um desempenho superior do controlador preditivo adaptativo na primeira etapa do processo. Ambos os controladores conseguem eliminar os distúrbios nesta etapa, porém o controlador preditivo e adaptativo tem uma resposta muito mais rápida ao levar a temperatura do reator até o *set point*. Nenhum dos controladores apresentou *offset* e os *overshoots* foram desprezíveis.



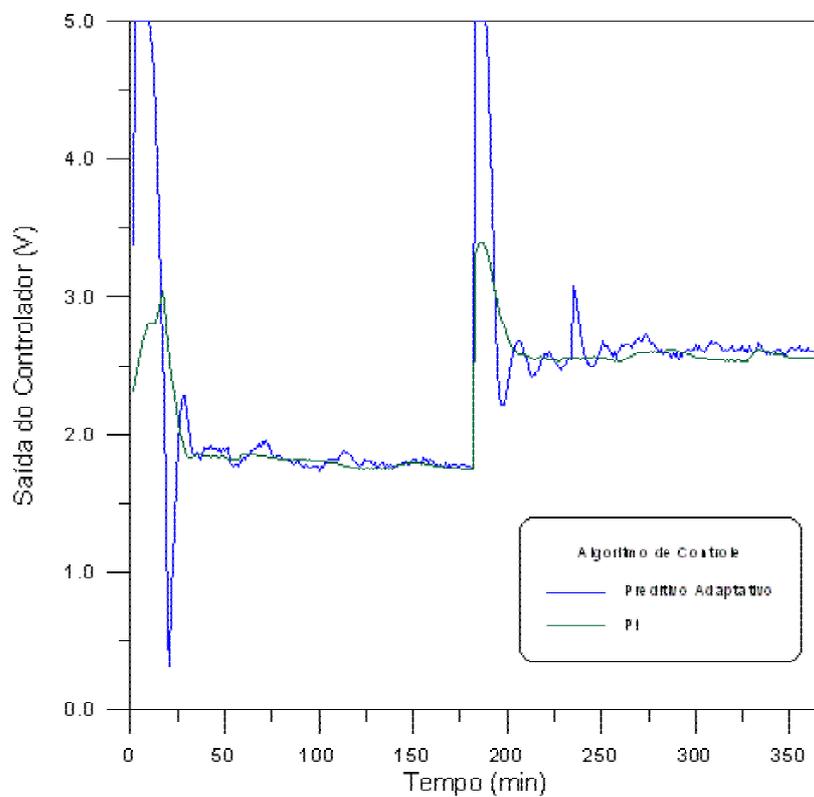
**Figura 6-33** - Evolução da pressão sujeita a pulsos ao longo da reação de pirólise de borra de tinta.

Na segunda etapa, o *set point* foi alterado de 250°C para 400°C. Apesar de apresentar um maior *overshoot* (*overshoot* de apenas 1%), o controlador preditivo apresentou mais uma vez um desempenho superior ao controlador do tipo retroalimentação. Como nesta etapa a reação ocorre de forma mais intensa, a produção de gás é incrementada e os distúrbios ocorrem com maior frequência e intensidade. O controlador do tipo retroalimentação apresenta dificuldades para conduzir a temperatura até o valor do *set point*, problema não repetido no controlador preditivo e adaptativo.

Analisando o comportamento da ação de controle, nota-se uma resposta mais “nervosa” do controlador preditivo. Estas ações entretanto, devem-se fundamentalmente à tentativa do controlador em eliminar os distúrbios que assolam o processo.



**Figura 6-34** - Comparação dos algoritmos de controle durante uma reação de pirólise de borra de tinta sujeita a pulsos na pressão.



**Figura 6-35** - Esforço dos controladores durante uma reação de pirólise de borra de tinta sujeita a pulsos na pressão.

A quantificação da performance dos controladores foi baseada no método ITAE e seus resultados são apresentados na Tabela 6-9.

**Tabela 6-9** - Índices de performance ITAE relativos entre os controladores preditivo e adaptativo e PI no controle da temperatura de um reator de pirólise.

<i>Set Point</i>	250°C	400°C
Controlador Preditivo Adaptativo	1.00	1.00
Controlador do Tipo Retroalimentação	4.90	1.70

Em vista do que foi apresentado neste capítulo, o algoritmo de controle preditivo adaptativo apresentou um comportamento muito superior ao do controlador clássico do tipo retroalimentação, no controle da temperatura de um reator de pirólise operando em regime semibatelada. O capítulo 8 traz as principais conclusões sobre os resultados apresentados neste capítulo, além de sugestões para estudos futuros.

# Capítulo 7

## Conclusões

---

**E**ste capítulo aponta as principais conclusões obtidas a partir do trabalho apresentado nesta obra. Foi desenvolvido um algoritmo de controle preditivo adaptativo com o objetivo de controlar a temperatura de um reator de pirólise operando em regime semibatelada. O controlador comportou-se de forma estável e sem *offset*, conseguindo conduzir a temperatura de reação aos valores estabelecidos pelo *set point*, além de compensar os fortes distúrbios a que o processo foi submetido, quando a válvula de saída do reator era aberta, com o intuito de diminuir a pressão formada pelos gases produzidos pela reação.

O controlador preditivo adaptativo proposto, quando comparado ao controlador clássico do tipo retroalimentação, apresentou um desempenho superior. Ao conduzir a temperatura do reator ao valor do *set point*, conseguiu reduzir significativamente o tempo de processamento. Para manter o processo, durante 10 minutos, no valor estabelecido pelo *set point*, valor sugerido por Costa-Muniz (Costa-Muniz, 2004), o tempo de batelada para o controlador do tipo retroalimentação foi de 290 minutos (160 minutos para atingir e manter-se em 250°C e 130 minutos para estabilizar e permanecer por 10 minutos em 400°C), enquanto o controlador preditivo e adaptativo proposto necessitou de apenas 140 minutos (sendo 60 minutos para o primeiro patamar e 80 minutos para o segundo). Esta

redução superior a 50% no tempo de processamento, ao optar pelo controlador preditivo e adaptativo, é um forte indicativo do ganho obtido por esse controlador.

Além do ganho no tempo de processamento do resíduo, essa condução mais rápida ao valor estabelecido para o processamento garante um melhor controle sobre a qualidade do produto obtido, a qual é sofre grande influência do tempo e da temperatura de operação do reator (Anexos A3, A4, A5 e A6).

A rede neural recursiva utilizada como modelo do processo, apesar de representar de forma satisfatória o comportamento dinâmico do processo, apresenta dificuldades na representação do estado estacionário. De fato, os dados obtidos para o treinamento representam o comportamento dinâmico do processo e não o estado estacionário. Como a rede “aprende” sobre o processo a partir do padrão de treinamento, este desempenho é justificável. Como o desempenho dos controladores MPC está intrinsecamente ligado à qualidade do modelo usado para representar o processo, essa dificuldade de representação do estado estacionário faz com que o controlador preditivo baseado em redes neurais apresente *offsets*. Uma estratégia de adaptação *on-line*, quando o processo está operando próximo ao ponto de estabilização garante a eliminação do *offset*.

A estratégia adaptativa empregada neste trabalho era baseada na técnica da janela móvel, a qual reduz o tamanho do padrão de treinamento, permitindo um treinamento da rede *on-line*. O método de otimização empregado para o treinamento da rede foi o método do gradiente, o qual forneceu, em conjunto com a técnica da janela móvel, uma adaptação robusta. Deve-se ressaltar que esse procedimento foi implementado em um computador Pentium II 300 MHz, evidenciando que para a implementação de estratégias de controle digitais não é necessário o uso de computadores com grande capacidade de processamento.

O tamanho do padrão gerado para o treinamento *on-line* afeta o desempenho do controlador. O número de parâmetros a serem determinados para modelo é 26 (20 pesos e 6 *bias*). Assim, um número reduzido de pontos no padrão de treinamento não garante fidedignidade à rede, prejudicando a robustez do controlador. Um número muito grande de pontos no padrão de treinamento aumentará o tempo de treinamento, obtendo-se assim valores longe do ótimo para os pesos da rede. Além disto, este padrão carrega consigo um histórico muito grande do processo, dificultando a adaptação do modelo a distúrbios não medidos. Neste trabalho, um tamanho de janela móvel igual a 35 foi adotado.

A estratégia de adaptação também tem papel decisivo no desempenho do controlador. A questão aqui é saber quando o modelo deve sofrer uma adaptação. Um número de pontos, ao menos igual ao tamanho da janela móvel foi adotado como critério para iniciar a adaptação. Assim um treinamento *offline* deve ser efetuado de forma a fornecer pesos iniciais para a rede, antes da adaptação. Entretanto, ao se produzir perturbações no *set point*, a rede adaptativa começa a fazer previsões para pontos onde ela não tem informações, realizando cálculos de extrapolação não recomendados. Portanto, neste trabalho, foi implementada no algoritmo uma condição de que ao ocorrer uma perturbação no *set point* o modelo para de sofrer adaptações por um período, pelo menos igual ao da janela móvel, e os pesos retornam aos valores iniciais, obtidos no treinamento *offline*.

Alguns aspectos merecem uma análise futura. Por exemplo, recomenda-se uma análise comparativa da performance do controlador proposto com um controlador preditivo com um modelo semi-empírico. Um balanço de massa e energia com parâmetros agrupados poderia ser proposto. A cinética da reação de pirólise, fonte de controvérsias na literatura especializada e de complexa estimativa, poderia ser descrita através de redes neurais. Desta forma, poderia ser adicionada uma ação *feedforward* para

o controlador, pois o distúrbio mais significativo (liberação parcial dos produtos de pirólise para aliviar a pressão do reator) poderia ser inferido através da queda de pressão e temperatura do reator.

O processo de pirólise operado em regime semibatelada poderia ser visto como um problema de controle multivariável, através do controle da pressão e da temperatura do reator. Esse é um outro estudo que deve ser conduzido em trabalhos futuros.

Sugere-se a aplicação da estratégia de controle proposta em outros processos operados em batelada ou semibatelada, com modelos de difícil identificação e que sofrem alterações na sua dinâmica ao longo do tempo, como é o caso dos bioprocessos.

# Capítulo 8

## Bibliografia

---

- ARENA, U., MASTELLONE, M.L. – The Phenomenology of Bed Defluidization During the Pyrolysis of Food-Packing Plastic Waste, **Powder Technology**, v. 120, p. 127 – 133, 2001.
- ASTRÖM, K.J. – Theory and Applications of Adaptive Control – A Survey, **Automatica**, v.19, n. 5, p. 471 – 486, 1983.
- BADGWELL, T.A. – Robust Model Predictive Control of Stable Linear Systems, **International Journal of Control**, v. 68, p. 797 – 818, 1997.
- BALLICE, L., YÜKSEL, M., SAGLAM, M., REIMERT, R., SCHULZ, H. – Classification of Volatile Products Evolved During Temperature-Programmed Co-Pyrolysis of Turkish Oil Shales with Low Density Polyethylene, **Fuel**, v. 77, n. 3, p. 1431 – 1441, 1998.
- BELTRAN, N.D.R., JACKSON, H. – Application of Neural Networks to Chemical Process Control, **Computers & Chemical Engineering**, v. 37, p. 387 – 390, 1999.
- BOCKHORN, H.; HORNUNG, A.; HORNUNG, U., JAKOBSTRÖER, P. – Modelling of Isothermal and Dynamic Pyrolysis of Plastics Considering Non-Homogeneous Temperature Distribution and Detailed Degradation Mechanism, **Journal of Analytical and Applied Pyrolysis**, v. 49, p. 53 – 74, 1999.
- BOLZAN, A. – Ajuste e Implementação de um Controlador Adaptativo para um Reator Semi-Batelada, Tese de Doutorado, COPPE, Universidade Federal do Rio de Janeiro – UFRJ, Rio de Janeiro, 1991.

- BRDYS, M.A.; KULAWSKI, G.J., QUEVEDO, J. - Recurrent Networks for Nonlinear Adaptive Control, **IEE Proceedings-Control Theory and Applications**, v. 145, Nº 2, p. 177 - 188, 1998.
- VAN BREUSEGEM, V., THIBAUT, J., CHÉRUUY, A. – Adaptive Neural Models for On-Line Prediction in Fermentation, **The Canadian Journal of Chemical Engineering**, v. 69, p. 481 – 487, 1991.
- CAMACHO, E.F., BORDONS, C. – Model Predictive Control in the Process Industry, London: Springer, 1995
- CANCELIER, A. – **Controle Preditivo de Reatores Semi-Batelada**, Dissertação de mestrado, Departamento de Engenharia Química, Universidade Federal de Santa Catarina – UFSC, Florianópolis, 1998.
- CHEN, L., NARENDRA, K.S. – Nonlinear Adaptive Control Using Neural Networks and Multiple Models, **Automatica**, v.37, p. 1245 – 1255, 2001.
- COOPER, D., BIESZCZAD, J. – Picles 4.0 and the Case of the Jackted CSTR, **CACHE News**, fall, p. 24 – 31, 1994.
- COSTA-MUNIZ, A.R. – **Otimização da Operação de um Reator de Pirólise de Resíduos Sólidos Industriais**, Tese de Doutorado, Departamento de Engenharia Química, Universidade Federal de Santa Catarina – UFSC, Florianópolis, 2004.
- CUTLER, C.R., RAMAKER, B.L. - Dynamic Matrix Control – a Computer Control Algorithm, **AIChE National Meeting**, Houston, TX, 1979.
- DÍAZ, G.; SEN, M.; YANG, K.T., McCLAIN, R.L. – Adaptive Neurocontrol of Heat Exchangers, **Journal of Heat Transfer**, v. 123, june, p. 556 – 562, 2001.
- DI BLASI, C. – Modeling Intra-and Extra-Particle Processes of Wood Fast Pyrolysis, **AIChE Journal**, v. 48, n. 10, p. 2386 – 2397, 2002.
- DIRION, J.-L., CABASSUD, M., LE LANN, M.V., CASAMATTA, G. – Development of Adaptive Neural Networks for Flexible Control of Batch Processes, **The Chemical Engineering Journal**, v. 63, p. 65 – 77, 1996.

- DOMINGUEZ, A., BLANCO, C.G., BARRIOCANAL, C., ALVAREZ, R., DIEZ, M.A.  
– Gas Chromatographic Study of the Volatile Products from Co-Pyrolysis of Coal and Polyethylene Wastes, **Journal of Chromatography**, v. 918, p. 135 – 144, 2001.
- DOUGHERTY, D., COOPER, D. – A Practical Multiple Model Adaptive Strategy for Single-Loop MPC, **Control Engineering Practice**, 11, p. 141 – 159, 2003.
- EDGAR, T.F., HIMMELBLAU, D.M. - Optimization of Chemical Process, International Edition., 1989.
- EDULJEE, G., CAINS, P. – Control of Dioxin Emissions from Waste Combustors, **Filtration & Separation**, july/august, p. 599 – 603, 1997.
- ENDER, L., MACIEL FILHO, R. – Design of Multivariable Controller Based on Neural Networks, **Computers & Chemical Engineering**, v. 24, p. 937 – 943, 2000.
- ENDER, L., MACIEL FILHO, R. - An Innovative Nonlinear Adaptive Control Algorithm: Application to a Fermentation Process, **Proceedings of Enpromer**, v. I, p. 283 - 288, 2001.
- ERDMAN, A.J.R., JOHNSON, J. – Low Temperature-Thermal Stripping and Volume Reduction of Waste Sludges with a Hollow Screw Indirect Heat Exchange Processor, **Pollution Engineering**, v. 21, N° 3, 1989.
- FIGUEREDO, M.E. – Reciclagem de Plásticos Termofixos à Base de Resina Poliéster Reforçado com Fibra de Vidro, **Anais do I Congresso Brasileiro de Polímeros**, São Paulo (SP): Universidade de São Carlos, p. 460 - 464, 1991.
- FILETI, A.M.F., PEREIRA, J.A.F.R. - Adaptive and Predictive Control Strategies for Batch Distillation: Development and Experimental Testing, **Computers & Chemical Engineering**, v. 21, Suppl., S1227 - S1231, 1997.
- FOLLY, R.; BERLIM, R.; SALGADO, A.; FRANÇA, R., VALDMAN, B. Adaptive Control of Feed Load Changes in Alcohol Fermentation, **Brazilian Journal of Chemical Engineering**, v. 14, N° 04, p. 375 - 381, 1997.

- GARCÍA, C.E., MORSHEDI, A.M. – Quadratic Programming Solution of Dynamic Matrix Control (QDMC), **Chemical Engineering Communications**, v. 46, p. 73 – 87, 1986.
- HUSSAIN, M.A. - Review of the Applications of Neural Networks in Chemical Process Control – Simulation and Online Implementation, **Artificial Intelligence in Engineering**, v. 13, p. 55 - 68, 1999.
- ISLAM, M.N., ANI, F.N. – Techno-Economics of Rice Husk Pyrolysis, Conversion with Catalytic Treatment to Produce Liquid Fuel, **Bioresource Technology**, v. 73, p. 67 – 75, 2000.
- ISLAM, M.N., ZAILANI, R., ANI, F.N. – Pyrolytic Oil from Fluidised Bed Pyrolysis of Oil Palm Shell and Its Characterisation, **Renewable Energy**, v. 73, n. 84, p. 73 – 84, 1999.
- JANSE, A.M.C., WESTERHOUT, R.W.J., PRINS, W. – Modelling of Flash Pyrolysis of a Single Wood Particle, **Chemical Engineering and Processing**, v.39, p. 67 – 75, 2000.
- KAILATH, T. – Linear Systems. Englewood Cliffs, New Jersey: Prentice-Hall, 1980.
- KALMAN, R.E. – A New Approach to Linear Filtering and Predictions Problems, **Transactions of ASME, Journal of Basic Engineering**, v.87, p. 35 – 45, 1960.
- KAMINSKI, W. – Recycling of Polymeric Materials by Pyrolysis, **Macromol. Chem., Macrom. Symposium**, p. 48 – 49, 1991.
- KANELLAKOPOULOS, I., KOKOTOVIC, P.V., MARINO, R. – An Extended Direct Scheme for Robust Adaptive Nonlinear Control, **Automatica**, v. 27, N° 2, p. 247 – 255, 1991.
- KIM, B.R.; KALIS, E.M.; SALMEEN, I.T.; KRUGE, C.W.; DEMIR, I.; CARLSON, S.L., ROSTAM ABADI, M.– Evaluating Paint Sludges Chars for Adsorption of Selected Paint Solvents, **Journal of Environmental Engineering**, v. 122, N° 6, 532 – 539, 1996.

- KIM, S.S., KIM, S.H. – Pyrolysis Kinetics of Waste Automobile Lubricating Oil, **Fuel**, v. 79, p. 1943 – 1949, 2000.
- KIM, B.R., PODSIADLIK, D.H.; YEH, D.H.; SALMEEN, I.T., BRIGGS, L.M. – Evaluating Conversion of an Automotive Paint Spray Booth Scrubber to an Activated Sludge System for Removing Paint Volatile Organic Compound from Air. **Water Environment Research**, 69 (7), 1211 – 1221, 1997.
- KWONG, W.H. – An Improved Simplified Model Predictive Control Algorithm and its Application to a Continuous Fermenter, **Brazilian Journal of Chemical Engineering**, v. 17, n. 2, 2000.
- LANOUILLE, R.; THIBAUT, J., VALADE, J.L. – Process Modeling with Neural Networks Using Small Experimental Datasets, **Computers & Chemical Engineering**, v 23, p. 1167 – 1176, 1999.
- LEE, M., PARK, S. - A New Scheme Combining Neural Feedforward Control with Model - Predictive Control. **AIChE Journal**, v. 38 N° 2, p. 193 - 200, 1992.
- LIMA, L.M.Q. – **Lixo – Tratamento e Biorremediação**. São Paulo (SP): Hemus Editora Ltda., 1991.
- LIMA, M.R.S. – Projeto e Montagem de um Aparato Experimental para Pirólise, Trabalho apresentado como parte dos requisitos para a obtenção da aprovação na disciplina de Estágio Supervisionado em Engenharia Química da Universidade de Caxias do Sul. Caxias do Sul (RS): Universidade de Caxias do Sul, 1998.
- LIN, K.S., WANG, H.P., LIU, S.H., CHANG, N.B., HUANG, Y.J., WANG, H.C. – Pyrolysis Kinetics of Refuse-Derived Fuel, **Fuel Processing technology**, v.60, p. 103 – 110, 1999.
- LOPEZ, A.M., MURRIL, P.W., SMITH, C.L. – Controller Tuning Relationships Based on Integral Performance Criteria, **Instrumentation Technology**, v. 14 p 57, 1976.
- LOVETT, S.; BERRUTI, F., BEHIE, L.A. – Ultraprolytic Upgrading of Plastics Wastes and Plastics/Heavy Oil Mixtures to Valuable Light Gas Products, **Ind. Eng. Chem.**, p.4436 – 4444, 1997.

- MACHADO, R.A.F. – Otimização e Controle de Reatores de Polimerização em Batelada, Tese de Mestrado, Departamento de Engenharia Química, Universidade Federal de Santa Catarina – UFSC, Florianópolis, 1996.
- MASTELLONE, M.L., ARENA, U. – Fluidized-Bed Pyrolysis of Polyolefins Wastes: Predictive Defluidization Model, **AIChE Journal**, v. 48, n. 7, p. 1439 – 1447, 2002.
- MAZZUCCO, M.M. – Implementação de um Controlador Preditivo Baseado em um Modelo Neural Associado a um Sistema Especialista, Dissertação de Mestrado, Departamento de Engenharia Química, Universidade Federal de Santa Catarina – UFSC, Florianópolis, 1996.
- MINGZHONG, L., FULLI, W. - Adaptive Control of Black - Box Nonlinear Systems Using Recurrent Neural Networks, **Proceedings of 36<sup>th</sup> Conference on Decision & Control**, San Diego, California-EUA, dezembro de 1997.
- MITCHELL, D.B., SCHWEERS, M.E. – Waste Reduction Using Organic Polymers, **Pollution Engineering**, v.21, Nº 3, 1989.
- MORARI, M., LEE, J.H. - Model Predictive Control: Past, Present and Future, **Computers and Chemical Engineering**, v. 23, p. 667 - 682, 1999.
- MORARI, M., ZAFIRIOU, E. – Robust Process Control. Englewood Cliffs, New Jersey: Prentice-Hall, 1989.
- MORRISON, R., BOYD, R. – **Química Orgânica**. Lisboa: Fundação Calouste Gulbenkian, 1993.
- MOUSQUÈS, P.; DIRION, J.L., GROUSET, D. – Modeling of Solid Particles Pyrolysis, **Journal of Analytical and Applied Pyrolysis**, v. 58-59, p. 733 – 745, 2001.
- MUNIZ, L.A.R.; COSTA, A.R.; STEFFANI, E.; PALOSCHI, R., ZATTERA, A.J. – Aproveitamento de Resíduos de EVA através de Pirólise. **XXVII Congresso Brasileiro de Sistemas Particulados**, Campos do Jordão – SP, 1999.
- MUNIZ, L.A.R., COSTA, A.R., ESTEFFANI, E., ZATTERA, A., HOFSETZ, K., BOSSARDI, K., VALENTINI, L. – A Study of Paint Sludge Deactivation by

- Pyrolysis Reaction, **Brazilian Journal of Chemical Engineering**, v. 20, n. 01, p. 63 – 68, 2003.
- NAHAS, E.P.; HENSON, M.A., SEBORG, D.E. Nonlinear Internal Model Control Strategy for Neural Network Models, **Computers & Chemical Engineering**, v. 16, N° 12, p. 1039 - 1057, 1992.
- NAKOUZI, S. ET AL. – Novel Approach to Paint Sludge Recycling: Reclaiming of Paint Sludge Components as Ceramic Composites and their Applications in Reinforcement of Metals and Polymers, **Journal of Materials Research**, v. 13, N° 1, 53 – 60, 1998.
- NARENDRA, K.S., PARTHASARATHY, K. – Identification and Control of Dynamical Systems Using Neural Networks, **IEEE Transactions on Neural Networks**, v. 1, N° 1, p. 4 – 27, 1990.
- NOVICKI, R.E.M. ET AL. – Retortagem de Pneus pelo Processo PETROSIX, **Petróleo Brasileiro S.A.**, 2000.
- PEREIRA, C.; HENRIQUES, J., DOURADO, A. - Adaptive RBFNN versus Conventional Self - Tuning: Comparison of Two Parametric Model Approaches for Non - Linear Control, **Control Engineering Practice**, v. 8, p. 3 - 12, 2000.
- PICHE, S., SAYYAR-RODSARI, B., JOHNSON, D., GERULES, M. – Nonlinear Model Predictive Control Using Neural Networks, **IEEE Control Systems Magazine**, p. 53 – 62, 2000.
- PIOVOSO, M.; KOSANOVICH, K.; ROKHLENKO, V., GUEZ, A. - A Comparison of Three Nonlinear Controller Designs Applied to a Nonadiabatic First Order Exothermic Reaction in a CSTR, **Proceedings of American Control Conference**, p. 490 - 494, june, Chicago-IL, 1992
- PRETT, D.M., GARCÍA, C.E., **Fundamental Process Control**, Boston: Butterworths, 1988.
- QIN, S.J., BADGWELL, T.A. – A Survey of Industrial Model Predictive Control Technology, **Control Engineering Practice**, v 11, p. 733 – 764, 2003.

- RICHALET, J.; RAULT, A.; TESTUD, J.L., PAPON, J. - Model Predictive Heuristic Control: Applications to Industrial Processes, **Automatica**, v. 14, p. 413 - 428, 1978.
- RITA, D.J. – Controle de Processos Usando Redes Neurais Artificiais: Uma Aplicação Experimental, Dissertação de mestrado, Departamento de Engenharia Química, Universidade Federal de Santa Catarina – UFSC, Florianópolis, 1995.
- RIVALS, I., PERSONNAZ, L. – Nonlinear Internal Model Control Using Neural Networks: Application to Processes with Delay and Design Issues, **IEEE Transactions on Neural Networks**, v. 11, N° 1, p. 80 – 90, 2000.
- RODRIGUES, M.A., ODLOAK, D. – Including Model Uncertainty in the Model Predictive Control with Output Feedback, **Brazilian Journal of Chemical Engineering**, v. 19, n. 4, p. 475 – 482, 2002.
- ROVITHAKIS, G.A., CHRISTODOULOU, M.A. – Adaptive Control of Unknown Plants Using Dynamical Neural Networks, **IEE Transactions on Systems, Man, and Cybernetics**, v. 24, n. 3, 1994.
- SARKAR, D., MODAK, J.M. – ANNSA: a Hybrid Artificial Neural Network/Simulated Annealing Algorithm for Optimal Control Problems, **Chemical Engineering Science**, v. 58, N° 14, p. 3131-3142, 2003.
- SEBASTIAN, M., DOBOSZ, J.R. – Thermoanalytical Investigation of Some Industrial Wastes Produced in Steel Works, **Journal of Thermal Analysis**, v. 33, N° 2, 1988.
- SEBORG, D., EDGAR, T.F., DUNCAN, A.M. – Process Dynamics and Control, New York: John Wiley & Sons, 1989.
- SILVA, R.G.; ANASTÁCIO, C.S., KWONG, W.H. - Model Predictive Control Algorithms and their Application to a Continuous Fermenter, **Brazilian Journal of Chemical Engineering**, v. 16, p. 155 - 161, 1999.
- SMITH, C.A., CORRIPIO, A.B. – Principle and Practice of Automatic Process Control, Second Edition, New York: John Wiley & Sons, 1997.

- TURNER, P.; MONTAGUE, G., MORRIS, J. - Dynamic Neural Networks in Non - Linear Predictive Control (an Industrial Application), **Computers & Chemical Engineering**, v. 20, suppl., S937 - S942, 1996.
- YOUSSEF, C.B., GUILLOU, V., OLMOS-DICHARA, A. – Modelling and Adaptive Control Strategy in a Lactic Fermentation Process, **Control Engineering Practice**, 8, p. 1297 – 1307, 2000.
- WILLIS, M.J.; MASSIMI, C.DI; MONTAGUE, G.A.; THAM, M.T., MORRIS, A.J. - Artificial Neural Networks in Process Engineering, **IEE proceedings-D.**, 138 (3), 1991.
- WURZENBERGER, J.C., WALLNER, S., RAUPENSTRAUCH, H., KHINAST, J.G. – Thermal Conversion of Biomass: Comprehensive Reactor and Particle Modeling, **AIChE Journal**, v. 48, n. 10, p. 2398 – 2411, 2002.
- ZHANG, T., GE, S.S., HANG, C.C. – Design and Performance Analysis of a Direct Adaptive Controller for a Nonlinear Systems, **Automatica**, 35, p. 1809 – 1817, 1999.
- ZHAO, H., GUIVER, J.P., SENTONI, G.B. – An Identification Approach to Nonlinear State Space Model for Industrial Multivariable Model Predictive Control, **Proceedings of the 1998 American Control Conference**, p 796 – 800, 1998.

## **Anexo A 1**

### **Efeito da Massa de Resíduo Sobre o Calor Fornecido ao Reator de Pirólise**

---

Potência Permanente (W)	Massa de Resíduo Alimentada (g)	Temperatura Média (°C)
444.24	500	455.18
506.64	800	452.82
723.68	0	643.07
672.48	500	551.23
662.26	800	550.67
865.56	500	638.22
927.32	800	638.99
362.12	0	454.67
975.40	700	648.11
662.43	600	568.03

## Anexo A 2

# Código Computacional do Controlador Preditivo Adaptativo

---

```
//Controle Preditivo Adaptativo
If ControleOtimo.Checked Then
Begin
  //Inicialização da Trajetória da Variável Controlada
  Auxiliar      := A_Normal*SP+B_Normal;
  If SP <> StrToFloat(eSetPoint.Text) Then
  Begin
    Tempo := 0;
    DeltaSP := StrToFloat(eSetPoint.Text) - SP;
  End;
  SP      := StrToFloat(eSetPoint.Text);
  Tamanho_Janela_Movel:= StrToInt(eTamanho_Janela_Movel.Text);
  Alfa    := StrToFloat(eHC.Text);
  Horizonte_Predicao := StrToInt(eHP.Text);
  Lambda  := StrToFloat(eB.Text);
  Beta    := StrToFloat(eA.Text);
  Tsetpoint := A_Normal*SP+B_Normal;
  //
  // Atualização da Janela Móvel
  //
  For i := Ordem_Var_Medida to 2 Do
  Begin
    Janela[1,i] := Janela[1,i-1];
  End;
  If Ordem_Var_Manipulada > 1 Then
```

```

Begin
  For i := Ordem_Var_Manipulada to 2 Do
    Begin
      Janela[2,i] := Janela[2,i-1];
    End;
  End;
Janela[1,1] := A_Normal*Entrada[1] + B_Normal;
Janela[2,1] := 0.12*OutVolts[1]+0.2;
If Tempo = 0 Then yref[2] := Janela[1,1];
Tempo := Tempo + 1;
Auxiliar := yref[1];
yref[1] := yref[2];
If Tempo < 30 Then
  Begin
    Alfa := 0.9;
    yref[1] := Janela[1,1];
    If Tempo > 2 Then
      Begin
        If Auxiliar > yref[1] Then yref[1] := yref[2];
      End;
    End;
  End;
For l := 2 to Horizonte_Predicao Do
  Begin
    yref[l] := Alfa*yref[l-1]+(1-Alfa)*Tsetpoint;
  End;
  yrefgraf := (yref[1]-B_Normal)/A_Normal;
  Series11.Add(SP);
  Series13.Add((Predicao[1]-B_Normal)/A_Normal);
  Series12.Add((yref[2]-B_Normal)/A_Normal);

```

```
//Algoritmo Adaptativo
```

```
//Treinamento On Line da Rede Neural
```

```
//Atualização do Padrão de Treinamento
```

```
For i := 1 to Tamanho_Janela_Movel Do
Begin
  VetorAdaptacao[i,2] := VetorAdaptacao[i,1];
  VetorAdaptacao[i,1] := VetorAdaptacao[i,4];
  VetorAdaptacao[i,4] := VetorAdaptacao[i+1,4];
  VetorAdaptacao[i,3] := VetorAdaptacao[i+1,3];
End;
VetorAdaptacao[Tamanho_Janela_Movel,4] := Janela[1,1];
VetorAdaptacao[Tamanho_Janela_Movel,3] := Janela[2,1];
If rbAdaptacao.Checked Then
Begin
  If Amostra > Trunc(1.5*Tamanho_Janela_Movel) Then
  Begin
    //Treinamento da Rede Neural
    //
    //Cálculo da direção de busca
    //
    delta_peso := 0.001;
    passo := 0.0001;
    For epocas := 1 to 300 Do
    Begin
      //
      //Cálculo da Função Objetivo
      //
      Objetivo_Anterior[1] := ObjetivoAdaptacao[1];
      ObjetivoAdaptacao[1] := 0;
      ObjetivoAdaptacao[2] := 0;
      For i := 1 To Tamanho_Janela_Movel Do
      Begin
        //Inicio da Rede Neural
        For j := 1 to Neuronios_Entrada do
        Begin
          At[j] := VetorAdaptacao[i,j];
        End;
        ObjetivoErro := 0;
```

```

For l := 1 to Horizonte_Predicao do
Begin
//
// Cálculo da Saída dos Neurônios da Camada de Entrada}
//
If ( i + 1 < Tamanho_Janela_Movel) then
Begin
For j := 1 To Neuronios_Entrada Do
Begin
Ativacao[1,j] := At[j];
End;
// Cálculo da Saída dos Neurônios da Camada Intermediária}
//
For j := 1 To Neuronios_Intermediario Do
Begin
soma_entrada := BiasAdaptacao[j];
For k := 1 To Neuronios_Entrada Do
Begin
soma_entrada := soma_entrada + Ativacao[1,k] * PesoAdaptacao[k,j];
End;
Ativacao[2,j] := 1 / (1 + exp(-soma_entrada));
End;
For j := 1 To Neuronios_Saida Do
Begin
soma_intermediaria := BiasAdaptacao[Neuronios_Intermediario+j];
For k := 1 To Neuronios_Intermediario Do
Begin
soma_intermediaria := soma_intermediaria + Ativacao[2,k] *
PesoAdaptacao[Neuronios_Entrada+j,k];
End;
//
// Cálculo do Neurônio de Saída
//
Ativacao[3,j] := 1 / (1 + exp(-soma_intermediaria));
End;
For k := Ordem_Var_Medida to 2 Do
Begin
At[k] := At[k-1];
End;
At[1] := Ativacao[3,1];
For k := Ordem_Var_Medida+1 to Neuronios_Entrada Do

```

```

Begin
  At[k] := VetorAdaptacao [i+1,k];
End;
ObjetivoErro := ObjetivoErro + (At[1]-VetorAdaptacao[i+1-
1,Neuronios_Entrada+1])*(At[1]-VetorAdaptacao[i+1-
1,Neuronios_Entrada+1]);

End;
End;
//
//Fim da Rede Neural
//
For j := 1 To Neuronios_Saida Do
Begin
  ObjetivoAdaptacao [1] := ObjetivoAdaptacao[1] + ObjetivoErro;
End;
End;
If Objetivo_Anterior[1] < ObjetivoAdaptacao[1] then
Begin
  passo := passo/1.2;
End;
For l := 1 to Neuronios_Entrada do
Begin
  For m := 1 to Neuronios_Intermediario do
Begin
  PesoAdaptacao[l,m]:=PesoAdaptacao[l,m] + delta_peso;
  ObjetivoAdaptacao[2]:=0;
  For i := 1 To Tamanho_Janela_Movel Do
Begin
  //Cálculo da Rede Neural

  For j := 1 to Neuronios_Entrada do
Begin
  At[j] := VetorAdaptacao[i,j];
End;
ObjetivoErro := 0;
For n := 1 to Horizonte_Predicao do
Begin
  //
  // Cálculo da Saída dos Neurônios da Camada de Entrada}

```

```

//
If ( i + n < Tamanho_Janela_Movel) then
Begin
  For j := 1 To Neuronios_Entrada Do
  Begin
    Ativacao[1,j] := At[j];
  End;
//
//  Cálculo da Saída dos Neurônios da Camada Intermediária}
//
For j := 1 To Neuronios_Intermediario Do
Begin
  soma_entrada := BiasAdaptacao[j];
  For k := 1 To Neuronios_Entrada Do
  Begin
    soma_entrada := soma_entrada + Ativacao[1,k] * PesoAdaptacao[k,j];
  End;
  Ativacao[2,j] := 1 / (1 + exp(-soma_entrada));
End;
For j := 1 To Neuronios_Saida Do
Begin
  soma_intermediaria := BiasAdaptacao[Neuronios_Intermediario+j];
  For k := 1 To Neuronios_Intermediario Do
  Begin
    soma_intermediaria := soma_intermediaria + Ativacao[2,k] *
    PesoAdaptacao[Neuronios_Entrada+j,k];
  End;
//
//  Cálculo do Neurônio de Saída
//
  Ativacao[3,j] := 1 / (1 + exp(-soma_intermediaria));
End;
For k := Ordem_Var_Medida to 2 Do
Begin
  At[k] := At[k-1];
End;
At[1] := Ativacao[3,1];
For k := Ordem_Var_Medida+1 to Neuronios_Entrada Do
Begin
  At[k] := VetorAdaptacao [i+n,k];

```

```

End;
ObjetivoErro := ObjetivoErro + (At[1]-VetorAdaptacao[i+n-
1,Neuronios_Entrada+1])*(At[1]-VetorAdaptacao[i+n-
1,Neuronios_Entrada+1]);

End;
End;
// Fim da Rede Neural
For j := 1 To Neuronios_Saida Do
Begin
ObjetivoAdaptacao [2] := ObjetivoAdaptacao[2] + ObjetivoErro;
End;
End;
PesoAdaptacao[l,m]:=PesoAdaptacao[l,m] - delta_peso;
derivada[1,l,m] := (ObjetivoAdaptacao[2] - ObjetivoAdaptacao[1])/(2*delta_peso);

End;
End;
//
//Cálculo das Derivadas dos Pesos entre a Camada de Escondida e a Camada de Saída
//
For l := 1 to Neuronios_Intermediario do
Begin
For k := 1 to Neuronios_Saida do
Begin
PesoAdaptacao[k+Neuronios_Entrada,l] := PesoAdaptacao[k+Neuronios_Entrada,l] +
delta_peso;

ObjetivoAdaptacao[2] := 0;
For i := 1 To Tamanho_Janela_Movel Do
Begin
//Cálculo da Rede Neural
For j := 1 to Neuronios_Entrada do
Begin
At[j] := VetorAdaptacao[i,j];
End;
ObjetivoErro := 0;
For n := 1 to Horizonte_Predicao do
Begin
//
// Cálculo da Saída dos Neurônios da Camada de Entrada}
//
If ( i + n < Tamanho_Janela_Movel) then

```

```

Begin
  For j := 1 To Neuronios_Entrada Do
    Begin
      Ativacao[1,j] := At[j];
    End;
  //
  // Cálculo da Saída dos Neurônios da Camada Intermediária}
  //
  For j := 1 To Neuronios_Intermediario Do
    Begin
      soma_entrada := BiasAdaptacao[j];
      For m := 1 To Neuronios_Entrada Do
        Begin
          soma_entrada := soma_entrada + Ativacao[1,m] * PesoAdaptacao[m,j];
        End;
      Ativacao[2,j] := 1 / (1 + exp(-soma_entrada));
    End;
  For j := 1 To Neuronios_Saida Do
    Begin
      soma_intermediaria := BiasAdaptacao[Neuronios_Intermediario+j];
      For m := 1 To Neuronios_Intermediario Do
        Begin
          soma_intermediaria := soma_intermediaria + Ativacao[2,m] *
            PesoAdaptacao[Neuronios_Entrada+j,m];
        End;
      //
      // Cálculo do Neurônio de Saída
      //
      Ativacao[3,j] := 1 / (1 + exp(-soma_intermediaria));
    End;
  For m := Ordem_Var_Medida to 2 Do
    Begin
      At[m] := At[m-1];
    End;
  At[1] := Ativacao[3,1];
  For m := Ordem_Var_Medida+1 to Neuronios_Entrada Do
    Begin
      At[m] := VetorAdaptacao [i+n,m];
    End;

```

```

ObjetivoErro      :=      ObjetivoErro      +      (At[1]-VetorAdaptacao[i+n-
                        1,Neuronios_Entrada+1])*(At[1]-VetorAdaptacao[i+n-
                        1,Neuronios_Entrada+1]);

End;
End;
// Fim da Rede Neural
For j := 1 To Neuronios_Saida Do
Begin
ObjetivoAdaptacao[2] := ObjetivoAdaptacao[2] + ObjetivoErro;
End;
End;
PesoAdaptacao[k+Neuronios_Entrada,1] := PesoAdaptacao[k+Neuronios_Entrada,1] -
                        delta_peso;
derivada[2,1,k] := (ObjetivoAdaptacao[2] - ObjetivoAdaptacao[1])/(2*delta_peso);
End;
End;
For i := 1 to Neuronios_Entrada do
Begin
For j := 1 to Neuronios_Intermediario do
Begin
PesoAdaptacao[i,j] := PesoAdaptacao[i,j] - passo*derivada[1,i,j];
End;
End;
For i := 1 to Neuronios_Intermediario do
Begin
For j := 1 to Neuronios_Saida do
Begin
PesoAdaptacao[j+Neuronios_Entrada,1] := PesoAdaptacao[j+Neuronios_Entrada,1] -
                        passo*derivada[2,i,j];

End;
End;
End;
//
//Fim do Treinamento On Line (algoritmo adaptativo)
If Amostra > Trunc(1.5*Tamanho_Janela_Movel) Then
Begin
ledAdaptativo.Enabled := True;
For i := 1 to Neuronios_Entrada Do
Begin
For j := 1 to Neuronios_Intermediario Do

```

```

Begin
    w[i,j] := PesoAdaptacao[i,j];
End;
End;
For i := 1 to Neuronios_Intermediario Do
Begin
    Bias[i] := BiasAdaptacao[i];
End;
For i := Neuronios_Entrada+1 To Neuronios_Entrada+Neuronios_Saida Do
Begin
    For j := 1 To Neuronios_Intermediario Do
    Begin
        w[i,j] := PesoAdaptacao[i,j];
    End;
    End;
    For j := Neuronios_Intermediario+1 to Neuronios_Intermediario+Neuronios_Saida Do
    Begin
        Bias[j] := BiasAdaptacao[j];
    End;
End
Else
Begin
    ledAdaptativo.Enabled := False;
    For i := 1 to Neuronios_Entrada Do
    Begin
        For j := 1 to Neuronios_Intermediario Do
        Begin
            w[i,j] := PesoFixo[i,j];
        End;
    End;
    End;
    For i := 1 to Neuronios_Intermediario Do
    Begin
        Bias[i] := BiasFixo[i];
    End;
    For i := Neuronios_Entrada+1 To Neuronios_Entrada+Neuronios_Saida Do
    Begin
        For j := 1 To Neuronios_Intermediario Do
        Begin
            w[i,j] := PesoFixo[i,j];
        End;
    End;

```

```

End;
For j := Neuronios_Intermediario+1 to Neuronios_Intermediario+Neuronios_Saida Do
Begin
    Bias[j] := BiasFixo[j];
End;
End;
End
Else
Begin
    ledAdaptativo.Enabled := False;
    For i := 1 to Neuronios_Entrada Do
    Begin
        For j := 1 to Neuronios_Intermediario Do
        Begin
            PesoAdaptacao[i,j] := PesoFixo[i,j];
            w[i,j] := PesoFixo[i,j];
        end;
    end;
    For i := 1 to Neuronios_Intermediario Do
    Begin
        BiasAdaptacao[i] := BiasFixo[i];
    end;
    For i := Neuronios_Entrada+1 To Neuronios_Entrada+Neuronios_Saida Do
    Begin
        For j := 1 To Neuronios_Intermediario Do
        Begin
            PesoAdaptacao[i,j] := PesoFixo[i,j];
            w[i,j] := PesoFixo[i,j];
        end;
    end;
    For j := Neuronios_Intermediario+1 to Neuronios_Intermediario+Neuronios_Saida Do
    Begin
        BiasAdaptacao[j] := BiasFixo[j];
    end;
End;
End
Else
Begin
    If Tempo > Trunc(1.5*Tamanho_Janela_Movel) Then
    Begin

```

```

//Treinamento da Rede Neural
//
//Cálculo da direção de busca
//
delta_peso := 0.001;
passo := 0.0001;
For epocas := 1 to 300 Do
Begin
//
//Cálculo da Função Objetivo
//
Objetivo_Anterior[1] := ObjetivoAdaptacao[1];
ObjetivoAdaptacao[1] := 0;
ObjetivoAdaptacao[2] := 0;
For i := 1 To Tamanho_Janela_Movel Do
Begin
//Inicio da Rede Neural
For j := 1 to Neuronios_Entrada do
Begin
At[j] := VetorAdaptacao[i,j];
End;
ObjetivoErro := 0;
For l := 1 to Horizonte_Predicao do
Begin
// Cálculo da Saída dos Neurônios da Camada de Entrada}
//
If ( i + 1 < Tamanho_Janela_Movel) then
Begin
For j := 1 To Neuronios_Entrada Do
Begin
Ativacao[1,j] := At[j];
End;
//
// Cálculo da Saída dos Neurônios da Camada Intermediária}
//
For j := 1 To Neuronios_Intermediario Do
Begin
soma_entrada := BiasAdaptacao[j];
For k := 1 To Neuronios_Entrada Do
Begin

```

```

        soma_entrada := soma_entrada + Ativacao[1,k] * PesoAdaptacao[k,j];
    End;
    Ativacao[2,j] := 1 / (1 + exp(-soma_entrada));
End;
For j := 1 To Neuronios_Saida Do
Begin
    soma_intermediaria := BiasAdaptacao[Neuronios_Intermediario+j];
    For k := 1 To Neuronios_Intermediario Do
    Begin
        soma_intermediaria := soma_intermediaria + Ativacao[2,k] *
            PesoAdaptacao[Neuronios_Entrada+j,k];
    End;
    //
    //   Cálculo do Neurônio de Saída
    //
    Ativacao[3,j] := 1 / (1 + exp(-soma_intermediaria));
End;
For k := Ordem_Var_Medida to 2 Do
Begin
    At[k] := At[k-1];
End;
At[1] := Ativacao[3,1];
For k := Ordem_Var_Medida+1 to Neuronios_Entrada Do
Begin
    At[k] := VetorAdaptacao [i+1,k];
End;
ObjetivoErro      :=      ObjetivoErro      +      (At[1]-VetorAdaptacao[i+1-
        1,Neuronios_Entrada+1])*(At[1]-VetorAdaptacao[i+1-
        1,Neuronios_Entrada+1]);

    End;
End;
//
//Fim da Rede Neural
//
For j := 1 To Neuronios_Saida Do
Begin
    ObjetivoAdaptacao [1] := ObjetivoAdaptacao[1] + ObjetivoErro;
End;
End;

```

```

If Objetivo_Anterior[1] < ObjetivoAdaptacao[1] then
Begin
    passo := passo/1.2;
End;
For l := 1 to Neuronios_Entrada do
Begin
    For m := 1 to Neuronios_Intermediario do
    Begin
        PesoAdaptacao[l,m]:=PesoAdaptacao[l,m] + delta_peso;
        ObjetivoAdaptacao[2]:=0;
        For i := 1 To Tamanho_Janela_Movel Do
        Begin
            //Cálculo da Rede Neural
            For j := 1 to Neuronios_Entrada do
            Begin
                At[j] := VetorAdaptacao[i,j];
            End;
            ObjetivoErro := 0;
            For n := 1 to Horizonte_Predicao do
            Begin
                //
                //  Cálculo da Saída dos Neurônios da Camada de Entrada}
                //
                If ( i + n < Tamanho_Janela_Movel) then
                Begin
                    For j := 1 To Neuronios_Entrada Do
                    Begin
                        Ativacao[1,j] := At[j];
                    End;
                    //
                    //  Cálculo da Saída dos Neurônios da Camada Intermediária}
                    //
                    For j := 1 To Neuronios_Intermediario Do
                    Begin
                        soma_entrada := BiasAdaptacao[j];
                        For k := 1 To Neuronios_Entrada Do
                        Begin
                            soma_entrada := soma_entrada + Ativacao[1,k] * PesoAdaptacao[k,j];
                        End;
                        Ativacao[2,j] := 1 / (1 + exp(-soma_entrada));
                    End;
                End;
            End;
        End;
    End;
End;

```

```

End;
For j := 1 To Neuronios_Saida Do
Begin
  soma_intermediaria := BiasAdaptacao[Neuronios_Intermediario+j];
  For k := 1 To Neuronios_Intermediario Do
  Begin
    soma_intermediaria := soma_intermediaria + Ativacao[2,k] *
                          PesoAdaptacao[Neuronios_Entrada+j,k];
  End;
  //
  // Cálculo do Neurônio de Saída
  //
  Ativacao[3,j] := 1 / (1 + exp(-soma_intermediaria));
End;
For k := Ordem_Var_Medida to 2 Do
Begin
  At[k] := At[k-1];
End;
At[1] := Ativacao[3,1];
For k := Ordem_Var_Medida+1 to Neuronios_Entrada Do
Begin
  At[k] := VetorAdaptacao [i+n,k];
End;
ObjetivoErro := ObjetivoErro + (At[1]-VetorAdaptacao[i+n-
1,Neuronios_Entrada+1])*(At[1]-VetorAdaptacao[i+n-
1,Neuronios_Entrada+1]);
End;
End;
// Fim da Rede Neural
For j := 1 To Neuronios_Saida Do
Begin
  ObjetivoAdaptacao [2] := ObjetivoAdaptacao[2] + ObjetivoErro;
End;
End;
PesoAdaptacao[l,m]:=PesoAdaptacao[l,m] - delta_peso;
derivada[1,l,m] := (ObjetivoAdaptacao[2] - ObjetivoAdaptacao[1])/(2*delta_peso);

End;
End;
//
//Cálculo das Derivadas dos Pesos entre a Camada de Escondida e a Camada de Saída

```

```

//
For l := 1 to Neuronios_Intermediario do
Begin
  For k := 1 to Neuronios_Saida do
  Begin
    PesoAdaptacao[k+Neuronios_Entrada,l] := PesoAdaptacao[k+Neuronios_Entrada,l] +
                                          delta_peso;

    ObjetivoAdaptacao[2] := 0;
    For i := 1 To Tamanho_Janela_Movel Do
    Begin
      //Cálculo da Rede Neural
      For j := 1 to Neuronios_Entrada do
      Begin
        At[j] := VetorAdaptacao[i,j];
      End;
      ObjetivoErro := 0;
      For n := 1 to Horizonte_Predicao do
      Begin
        //
        // Cálculo da Saída dos Neurônios da Camada de Entrada}
        //
        If ( i + n < Tamanho_Janela_Movel) then
        Begin
          For j := 1 To Neuronios_Entrada Do
          Begin
            Ativacao[1,j] := At[j];
          End;
          //
          // Cálculo da Saída dos Neurônios da Camada Intermediária}
          //
          For j := 1 To Neuronios_Intermediario Do
          Begin
            soma_entrada := BiasAdaptacao[j];
            For m := 1 To Neuronios_Entrada Do
            Begin
              soma_entrada := soma_entrada + Ativacao[1,m] * PesoAdaptacao[m,j];
            End;
            Ativacao[2,j] := 1 / (1 + exp(-soma_entrada));
          End;
          For j := 1 To Neuronios_Saida Do

```

```

Begin
  soma_intermediaria := BiasAdaptacao[Neuronios_Intermediario+j];
  For m := 1 To Neuronios_Intermediario Do
    Begin
      soma_intermediaria := soma_intermediaria + Ativacao[2,m] *
        PesoAdaptacao[Neuronios_Entrada+j,m];
    End;
  //
  // Cálculo do Neurônio de Saída
  //
  Ativacao[3,j] := 1 / (1 + exp(-soma_intermediaria));
End;
For m := Ordem_Var_Medida to 2 Do
  Begin
    At[m] := At[m-1];
  End;
At[1] := Ativacao[3,1];
For m := Ordem_Var_Medida+1 to Neuronios_Entrada Do
  Begin
    At[m] := VetorAdaptacao [i+n,m];
  End;
  ObjetivoErro := ObjetivoErro + (At[1]-VetorAdaptacao[i+n-
    1,Neuronios_Entrada+1])*(At[1]-VetorAdaptacao[i+n-
    1,Neuronios_Entrada+1]);
End;
End;
// Fim da Rede Neural
For j := 1 To Neuronios_Saida Do
  Begin
    ObjetivoAdaptacao[2] := ObjetivoAdaptacao[2] + ObjetivoErro;
  End;
End;
PesoAdaptacao[k+Neuronios_Entrada,1] := PesoAdaptacao[k+Neuronios_Entrada,1] -
  delta_peso;
derivada[2,1,k] := (ObjetivoAdaptacao[2] - ObjetivoAdaptacao[1])/(2*delta_peso);
End;
End;
For i := 1 to Neuronios_Entrada do
  Begin
    For j := 1 to Neuronios_Intermediario do

```

```

Begin
  PesoAdaptacao[i,j] := PesoAdaptacao[i,j] - passo*derivada[1,i,j];
End;
End;
For i := 1 to Neuronios_Intermediario do
Begin
  For j := 1 to Neuronios_Saida do
  Begin
    PesoAdaptacao[j+Neuronios_Entrada,1] := PesoAdaptacao[j+Neuronios_Entrada,1] -
    passo*derivada[2,i,j];

  End;
End;
End;
//
//Fim do Treinamento On Line (algoritmo adaptativo)
//
If Tempo > Trunc(1.5*Tamanho_Janela_Move) Then
Begin
  ledAdaptativo.Enabled := True;
  For i := 1 to Neuronios_Entrada Do
  Begin
    For j := 1 to Neuronios_Intermediario Do
    Begin
      w[i,j] := PesoAdaptacao[i,j];
    End;
  End;
  For i := 1 to Neuronios_Intermediario Do
  Begin
    Bias[i] := BiasAdaptacao[i];
  End;
  For i := Neuronios_Entrada+1 To Neuronios_Entrada+Neuronios_Saida Do
  Begin
    For j := 1 To Neuronios_Intermediario Do
    Begin
      w[i,j] := PesoAdaptacao[i,j];
    End;
  End;
  For j := Neuronios_Intermediario+1 to Neuronios_Intermediario+Neuronios_Saida Do
  Begin
    Bias[j] := BiasAdaptacao[j];

```

```

End;
End
Else
Begin
  ledAdaptativo.Enabled := False;
  For i := 1 to Neuronios_Entrada Do
  Begin
    For j := 1 to Neuronios_Intermediario Do
    Begin
      w[i,j] := PesoFixo[i,j];
    End;
  End;
  For i := 1 to Neuronios_Intermediario Do
  Begin
    Bias[i] := BiasFixo[i];
  End;
  For i := Neuronios_Entrada+1 To Neuronios_Entrada+Neuronios_Saida Do
  Begin
    For j := 1 To Neuronios_Intermediario Do
    Begin
      w[i,j] := PesoFixo[i,j];
    End;
  End;
  For j := Neuronios_Intermediario+1 to Neuronios_Intermediario+Neuronios_Saida Do
  Begin
    Bias[j] := BiasFixo[j];
  End;
End;
End
Else
Begin
  ledAdaptativo.Enabled := False;
  For i := 1 to Neuronios_Entrada Do
  Begin
    For j := 1 to Neuronios_Intermediario Do
    Begin
      PesoAdaptacao[i,j] := PesoFixo[i,j];
      w[i,j] := PesoFixo[i,j];
    end;
  end;
end;
end;

```

```

For i := 1 to Neuronios_Intermediario Do
Begin
  BiasAdaptacao[i] := BiasFixo[i];
end;
For i := Neuronios_Entrada+1 To Neuronios_Entrada+Neuronios_Saida Do
Begin
  For j := 1 To Neuronios_Intermediario Do
  Begin
    PesoAdaptacao[i,j] := PesoFixo[i,j];
    w[i,j] := PesoFixo[i,j];
  end;
end;
For j := Neuronios_Intermediario+1 to Neuronios_Intermediario+Neuronios_Saida Do
Begin
  BiasAdaptacao[j] := BiasFixo[j];
end;
End;
End;
//Cálculo da Ações de Controle
// Algoritmos Genéticos
If (AlgoritmosGenticos1.Checked) Then
Begin
End;
//Fim do Algoritmo Genético
//Método Backpropagation Não Adaptativo
If (Gradiente1.Checked) Then
Begin
End;
//Método Backpropagation Adaptativo
If (Simplex1.Checked) Then
Begin
  delta := 0.05;
  //Atualização das Entradas da Rede
  For i:= 1 to Ordem_Var_Medida Do
  Begin
    y[i] := Janela[1,i];
  End;
  For i := 1 to Ordem_Var_Manipulada Do
  Begin
    u[i] := Janela[2,i];
  End;
  End;
End;

```

```

End;
erro[3] := erro[2];
erro[2] := yref[1] - A_Normal*Entrada[1] - B_Normal;
erro[1] := y[1] - Predicao[1];
Objetivo[1] := Lambda*(0.12*OutVolts[1]+0.2-u[1])*(0.12*OutVolts[1]+0.2-u[1]);
//Cálculo da rede neural
For j := 1 to Horizonte_Predicao Do
Begin
  For i := 1 to Ordem_Var_Medida Do
  Begin
    At[i] := y[i];
  End;
  For i:= 1 to Ordem_Var_Manipulada Do
  Begin
    At[Ordem_Var_Medida+i] := u[i];
  End;
  For i:= 1 to Neuronios_Intermediario Do
  Begin
    Soma[i] := Bias[i];
    For l := 1 to Neuronios_Entrada Do
    Begin
      Soma[i] := Soma[i] + At[l]*w[l,i];
    End;
  End;
  For i:= Neuronios_Entrada+1 to Neuronios_Entrada+Neuronios_Intermediario Do
  Begin
    At[i] := 1/(1+ Exp(-Soma[i-Neuronios_Entrada]));
  End;
  Soma[Neuronios_Entrada+Neuronios_Intermediario+1] := Bias[Neuronios_Intermediario+1];
  For i := 1 to Neuronios_Intermediario Do
  Begin
    Soma[Neuronios_Entrada+Neuronios_Intermediario+1]
                                                    :=
                                                    Soma[Neuronios_Entrada+Neuron
ios_Intermediario+1]
                                                    +
                                                    At[Neuronios_Entrada+i]
                                                    *
                                                    w[Neuronios_Entrada+1,i];
  End;
  At[Neuronios_Entrada+Neuronios_Intermediario+1] := 1/(1+Exp(-Soma[Neuronios_Entrada +
Neuronios_Intermediario+1]));
  Predicao[j] := At[Neuronios_Entrada+Neuronios_Intermediario+1];

```

```

Objetivo[1] := Objetivo[1] + Beta*(yref[j]-Predicao[j]-erro[1])*(yref[j]-Predicao[j]-erro[1]);
For i := Ordem_Var_Medida to 2 Do
Begin
  y[i] := y[i-1];
End;
y[1] := At[Neuronios_Entrada+Neuronios_Intermediario+1];
If Ordem_Var_Manipulada > 1 Then
Begin
  For i := Ordem_Var_Manipulada to 2 Do
  Begin
    u[i] := u[i-1];
  End;
End;
u[1] := acao_controle[1];
End;
//Fim da rede neural
//Cálculo da ação de controle
For iteracao := 1 to 25000 Do
Begin
  acao_controle[1] := acao_controle[1] + deltau;
  Objetivo[1] := Lambda*(0.12*OutVolts[1]+0.2-acao_controle[1])*(0.12*OutVolts[1]+0.2-
    acao_controle[1]);
  //Atualização das Entradas da Rede
  For i := 1 to Ordem_Var_Medida Do
  Begin
    y[i] := Janela[1,i];
  End;
  For i := 1 to Ordem_Var_Manipulada Do
  Begin
    u[i] := Janela[2,i];
  End;
  For j := 1 to Horizonte_Predicao Do
  Begin
    For i := 1 to Ordem_Var_Medida Do
    Begin
      At[i] := y[i];
    End;
    For i:= 1 to Ordem_Var_Manipulada Do
    Begin
      At[Ordem_Var_Medida+i] := u[i];
    End;
  End;
End;

```

```

End;
for i:= 1 to Neuronios_Intermediario Do
begin
  Soma[i] := Bias[i];
  for m := 1 to Neuronios_Entrada Do
  begin
    Soma[i] := Soma[i] + At[m]*w[m,i];
  end;
end;
for i:= Neuronios_Entrada+1 to Neuronios_Entrada+Neuronios_Intermediario Do
begin
  At[i] := 1/(1+ Exp(-Soma[i-Neuronios_Entrada]));
end;
Soma[Neuronios_Entrada+Neuronios_Intermediario+1] :=
  Bias[Neuronios_Intermediario+1];

for i := 1 to Neuronios_Intermediario Do
begin
  Soma[Neuronios_Entrada+Neuronios_Intermediario+1] := Soma[Neuronios_Entrada +
  Neuronios_Intermediario+1]
  + At[Neuronios_Entrada+i] *
  w[Neuronios_Entrada+1,i];
end;
At[Neuronios_Entrada+Neuronios_Intermediario+1] := 1/(1+Exp(-Soma[Neuronios_Entrada
+ Neuronios_Intermediario+1]));
Predicao[j] := At[Neuronios_Entrada+Neuronios_Intermediario+1];
Objetivo[1] := Objetivo[1] + Beta*(yref[j]-Predicao[j]-erro[1])*(yref[j]-Predicao[j]-erro[1]);
For i := Ordem_Var_Medida to 2 Do
Begin
  y[i] := y[i-1];
End;
y[1] := At[Neuronios_Entrada+Neuronios_Intermediario+1];
If Ordem_Var_Manipulada > 1 Then
Begin
  For i := Ordem_Var_Manipulada to 2 Do
  Begin
    u[i] := u[i-1];
  End;
End;
u[1] := acao_controle[1];

```

```

end;
acao_controle[1] := acao_controle[1] - deltau;
acao_controle[1] := acao_controle[1] - deltau;
Objetivo_Back[1] := Lambda*(0.12*OutVolts[1]+0.2-
acao_controle[1])*(0.12*OutVolts[1]+0.2-acao_controle[1]);

//Atualização das Entradas da Rede
For i := 1 to Ordem_Var_Medida Do
Begin
y[i] := Janela[1,i];
End;
For i := 1 to Ordem_Var_Manipulada Do
Begin
u[i] := Janela[2,i];
End;
For j := 1 to Horizonte_Predicao Do
Begin
For i := 1 to Ordem_Var_Medida Do
Begin
At[i] := y[i];
End;
For i:= 1 to Ordem_Var_Manipulada Do
Begin
At[Ordem_Var_Medida+i] := u[i];
End;
for i:= 1 to Neuronios_Intermediario Do
begin
Soma[i] := Bias[i];
for m := 1 to Neuronios_Entrada Do
begin
Soma[i] := Soma[i] + At[m]*w[m,i];
end;
end;
for i:= Neuronios_Entrada+1 to Neuronios_Entrada+Neuronios_Intermediario Do
begin
At[i] := 1/(1+ Exp(-Soma[i-Neuronios_Entrada]));
end;
Soma[Neuronios_Entrada+Neuronios_Intermediario+1] :=
Bias[Neuronios_I
ntermediario+1];

```

```

for i := 1 to Neuronios_Intermediario Do
begin
  Soma[Neuronios_Entrada+Neuronios_Intermediario+1] := Soma[Neuronios_Entrada +
  Neuronios_Intermediario+1] +
  At[Neuronios_Entrada+i] *
  w[Neuronios_Entrada+1,i];

end;
At[Neuronios_Entrada+Neuronios_Intermediario+1] := 1/(1+Exp(-Soma[Neuronios_Entrada
+ Neuronios_Intermediario+1]));
Predicao[j] := At[Neuronios_Entrada+Neuronios_Intermediario+1];
Objetivo_Back[1] := Objetivo_Back[1] + Beta*(yref[j]-Predicao[j]-erro[1])*(yref[j]-
Predicao[j]-erro[1]);
For i := Ordem_Var_Medida to 2 Do
Begin
  y[i] := y[i-1];
End;
y[1] := At[Neuronios_Entrada+Neuronios_Intermediario+1];
If Ordem_Var_Manipulada > 1 Then
Begin
  For i := Ordem_Var_Manipulada to 2 Do
  Begin
    u[i] := u[i-1];
  End;
End;
u[1] := acao_controle[1];
end;
acao_controle[1] := acao_controle[1] + deltau;
acao_controle[1] := acao_controle[1] - 0.001*(Objetivo[1] - Objetivo_Back[1])/deltau;

If acao_controle[1] > 0.8 then acao_controle[1] := 0.8;
If acao_controle[1] < 0.2 then acao_controle[1] := 0.205;
//Fim das Iterações
End;
//Atualização das Entradas da Rede
For i:= 1 to Ordem_Var_Medida Do
Begin
  y[i] := Janela[1,i];
End;
For i := 1 to Ordem_Var_Manipulada Do
Begin
  u[i] := acao_controle[1];

```

```

end;
//Cálculo da rede neural
For j := 1 to Horizonte_Predicao Do
Begin
  For i := 1 to Ordem_Var_Medida Do
  Begin
    At[i] := y[i];
  End;
  For i:= 1 to Ordem_Var_Manipulada Do
  Begin
    At[Ordem_Var_Medida+i] := u[i];
  End;
  for i:= 1 to Neuronios_Intermediario Do
  begin
    Soma[i] := Bias[i];
    for l := 1 to Neuronios_Entrada Do
    begin
      Soma[i] := Soma[i] + At[l]*w[l,i];
    end;
  end;
  for i:= Neuronios_Entrada+1 to Neuronios_Entrada+Neuronios_Intermediario Do
  begin
    At[i] := 1/(1+ Exp(-Soma[i-Neuronios_Entrada]));
  end;
  Soma[Neuronios_Entrada+Neuronios_Intermediario+1] := Bias[Neuronios_Intermediario+1];
  for i := 1 to Neuronios_Intermediario Do
  begin
    Soma[Neuronios_Entrada+Neuronios_Intermediario+1] := Soma[Neuronios_Entrada +
      Neuronios_Intermediario+1] +
      At[Neuronios_Entrada+i] *
      w[Neuronios_Entrada+1,i];
  end;
  At[Neuronios_Entrada+Neuronios_Intermediario+1] := 1/(1+Exp(-Soma[Neuronios_Entrada +
    Neuronios_Intermediario+1]));
  Predicao[j] := At[Neuronios_Entrada+Neuronios_Intermediario+1];
  For i := Ordem_Var_Medida to 2 Do
  Begin
    y[i] := y[i-1];
  End;
  y[1] := At[Neuronios_Entrada+Neuronios_Intermediario+1];

```

```

For i := Ordem_Var_Manipulada to 2 Do
Begin
  u[i] := u[i-1];
End;
u[1] := acao_controle[1];
end;
//Fim da rede neural
Series14.Clear;
Series15.Clear;
Series16.Clear;
Series17.Clear;
For i := 1 to Horizonte_Predicao Do
Begin
  Series14.Add(Predicao[i]+erro[1]);
  Series15.Add(yref[i]);
  Series16.Add(acao_controle[1]);
  Series17.Add(erro[1]);
End;
//Implementação da ação de controle
OutVolts[1] := (acao_controle[1]-0.2)/0.12;
If OutVolts[1] > 5 Then OutVolts[1] := 5;
If OutVolts[1] <= 0 Then OutVolts[1] := 0.1;
Saida := 20*Volts;
End;
//Método de Rosenbrock
IF (Rosenbrock1.Checked) Then
Begin
End;
//Fim do Método de Rosenbrock
//Um Passo a Frente
IF (Umpassoafrente1.Checked) Then
Begin
End;
End;

```

## Anexo A 3

# Influência Qualitativa da Temperatura e do Tempo de Reação nos Produtos Gasosos da Pirólise de Borra de Tinta

---

Temperatura de Reação (°C)	Tempo de Reação (min)	Produtos						
		Ar	CH <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	C <sub>3</sub> H <sub>8</sub>	C <sub>3</sub> H <sub>6</sub>
450	10	31,91	4,38	1,89	10,23	49,12	1,69	0,78
650	10	15,28	43,54	5,9	2,88	27,61	3,39	1,4
450	90	32,17	6,46	2,68	7,56	47,52	2,27	1,35
650	90	15,43	42,40	3,61	2,92	33,61	1,02	1,02
550	50	19,21	23,43	10,14	6,01	33,74	3,54	3,92
550	50	21,17	23,04	8,95	5,23	35,19	3,06	3,36

## Anexo A 4

# Influência Qualitativa da Temperatura e do Tempo de Reação nos Produtos Líquidos da Pirólise de Borra de Tinta

---

Temperatura de Reação (°C)	Tempo de Reação (min)	Produtos							
		Parafinas	<i>Olefinas</i>	Naftênicos	Aromáticos	Cetonas	Éster	Álcool	Outros
450	10	2.70	0.00	0.00	63.80	16.61	13.11	2.84	0.95
650	10	2.97	0.00	0.00	65.98	10.60	11.34	7.23	1.87
450	90	1.61	0.00	0.00	67.23	11.62	10.84	7.93	0.77
650	90	4.91	0.00	0.00	71.11	8.43	9.16	10.08	1.23
550	50	0.00	0.00	0.00	63.35	11.99	14.53	4.36	0.86
550	50	0.00	0.00	0.00	73.81	6.41	10.99	7.63	1.16

## Anexo A 5

# Caracterização Física do Óleo Obtido pela Pirólise da Borra de Tinta

---

Temperatura (°C)	Tempo (min)	Poder Calorífico Inferior (cal/g)	Viscosidade (cSt)	Massa Específica (g/cm <sup>3</sup> )	Ponto de Fulgor (°C)
450	90	9222.20	64.18	0.888	25
550	90	9296.44	28.61	0.877	23
650	90	9725.14	30.31	0.916	20

## Anexo A 6

# Influência da Temperatura e Tempo de Batelada Sobre o Rendimento do Óleo de Pirólise da Borra de Tinta

---

