

Dissertação de Mestrado

APLICAÇÃO A UM REATOR DE HIDROTRATAMENTO DE MÉTODO DE DETECÇÃO E DIAGNÓSTICO DE FALHAS BASEADO EM MODELO

Giovani Santos Correia da Silva

Universidade Federal do Rio de Janeiro
Escola de Química
Pós-graduação em Tecnologia de Processos Químicos e Bioquímicos

Orientadores: Maurício Bezerra de Souza Júnior D. Sc. Enrique Luís Lima D. Sc.

Rio de Janeiro 2008 Aplicação A Um Reator de Hidrotratamento de Método de Detecção e Diagnóstico de Falhas Baseado em Modelo

Giovani Santos Correia da Silva

Dissertação submetida ao corpo docente da Coordenação do Programa de Pós-Graduação em Tecnologia de Processos Químicos e Bioquímicos da Escola de Química da Universidade Federal do Rio de Janeiro - UFRJ, como parte dos requisitos necessários à obtenção do grau de Mestre em Ciências.

Aprovada por:		
	Prof. Maurício Bezerra de Souza Júnior (Orientador), D.Sc.	
	Prof. Enrique Luis Lima (Co-Orientador), D.Sc.	
	Prof. Amaro Gomes Barreto Junior, D. Sc.	
	Mário César Mello Massa Campos, D. Sc	

Rio de Janeiro, RJ-Brasil 2008

Prof. Domingos Fabiano de Santana Souza, D. Sc

Correia da Silva, Giovani Santos

Aplicação A Um Reator De Hidrotratamento De Método De Detecção E Diagnóstico De Falhas Baseado Em Modelo – Rio de Janeiro, 2008.

xx, 156 f. il

Dissertação (Mestrado em Tecnologia de Processos Químicos e Bioquímicos) - Universidade Federal do Rio de Janeiro – UFRJ, Escola de Química (EQ), 2008.

Orientador: Maurício Bezerra de Souza Jr.

- 1. Detecção e Diagnóstico de Falhas 2. Polinômio de Laguerre.
- 3. Redes Neuronais Teses. I. De Souza Jr., Maurício B. (Orient.). II. Pós-Graduação em Engenharia Química III. Título.

Para a minha esposa, Anie

Daniela Medeiros Lima.

"A beleza não está naquilo que vemos, mas no que sentimos e almejamos para nossas vidas."

AGRADECIMENTOS

Começo agradecendo aos meus pais, José Gilvan Correia da Silva e Maria de Lourdes Santos Correia, por todo o apoio dado em todas as etapas da minha vida;

Agradeço também, aos meus sogros, Daniel Medeiros Lima e Anie Ernestine Duque Lima, pelos ensinamentos e incentivos destinados ao meu crescimento pessoal e a finalização deste trabalho.

Como não poderia deixar de ser, agradeço especialmente a pessoa que tem estado ao meu lado de perto, em todos os momentos da minha vida, seja em pensamentos, desejos ou aspirações, desde um encontro casual em março de 1998, a minha esposa, Anie Daniela, pela contribuição, incentivo, amorosidade, carinho, compreensão e sobretudo, paciência, colaborando de forma primordial para a conclusão desta dissertação de Mestrado;

Aos meus colegas da Gerência de Engenharia de Projetos do Abastecimento e Gás e Energia, em especial a Victor Rolando Ruiz Ahón, do Centro de Pesquisas da PETROBRAS, que me auxiliaram na execução prática do presente trabalho;

Aos Professores Maurício e Enrique, pela orientação e sugestões dedicadas à elaboração, desenvolvimento e conclusão deste trabalho;

RESUMO

CORREIA DA SILVA, Giovani Santos. Aplicação A Um Reator De Hidrotramento De Método De Detecção E Diagnóstico De Falhas Baseado Em Modelo. Orientador: Maurício Bezerra de Souza Jr. Rio de Janeiro: UFRJ/ EQ; 2008. Dissertação (Mestrado em Tecnologia de Processos Químicos e Bioquímicos).

Apresenta-se o desenvolvimento de um sistema de detecção e diagnóstico de falhas (FDD) baseado em modelo de processo, aplicado a uma unidade simulada de hidrotratamento (HDT) de diesel combustível. A abordagem FDD proposta classifica, usando uma técnica baseada na distância geométrica, as discrepâncias (expressas como resíduos) entre o comportamento real do processo - representado por um modelo fenomenológico da literatura – e aquele do modelo empírico desenvolvido. Considerando-se que o modelo do processo deve apresentar capacidade de representação dos dados reais e rapidez na sua resolução numérica, foram comparados dois modelos alternativos: função de transferência clássica, utilizando redes neuronais para a predição de seus parâmetros, e função de Laguerre, empregando as técnicas de *lookup table* e interpolação para o cálculo dos seus parâmetros. O modelo baseado em funções de Laguerre se revelou mais aderente ao modelo fenomenológico e foi escolhido como modelo do processo. Para o estudo de FDD, foram simulados 16 casos que incluíam condições operacionais normais e perturbações nas variáveis de entrada (vazão e concentração de alimentação) do primeiro reator de hidrotratamento, para o qual a temperatura de saída foi medida. Cartas de controle univariáveis auxiliares (Shewhart, CUSUM e MMEP) dos resíduos foram investigadas, pois elas detectam quando o processo sai de controle, acionando o algoritmo classificador. Exemplos foram apresentados nos quais o sistema FDD desenvolvido foi capaz de classificar corretamente os 16 casos simulados e 4 casos novos, usando dados de uma janela de 30 minutos.

PALAVRAS CHAVE

Detecção de Diagnóstico de Falhas, Funções de Laguerre, Redes Neuronais.

ABSTRACT

CORREIA DA SILVA, Giovani Santos. Aplicação a um Reator de Hidrotramento de Método de Detecção e Diagnóstico de Falhas Baseado em Modelo. Orientador: Maurício Bezerra de Souza Jr. Rio de Janeiro: UFRJ/ EQ; 2008. Dissertação (Mestrado em Tecnologia de Processos Químicos e Bioquímicos).

The industries lose large amounts of money with faults and defects that could be prevented if their plants worked under acceptable operation conditions. In this scenario, the importance of early fault detection and diagnosis (FDD) is magnified. This document presents the development of a quantitative model-based FDD approach for fault detection and diagnosis of a simulated diesel fuel hydrotreating (HDT) unit. The proposed FDD approach classifies the discrepancies (expressed as residuals) between the actual system behaviour – represented by a phenomenological model from the literature – and that of the system model, using a geometric distance classification technique. Two alternative system models were compared: classical pre-defined transfer functions, with variable parameters given by neural networks, and Laguerre functions, with variable parameters given by interpolated lookup table values. The Laguerre functions were chosen as the system model, because they showed a better fit of the actual data given by the output reactor temperature. For the FDD study, disturbances in the input variables (flowrate and reactant concentration) of the first hydrogenation reactor were assumed and the HDT unit was simulated in order to generate 16 cases representing normal and abnormal (disturbed) operational conditions. Auxiliary univariate control charts (Shewhart, CUSUM and MMEP) of the residuals were investigated as they detect when the process is out of control triggering the FDD algorithm. Examples are shown in which the developed FDD system was able to correctly classifiy the 16 simulated cases and new ones, using data from a time window of 30 minutes.

KEY WORDS

Fault Detection and Diagnosis, Laguerre Function, Neural Networks

LISTA DE SIGLAS

AEM Gerenciamento de Eventos Anormais (Abnormal Event Management)

CENPES Centro de Pesquisas Leopoldo A. Miguez de Mello da PETROBRAS.

CEP Controle Estatístico de Processo

CSTR Reator de Mistura Perfeita (Continuosly Stirred Tank Reator)

CTB Craqueamento Térmico Brando

CUSUM Carta de Controle de Soma Cumulativa (*Cumulative Sum*)

EM Erro Médio

EMA Erro Médio Absoluto

FCC Craqueamento Fluido Catalítico (*Fluid Catalitic Craking*)

FDD Detecção e Diagnóstico de Falhas (Fault Detection and Diagnosis)

IPS Intelligent Problem Solver, módulo do "software" "Statistica" que permite

o desenvolvimento de redes neuronais.

LC Linha Central

LHSV Velocidade Espacial Mássica (*Liquid Hourly Space Velocity*)

LIC Limite Inferior de Controle

LSC Limite Superior de Controle

MMEP Média Móvel Exponencialmente Ponderada – Carta de Controle

MR Média Móvel

LISTA DE SÍMBOLOS

Símbolos Latinos

A	Área transversal dos leitos (m²) ou reagente A
a	Área superficial externa das partículas sólidas de catalisador por volume total do estágio (m ⁻¹) ou constante da derivada
b	Constante da função no domínio do tempo.
C	Concentração do reagente A na fase fluida (mol/m³)
C^+	Soma Cumulativa Superior
C ⁻	Soma Cumulativa Inferior
C_p	Calor específico do gás (J.kg ⁻¹ .K ⁻¹)
C_s	Concentração do reagente A nos poros internos das partículas (mol/m³)
c	Parâmetro da função de Laguerre.
c^{T}_{4}	Parâmetro da função de Laguerre para a perturbação na temperatura
$\mathbf{c}^{\mathrm{T}}_{5}$	Parâmetro da função de Laguerre para a perturbação na temperatura
c^{T}_{6}	Parâmetro da função de Laguerre para a perturbação na temperatura
c^{v}_{1}	Parâmetro da função de Laguerre para a perturbação na vazão
c^{v}_{2}	Parâmetro da função de Laguerre para a perturbação na vazão
c ^v ₃	Parâmetro da função de Laguerre para a perturbação na vazão
d_2	Valor tabelado para construção de gráfico de controle de Shewhart
$d_{\rm j}$	Distancia euclidiana entre o ponto dado e o valor de referencia para a obtenção do vizinho mais próximo no algoritmo de detecção de falhas.
e_i	Erro para cada variável de saída (diferença entre o valor alvo e o estimado)
E/R	Energia de ativação da reação (K ⁻¹)
f	Função de ativação para os neurônios ou função no domínio do tempo

\overline{f}	Entrada do processo no domínio de Laplace	
f_j	Coeficientes da equação dinâmica do forno	
F_{OBJ}	Função objetivo	
g	Representação geral para as vazões $g_m\ e\ g_t\ (m^3/s)$	
$g_{\rm m}$	Vazão volumétrica associada ao fluxo reverso de massa (m³/s)	
G(s)	Função de Transferência no domínio de Laplace	
$G_{T}(s)$	Função de transferência referente à perturbação na temperatura	
$G_{u}(s)$	Função de transferência referente à perturbação na vazão	
\mathbf{g}_{t}	Vazão volumétrica associada ao fluxo reverso de calor (m³/s)	
h	Valor numérico dos limites superior e inferior da Carta MMEP	
i	Contador do número de estágios (i=1 até 12) ou índice da Função de L Laguerre	
j	Neurônio	
k_0	Constante de Velocidade de reação (s ⁻¹)	
K	Valor de referência, tolerância ou folga do CUSUM	
K_g	Coeficiente de transporte de massa através da superfície externa das partículas de catalisador (s ⁻¹ /m ²)	
K_h	Fluxo adimensional reverso de energia	
K_{m}	Fluxo adimensional reverso de massa	
K_{P}^{T}	Ganho estático da função de transferência da temperatura de alimentação	
K_P^{v}	Ganho estático da função de transferência da vazão de alimentação	
L	Camada de saída da rede ou Função de Laguerre do domino de Laplace ou	
1	Comprimento total dos 2 leitos do reator Funções de Laguerre	
L_1	Comprimento do primeiro leito (m)	

Máx Valor máximo do conjunto da amostra

m/m Razão entre a massa da substância em questão e a massa da mistura.

MQ_{regressão} Média dos quadrados dos valores ajustados numa análise de variância.

MQ_{residuos} Média dos quadrados dos resíduos numa análise de variância.

n Número de variáveis a serem correlacionadas ou Número de estágios por

leito ou ordem da derivada.

n_h Número de neurônios na camada escondida.

n_i Número de neurônios na camada de entrada.

n_k Número de neurônios na camada de k.

n_L Número de neurônios na camada de saída.

N_p Número total de padrões para treinamento.

N Número inteiro finito que indica a ordem para o truncamento expansão da

Função de Laguerre

N_w Número de pesos somados aos limites de ativação interna dos neurônios de

uma rede.

p_p Pressão Parcial (bar)

p^T Parâmetro p da função de Laguerre para a perturbação na temperatura

p^v Parâmetro p da função de Laguerre para a perturbação na vazão

R² Coeficiente de determinação (regressão linear).

r_A Taxa de reação do reagente A (mol/s)

Rdo(i) Ruído randômico

R_i Resíduo

s Direção de busca para otimização ou tempo no domínio de Laplace.

s_j Ponto para o qual deseja-se determinar a distância euclidiana do classificador geométrico.

s_{ref,i} Ponto de referência para a determinação da distância euclidiana do classificador geométrico.

s_{pi,k} Saída ou ativação de um neurônio i da camada k, para um padrão p.

 $s_{pj,k+1}$ Resposta produzida pelo neurônio "j" para uma função de ativação f.

SQ_{regressão} Variância explicada pela regressão (soma dos quadrados dos valores

ajustados).

SQ_{resíduos} Variância não explicada pela regressão (soma dos quadrados resíduos).

t Tempo de escoamento ou Tempo de simulação (s).

T Temperatura (°C)

Te Temperatura do fluido (°C)

Te_f Temperatura do fluido na saída do forno (°C)

Te_{fin} Temperatura do fluido na entrada do forno (°C)

Te_q Temperatura do gás frio (°C)

T_F Temperatura final de saída estimada pelo modelo (°C)

t_{pl} Saída alvo de um neurônio "l" da camada de saída para um padrão p.

T_s Temperatura absoluta do sólido (K)

V Volume total de cada estágio (m³)

V₁ Volume dos Estágios do Primeiro Reator (m³)

V₂ Volume dos Estágios do Segundo Reator (m³)

V_{fluido} Volume da fase fluida no estagio CSTR-CELULA (m³)

V_q Vazão volumétrica do gás frio (m³/s)

V_s Volume na fase sólida- incluindo o volume dos poros (m³)

V_Z Vazão volumétrica da fase fluída (m³/s)

V_z Vazão volumétrica total da fase fluída (m³/s)

Vol_{mist} Volume do misturador (m³)

x Média de uma variável

x_i Variável do processo em análise estatística

x₀ Índice que indica a entrada do primeiro estágio do segundo leito

w_{jik} Peso entre o neurônio "j" da camada (k+1) e o neurônio "i" da camada

precedente.

 W_{k+1} Vetor de pesos.

y_i Valor da amostra padronizada para o CUSUM.

y Entrada do processo no domínio do tempo.

y Entrada do processo no domínio de Laplace.

y_{est} É a estimativa da variável através do simulador, para o cálculo da função

objetivo.

y_{exp} É o valor real (experimental) da variável, para o cálculo da função objetivo.

y_{out} Valor do estado estacionário após a perturbação.

Y_i^{RIG} Temperatura de saída do primeiro leito do primeiro reator com ruído

 $y_i^{\,\mathrm{SIM}}$ Temperatura de saída obtida através do modelo empírico.

y_i RIG Temperatura de saída do primeiro leito do primeiro reator sem ruído

y_{EE} Valor do estado estacionário antes da perturbação (236,30 °C).

Z Valor da variável para a Carta MMEP

Símbolos Gregos

Constante de momento do método do gradiente conjugado. 3 Taxa de aprendizagem no método do gradiente conjugado. η Função auxiliar que indica a soma ponderada de todas as entradas de m $\lambda_{pj,k+1}$ neurônio "j" da camada (k+1), para um padrão p, mais o seu "bias" (ou limite interno de ativação). "Bias" (ou limite interno de ativação) do neurônio "j" da camada (k+1) $\theta_{i,k+1}$ Desvio padrão de uma variável σ Valor alvo para a construção do CUSUM ou MMEP μ_0 Massa específica do gás (kg/m³) ρ Massa específica do sólido (kg/m³) ρ_{s} porosidade interpartículas de catalisador. ν $(-\Delta H_r)$ Calor de reação (J/mol) $\Delta T_{\rm v}$ Variação da temperatura de saída do leito devido a perturbação na vazão (°C) perturbação na vazão (m³/s) Δu ΔT Perturbação na temperatura (°C) ${\tau_1}^v$ Constante de tempo 1 da função de transferência da vazão. τ_2^{v} Constante de tempo 2 da função de transferência da vazão. ${\tau_1}^T$ Constante de tempo 1 da função de transferência da temperatura. τ_2^{T} Constante de tempo 2 da função de transferência da temperatura. $\Delta T_{T} \\$ Variação da temperatura de saída do leito devido a perturbação na temperatura (°C)

LISTA DE FIGURAS

FIGURA 1-FLUXOGRAMA SIMPLIFICADO DO PROCESSO (SALVATORE, 2007)	
FIGURA 2-ESTÁGIO CSTR-CÉLULA	
FIGURA 3-ESTÁGIOS CSTR-CÉLULA EM SÉRIE	
FIGURA 4-PROCESSO COM SIMPLES ENTRADA – SIMPLES SAÍDA	
FIGURA 5-DIAGRAMA DE BLOCOS DE UM PROCESSO DE SIMPLES ENTRADA E SAÍDA	
FIGURA 6-EXEMPLO DE CONFIGURAÇÃO DE UMA REDE DO TIPO MLP	
FIGURA 7-J-ÉSIMO NEURÔNIO (DE SOUZA JR., 1993)	22
FIGURA 8-GRÁFICO DE CONTROLE DE SHEWHART	
FIGURA 9-ESTRUTURA GERAL DE DIAGNÓSTICO (VENKATASUBRAMANIAN ET AL., 2003)	
FIGURA 10-ALGORITMO GEOMÉTRICO (ISERMANN, 2005)	
Figura 11-Temperatura de Saída do Reator com Temperatura de Alimentação de 213,0 °C	
Figura 12-Temperatura de Saída do Reator com Temperatura de Alimentação de 214,8 °C	
Figura 13-Temperatura de Saída do Reator com Temperatura de Alimentação de 215,4 °C	62
Figura 14-Temperatura de Saída do Reator com Temperatura de Alimentação de 217,0 °C	
FIGURA 15-TEMPERATURA DE SAÍDA DO REATOR COM VAZÃO DE ALIMENTAÇÃO DE 0,050 M ³ /s	
FIGURA 16-TEMPERATURA DE SAÍDA DO REATOR COM VAZÃO DE ALIMENTAÇÃO DE 0,095 M ³ /s	
FIGURA 17-TEMPERATURA DE SAÍDA DO REATOR COM VAZÃO DE ALIMENTAÇÃO DE 0,105 M ³ /s	65
FIGURA 18-TEMPERATURA DE SAÍDA DO REATOR COM VAZÃO DE ALIMENTAÇÃO DE 0,150 M ³ /s	65
FIGURA 19-TEMPERATURA DE SAÍDA DO REATOR COM VAZÃO DE ALIMENTAÇÃO DE 0,050 M³/S E	
Temperatura 213,0 °C	67
FIGURA 20-TEMPERATURA DE SAÍDA DO REATOR COM VAZÃO DE ALIMENTAÇÃO DE 0,085 M³/S E	
	67
FIGURA 21-TEMPERATURA DE SAÍDA DO REATOR COM VAZÃO DE ALIMENTAÇÃO DE 0,110 M ³ /S E	
	68
FIGURA 22-TEMPERATURA DE SAÍDA DO REATOR COM VAZÃO DE ALIMENTAÇÃO DE 0,110 M³/S E	
Temperatura 214,6 °C	
FIGURA 23-RESULTADO DA OTIMIZAÇÃO DOS PARÂMETROS PARA A CONDIÇÃO OPERACIONAL: VAZÃO -0	
3 /s e temperatura 213,0 °C	
FIGURA 24-RESULTADO DA OTIMIZAÇÃO DOS PARÂMETROS PARA A CONDIÇÃO OPERACIONAL: VAZÃO -0	
m³/s e temperatura 213,8 °C	
FIGURA 25-RESULTADO DA OTIMIZAÇÃO DOS PARÂMETROS PARA A CONDIÇÃO OPERACIONAL: VAZÃO -0	-
m³/s e temperatura 215,4 °C	
FIGURA 26-RESULTADO DA OTIMIZAÇÃO DOS PARÂMETROS PARA A CONDIÇÃO OPERACIONAL: VAZÃO -0	
m³/s e temperatura 215,4 °C	
FIGURA 27-FUNÇÃO OBJETIVO DA FUNÇÃO DE TRANSFERÊNCIA EM RELAÇÃO A DELTA V E DELTA T	
Figura 28- K_P^V em função de Δ u e Δ T	
FIGURA 29 -T $_1$ ^V EM FUNÇÃO DE Δ U E Δ T $_1$	
FIGURA 30 -T $_2$ ^V EM FUNÇÃO DE Δ V E Δ T $_2$	
FIGURA 31- K_P^T EM FUNÇÃO DE $\Delta V \to \Delta T$	75
FIGURA 32- T_1^T EM FUNÇÃO DE Δ U E ΔT	76
Figura 33- ${\rm T_2}^{\rm T}$ em função de Δ u e Δ T	76
FIGURA 34-OBSERVADO X PREDITO PARA O PARAMETRO Kp ⁺	78
Figura 35-Observado x Predito para o Parâmetro $\tau_1^{\hat{r}}$	79
FIGURA 36-OBSERVADO X PREDITO PARA O PARÂMETRO T ¹ ₂	79
FIGURA 37-OBSERVADO X PREDITO PARA O PARÂMETRO K _P ^v	81
FIGURA 38-OBSERVADO X PREDITO PARA O PARÂMETRO T ^V ₁	
FIGURA 39-OBSERVADO X PREDITO PARA O PARÂMETRO T ^V ₂	
FIGURA 40-RESULTADO DA PERFORMANCE DO MODELO EMPÍRICO PARA A CONDIÇÃO OPERACIONAL: VA	
0,050 m ³ /s e temperatura 213,0 °C	
FIGURA 41-RESULTADO DA PERFORMANCE DO MODELO EMPÍRICO PARA A CONDIÇÃO OPERACIONAL: VA	
0,090 m ³ /s e temperatura 213,2 °C	
FIGURA 42-RESULTADO DA PERFORMANCE DO MODELO EMPÍRICO PARA A CONDIÇÃO OPERACIONAL: VA	
$0.100 \text{ m}^3/\text{s}$ e temperatura 214,0 °C	84

Figura 43-Resultado da Performance do Modelo Empírico para a Condição Operacional: vaz	ĹÃΟ
$0,115 \text{m}^3/\text{s}$ e temperatura $216,8 ^{\circ}\text{C}$	
FIGURA 44-RESULTADO DA PERFORMANCE DO MODELO EMPÍRICO PARA A CONDIÇÃO OPERACIONAL: VAZ	ΔÃO
$0,105 \mathrm{m}^3/\mathrm{s}$ e temperatura $215,8 ^{\circ}\mathrm{C}$	85
FIGURA 45-RESULTADO DA PERFORMANCE DO MODELO EMPÍRICO PARA A CONDIÇÃO OPERACIONAL: VAZ	ĹÃΟ
$0.095 \mathrm{m}^3/\mathrm{s}$ e temperatura $213.8 ^{\circ}\mathrm{C}$	86
FIGURA 46-RESULTADO DA ESTIMAÇÃO DOS PARÂMETROS PARA A CONDIÇÃO OPERACIONAL: VAZÃO 0,050	0
M^3/S E TEMPERATURA 214,2 °C.	87
FIGURA 47-RESULTADO DA ESTIMAÇÃO DOS PARÂMETROS PARA A CONDIÇÃO OPERACIONAL: VAZÃO 0,090	0
M^3/S E TEMPERATURA 213,0 °C	88
FIGURA 48-RESULTADO DA ESTIMAÇÃO DOS PARÂMETROS PARA A CONDIÇÃO OPERACIONAL: VAZÃO 0,11:	
M^3/S E TEMPERATURA 213,8 °C	88
FIGURA 49-RESULTADO DA ESTIMAÇÃO DOS PARÂMETROS PARA A CONDIÇÃO OPERACIONAL: VAZÃO 0,110	0
M^3/S E TEMPERATURA 216,2 °C	89
Figura 50-Função Objetivo (Laguerre) em relação a ΔT e Δu	90
Figura 51-p v em relação a Δ u e Δ T	91
Figura 52- $c_1^{\ v}$ em relação a Δu e ΔT	91
Figura-53 $c_2^{\ \nu}$ em relação a Δu e ΔT	
Figura 54- $c_3^{\ \nu}$ em relação a $\Delta \nu$ e ΔT	92
Figura 55-p ^T em relação a Δ u e Δ T	
Figura 56- $c_1^{\ T}$ em relação a Δu e ΔT	
Figura 57- c_2^{T} em relação a Δ u e Δ T	94
Figura 58- c_3^{T} em relação a Δ u e Δ T	94
Figura 59-Resultado da Performance do Modelo Empírico de Laguerre na condição	
OPERACIONAL: VAZÃO 0,0525 M³/S E TEMPERATURA 213,7 °C	95
Figura 60-Resultado da Performance do Modelo Empírico de Laguerre na condição	
OPERACIONAL: VAZÃO 0,090 m³/s e temperatura 213,8 °C	96
Figura 61-Resultado da Performance do Modelo Empírico de Laguerre na condição	
Operacional: vazão $0,110 \text{ m}^3/\text{s}$ e temperatura $216,9 \text{ °C}$	96
Figura 62-Resultado da Performance do Modelo Empírico de Laguerre na condição	
OPERACIONAL: VAZÃO 0,128 m³/s e temperatura 216,7 °C	
Figura 63-Comparação entre os modelos Empíricos e Fenomenológico na condição operacion	
VAZÃO $0,070~\text{m}^3/\text{S}$ e temperatura $214,0~^{\circ}\text{C}$	
FIGURA 64-COMPARAÇÃO ENTRE OS MODELOS EMPÍRICOS E FENOMENOLÓGICO NA CONDIÇÃO OPERACION	
VAZÃO 0,120 m³/s e temperatura 213,0 °C.	
FIGURA 65-COMPARAÇÃO ENTRE OS MODELOS EMPÍRICOS E FENOMENOLÓGICO NA CONDIÇÃO OPERACION	
VAZÃO 0,065 m³/s e temperatura 213,4 °C	
FIGURA 66-COMPARAÇÃO ENTRE OS MODELOS EMPÍRICOS E FENOMENOLÓGICO NA CONDIÇÃO OPERACION	
VAZÃO 0,107 m³/s e temperatura 214,3 °C	
FIGURA 67-COMPARAÇÃO ENTRE OS MODELOS EMPÍRICOS E FENOMENOLÓGICO NA CONDIÇÃO OPERACION	
VAZÃO 0,112 m³/s e temperatura 216,6 °C	100
FIGURA 68-COMPARAÇÃO ENTRE OS MODELOS EMPÍRICOS E FENOMENOLÓGICO NA CONDIÇÃO OPERACION	AL:
VAZÃO 0,115 m ³ /s e temperatura 216,9 °C	
FIGURA 69-RESÍDUOS DOS 16 CASOS ESTUDADOS (VER TABELA 2)	
FIGURA 70-CARTA DE SHEWHART PARA O CASO 1 (EE)	
FIGURA 71-CARTA DE SHEWHART PARA O CASO 2	
FIGURA 72-CARTA DE SHEWHART PARA O CASO 3	
Figura 73-Carta de Shewhart para o Caso 5 Figura 74-CUSUM Tabular para o Caso 1	
FIGURA 75-CUSUM TABULAR PARA O CASO 2 FIGURA 76-CUSUM TABULAR PARA O CASO 3	
FIGURA 76-CUSUM TABULAR PARA 0 CASO 3	
FIGURA // CUSUM TABULAR PARA O CASO 5	
FIGURA 78-CUSUM PADRONIZADO PARA 0 CASO 1	
FIGURA 79 CUSUM PADRONIZADO PARA 0 CASO 2	
FIGURA 81-CUSUM PADRONIZADO PARA O CASO 5	
I IOURA 01-CUDUIVI I ADRONIZADO FARA U CASO J	112

FIGURA 82-GRÁFICO MMEP PARA O CASO 1	114
FIGURA 83-GRÁFICO MMEP PARA O CASO 2	115
FIGURA 84-GRÁFICO MMEP PARA O CASO 3	115
FIGURA 85-GRÁFICO MMEP PARA O CASO 5	116
Figura 86-Estudo do Caso 1	119
FIGURA 87-ESTUDO DO CASO 2	120
FIGURA 88-ESTUDO DO CASO 3	121
FIGURA 89-ESTUDO DO CASO 4	122
FIGURA 90-ESTUDO DO CASO 5	123
FIGURA 91-ESTUDO DO CASO 6	124
FIGURA 92-ESTUDO DO CASO 7	125
FIGURA 93-ESTUDO DO CASO 8	126
FIGURA 94-ESTUDO DO CASO 9	127
FIGURA 95-ESTUDO DO CASO 10	128
FIGURA 96-ESTUDO DO CASO 11	
FIGURA 97-ESTUDO DO CASO 12	130
FIGURA 98-ESTUDO DO CASO 13	
Figura 99-Estudo do Caso 14	
FIGURA 100-ESTUDO DO CASO 15.	
FIGURA 101-ESTUDO DO CASO 16.	
FIGURA 102-RESULTADO DO TESTE I	
FIGURA 103-RESULTADO DO TESTE II	
FIGURA 104-RESULTADO DO TESTE III	
FIGURA 105-RESULTADO DO TESTE IV	139
LISTA DE TABELAS	
TABELA 1-PARÂMETROS DO REATOR DE HDT (CARNEIRO, 1992)	14
TABELA 2-CONDIÇÕES OPERACIONAIS DOS CASOS ESTUDADOS	
TABELA 3-ANÁLISE ESTATÍSTICA PARA A REDE NEURONAL DA TEMPERATURA	77
Tabela 4-Análise de Sensibilidade	78
TABELA 5-ANÁLISE ESTATÍSTICA PARA A REDE NEURONAL DA VAZÃO	
Tabela 6-Análise de Sensibilidade para a rede neuronal da vazão	81
TABELA 7-RESULTADO DA CARTA DE SHEWHART PARA OS CASOS EM ESTUDO	106
TABELA 8-RESULTADO DA CARTA DE CUSUM TABULAR PARA OS CASOS EM ESTUDO	
TABELA 9-RESULTADO DA CARTA DE CUSUM PADRONIZADO PARA OS CASOS EM ESTUDO	
TABELA 10-RESULTADO DA CARTA DE MMEP OS CASOS EM ESTUDO	
TABELA 11-RESULTADO DOS ESTUDOS DE CASO COM SUA RESPECTIVA CONDIÇÃO OPERACIONAL	
TABELA 12-CONDIÇÕES OPERACIONAIS DOS TESTES PROPOSTOS COM INDICAÇÃO DO CASO MAIS PRÓXIMO	134
TABELA 13-RESULTADO DOS TESTES COM SUA RESPECTIVA CONDICÃO OPERACIONAL	135

SUMÁRIO

AGRADECIMENTOS	
RESUMO	
ABSTRACT	VIJ
1 - INTRODUÇÃO	1
2 - FUNDAMENTOS TEÓRICOS	4
2.1 UNIDADE DE HIDROPROCESSAMENTO	4
2.1.1 Tipos de Unidades de Hidroprocessamento	
2.1.2 Unidades de Hidrotratamento (HDT)	
2.2 MODELAGEM FENOMENOLÓGICA DA UNIDADE DE HDT	5
Balanço de massa para o composto A na fase fluída do estágio i	
Balanço de massa na região sólida do estágio i	
Balanço de energia na fase fluida do estágio i	
Balanço de energia na região sólida do estágio i	
Cinética Química	
Modelagem do Forno	
2.3 MODELOS EMPÍRICOS PARA A UNIDADE DE HDT	15
2.3.1 Modelagem baseada em Função de Transferência	15
2.3.2 Modelagem baseada em Função de Laguerre	17
2.4 CONCEITOS TEÓRICOS DE REDES NEURONAIS	
2.5 LOOKUP TABLE	24
2.6 CONTROLE ESTATÍSTICO DE PROCESSO	25
2.6.1 Princípios Estatísticos dos Gráficos de Controle	
2.6.2 Gráfico de Controle de Shewhart para medidas individuais	
2.6.3 Gráficos da Soma Cumulativa e da Média Móvel Exponencialmente Ponderada	
2.6.3.1 Gráficos de Controle da Soma Cumulativa	
2.6.3.1.1 O CUSUM Tabular	
2.6.3.1.2 CUSUM Padronizado	
2.6.3.1.3 Gráfico de Controle da Média Móvel Exponencialmente Ponderada	
2.7 Defecção e Diagnostico de Palhas	
2.7.2 Nomenclatura Empregada	
2.7.2.1 Falha.	
2.7.2.2 Defeito ou Mau Funcionamento.	
2.7.3 Fontes dos Defeitos	
2.7.3.1 Perturbações Grosseiras dos Parâmetros do Modelo	34
2.7.3.2 Mudanças Estruturais no Processo	35
2.7.3.3 Mau funcionamento dos sensores ou atuadores	
2.7.4 Características do Sistema de Diagnóstico de Falhas	
2.7.4.1 Detecção e Diagnósticos rápidos	36
2.7.4.2 Isolabilidade ou detectabilidade	
2.7.4.4 Identificação de Novos Eventos	
2.7.4.5 Estimativa do Erro de Classificação	
2.7.4.6 Adaptabilidade	
2.7.4.7 Facilidade de Explicação	
2.7.4.8 Requisitos do Modelo	
2.7.4.9 Requisitos Computacionais e de Armazenamento	
2.7.4.10 Identificação de Múltiplas Falhas	
2.7.5 Classificação das Técnicas de Diagnóstico de Falhas	
2.7.3.1 Classificadores Geometricos 2.8 Polinômio Interpolador de Lagrange	
2.9 MODELAGEM, SIMULAÇÃO, DETECÇÃO E DIAGNÓSTICO DE FALHAS EM UNIDADES DE PROCESSOS	+∠
Industriais	43

3 - METODOLOGIA	47
3.1 - Simulação do Modelo Fenomenológico	47
3.2 - MODELAGEM EMPÍRICA BASEADA NA FUNÇÃO DE TRANSFERÊNCIA CLÁSSICA	48
Resposta da Função de Transferência da Vazão de alimentação	48
Resposta da Função de Transferência da Temperatura da alimentação	48
Resposta Final do Modelo Empírico	
3.3 MODELAGEM EMPÍRICA BASEADA NA FUNÇÃO DE LAGUERRE	
Função de Laguerre para a Perturbação na Vazão de Alimentação	
Função de Laguerre para a Perturbação na Temperatura de Alimentação	50
Resposta Final do Modelo de Laguerre	
3.4 ESTIMAÇÃO	
3.4.1 Parâmetros do Modelo Função de Transferência	
3.4.2 Parâmetros do Modelo Função de Laguerre	
3.5 PROBLEMAS DA NÃO LINEARIDADE	
3.6 Treinamento das Redes Neuronais	
3.7 APLICAÇÃO DO LOOKUP TABLE	
3.8 Interpolação	
3.9 Introdução do Ruído Randômico e Cálculo dos Resíduos.	
3.10 CONTROLE ESTATÍSTICO DO PROCESSO	
3.11 DETECÇÃO E DIAGNÓSTICO DE FALHAS	57
4 - RESULTADOS E DISCUSSÕES	60
4.1 DINÂMICA DO PROCESSO DE HIDROTRATAMENTO	
4.1.1 Influência da Perturbação na Temperatura de Alimentação	
4.1.2 Influência da Perturbação na Vazão de Alimentação	
4.1.3 Influência combinada entre as perturbações na temperatura e vazão de alimentação	
4.2 FUNÇÃO DE TRANSFERÊNCIA	
4.2.1.Estimação dos Parâmetros	
4.2.2 Treinamento das Redes	
4.2.2.1 Rede Neuronal para os Parâmetros K_p^T , $\tau_1^T e \tau_2^T$	77
4.2.2.1.1 Predições dos Parâmetros da rede da temperatura	/8 00
4.2.2.1 Predições dos Parâmetros da rede da vazão.	80 81
4.2.3 Performance do Modelo Empírico – Função Transferência	
4.3 FUNÇÃO DE LAGUERRE	
4.3.1 Estimação dos Parâmetros	
Parâmetros da Função de Laguerre	
4.3.2 Estrutura de Predição dos Parâmetros do Modelo	
4.4 Comparação Entre os Modelos Empíricos	
4.5 CONTROLE ESTATÍSTICO DO PROCESSO	
4.5.1 Carta de Shewhart (Medidas Individuais).	
4.5.2 –CUSUM Tabular	
4.5.3 –CUSUM Padronizado	
4.5.4 –MMEP	
4.6 Classificação e Diagnóstico de Falhas.	
4.6.1 Estudos de Caso	
4.6.1.1 Caso 1	
4.6.1.2 Caso 2	
4.6.1.3 Caso 3	
4.6.1.4 Caso 4	
4.6.1.5 Caso 5	
4.6.1.6 Caso 6	123
4.6.1.7 Caso 7	
4.6.1.8 Caso 8	
4.5.1.9 Caso 9	
4.6.1.10 Caso 10	
4.6.1.11 Caso 11	128

4.6.1.12 Caso 12	129
4.6.1.13 Caso 13	
4.6.1.14 Caso 14	
4.6.1.15 Caso 15	
4.6.1.16 Caso 16	
4.6.2 Estudo de Novos Casos	
4.6.2.1 Resultado do Teste I	
4.6.2.2 Resultado do Teste II	
4.6.2.3 Resultado do Teste III	
4.6.2.3 Resultado do Teste IV	138
5 - CONCLUSÕES E SUGESTÕES	140
6 - REFERÊNCIAS BIBLIOGRÁFICAS	142
7 - APÊNDICES	149
Apêndice 1 – Cartas de Shewhart	149
APÊNDICE 2 – CARTAS DE CUSUM TABULAR.	151
APÊNDICE 3 – CARTAS DE CUSUM PADRONIZADO	
APÊNDICE 4 – CARTAS DE MMEP.	
ALENDICE T = CARTAS DE IVIIVIEI	133

1 - Introdução

O hidrotratamento é uma dos processos mais utilizados no refino de óleos pesados e resíduos. É bastante abrangente podendo ser empregado para todas as frações do petróleo promovendo a remoção de contaminantes (MUÑOZ *et al.*, 2005). Uma unidade de hidrotratamento (HDT) dever ter a capacidade de ajustar a qualidade do produto à legislação ambiental vigente no mercado consumidor (GOMES *et al.*, 2005).

No Brasil, existe uma Agência Reguladora das especificações dos combustíveis quanto à qualidade - ANP (Agência Nacional de Petróleo, Gás Natural e Biocombustíveis). Se os produtos provenientes das unidades de processo não atenderem aos padrões ambientais impostos pela legislação, não será possível a sua introdução no mercado consumidor. De forma a se adequar a esse novo cenário e ao processamento de grandes volumes de óleos pesados, a PETROBRAS destinou US\$ 2,58 bilhões em investimento para a modernização dos parques de refino, visando à melhoria da qualidade de diesel e gasolina, elevando a capacidade das unidades de HDT, de 22200 barris por dia (bpd) para 92600 bpd até 2011 (SCHAEFFER e SZKLO, 2007).

A crescente importância dada pela PETROBRAS e por outros refinadores mundiais, para as unidades de processo, em especial o hidrotratamento, resulta no surgimento de ferramentas como o desenvolvimento e a implementação de técnicas de controle e gerenciamento de eventos anormais (AEM). AEM constitui-se num conjunto de procedimentos que aborda detecção, diagnóstico e correções das condições inadequadas que geram as falhas em um processo. Realizar o "AEM" significa a possibilidade de detectar as "falhas" com a planta trabalhando em uma região de segurança operacional, de maneiras a evitar a progressão do evento e a conseqüente perda de produtividade. Estas técnicas citadas, se bem implementadas, podem representar uma economia de cerca de 20 bilhões de dólares por ano para os refinadores mundiais (VENKATASUBRAMANIAN *et al.*, 2003a).

Segundo LEES (1996) e VENKATASUBRAMANIAN *et al.* (2003a), muitos prejuízos e até mesmo situações perigosas podem ocorrer pela falta ou operação equivocada das ferramentas de monitoramento dos processos industriais. Por esta razão, o objetivo desta dissertação foi desenvolver uma metodologia para a aplicação de uma técnica

quantitativa de detecção e diagnóstico de falhas em uma Unidade de HDT, da família dos classificadores geométricos denominada de Classificação do Vizinho Próximo (Nearest Neighbor Classification) baseada na geração e avaliação de resíduos (ISERMANN, 2005). Tal técnica aplica-se a detecção e posterior diagnóstico de falhas no primeiro leito do primeiro reator fixo catalítico de uma unidade simulada industrial de HDT. Uma modelagem empírica do processo foi necessária para se obter respostas rápidas e confiáveis do sistema de classificação e diagnóstico de falhas. Em contra-partida, modelagens de processos que contemplem balanços de massa e de energia requerem uma forte demanda computacional quando simuladas e podem apresentar uma certa morosidade na resolução do problema e além disso, a modelagem fenomenológica proposta por CARNEIRO (1992) foi empregada como "processo real", uma vez que não se dispunham de dados oriundos de plantas industriais.

Da Unidade de HDT, apenas o pré-aquecimento da carga e o primeiro leito, do primeiro reator serão explorados. Foram propostas duas modelagens empíricas do processo de HDT (a serem empregadas internamente no sistema de FDD), ambas desenvolvidas no domínio de Laplace, sendo a primeira com base em funções de transferência clássica e a segunda empregando-se Funções de Laguerre. Para o cálculo e ajuste dos parâmetros dessas funções, tomou-se como base, dados simulados empregando o modelo fenomenológico do processo proposto por CARNEIRO (1992), introduzindo perturbações na vazão e temperatura de alimentação.

O Capítulo 2 desta dissertação destinou-se aos fundamentos teóricos dos processos e ferramentas empregadas no desenvolvimento do trabalho.

A metodologia empregada para o cálculo dos parâmetros das funções é objeto de estudo do Capitulo 3 desta dissertação. Neste mesmo capítulo, é descrito o procedimento adotado para a análise estatística dos resíduos empregados para a classificação e diagnóstico das falhas, bem como o seu principio de funcionamento.

No Capítulo 4 apresentam-se, primeiramente, os resultados e discussões referentes ao ajuste dos parâmetros para cada modelo proposto. Devido ao fato do processo em estudo apresentar características não lineares, os parâmetros dos modelos empíricos apresentaram valores diferentes para cada condição operacional simulada, por isso, foi proposta uma técnica de predição para estes valores a serem empregados ao longo da simulação. Para o

modelo empírico 1 (Função de Transferência Clássica) foram empregadas redes neuronais, ao passo que, para o modelo empírico 2 (Função de Laguerre) foi empregada à técnica de Busca Ordenada ("Lookup Table") aliada à interpolação de Lagrange. Em seguida, foi realizada a comparação entre os dois modelos empíricos propostos, verificou-se qual apresentou melhor performance de ajuste ao Modelo Fenomenológico proposto por CARNEIRO (1992). O modelo empírico escolhido e o modelo fenomenológico foram empregados para gerar resíduos que foram estudados estatisticamente de maneira a verificar os seus desvios e sua variabilidade, onde se empregaram cartas de controle univariável (Shewhart, CUSUM e MMEP), onde, também se verificou qual a melhor Carta a ser empregada para o acompanhamento do processo. Para a obtenção dos resíduos, empregaram-se 16 casos estabelecidos onde se introduziram perturbações na vazão e concentração de alimentação. Desta forma, conseguiu-se simular condições normais, de altas e baixas vazões e concentrações de operação. Em seguida, os valores dos resíduos foram utilizados para a montagem do sistema classificador e diagnosticador de falhas. Seu desempenho foi testado através da análise dos 16 casos além de 4 testes propostos com uma nova condição operacional.

Por fim, no Capítulo 5 são apresentadas análises finais e conclusões obtidas com as discussões realizadas pelo estudo dos resultados obtidos em todas as etapas descritas no Capítulo 4.

2 - Fundamentos Teóricos

2.1 Unidade de Hidroprocessamento

Embora as unidades de hidroprocessamento mantenham uma grande similaridade entre si, existem diferenças nos diversos esquemas de processamento que derivam de fatores tais como: tipo de carga, objetivos do processo e projeto da unidade (ZOTIN *et al.*, 2003).

2.1.1 Tipos de Unidades de Hidroprocessamento

O esquema básico de uma unidade de Hidroprocessamento consiste da mistura de uma carga de hidrocarbonetos com H₂ para reação catalítica, normalmente em reatores de leito fixo catalítico, seguido de uma secção de separação e recuperação de produtos (SILVA, 1997).

De modo geral, as unidades de hidroprocessamento podem ser classificadas em:

- Unidades de Hidrotratamento (HDT)
- Unidades de Hidroconversão (SILVA, 1997).

As unidades de Hidrotratamento têm como finalidade principal melhorar as propriedades da carga a ser hidrogenada, através da remoção de contaminantes reacões de hidrossulfurização, indesejáveis. partir de hidrodenitrificação, hidrodesaromatização e hidrodeoxigenação. A adição química de hidrogênio promove a eliminação de compostos insaturados, por reações de saturação (GOMES et al., 2005). O produto da unidade possui, essencialmente, a mesma faixa de destilação da carga, embora exista uma produção marginal de produtos mais leves, tais: como gás e nafta, provenientes de reacões de Hidrocraqueamento (SPEIGHT, 2005). As cargas típicas deste tipo de unidade variam de hexano a gasóleo pesado de destilação a vácuo, provenientes de unidades de destilação, FCC, CTB, Coqueamento, Visco-redução etc (SILVA, 1997).

As unidades de Hidroconversão (HDC) objetivam a produção de derivados mais leves do que a carga, por reações de Hidrocraqueamento, embora haja também a finalidade de melhoria da parte não convertida da carga (resíduo hidrogenado) para uso como carga para unidades de FCC ou produção de óleos lubrificantes. A corrente típica processada nas unidades de Hidroconversão é o gasóleo pesado de destilação a vácuo (ZOTIN, 2003).

2.1.2 Unidades de Hidrotratamento (HDT)

As especificações dos produtos destilados são funções das severidades dos processos de HDT. Quanto maior a temperatura e a pressão parcial de hidrogênio e menor a velocidade espacial no reator, maior será a severidade da operação. Unidades com severidades moderadas são capazes de remover enxofre e olefinas. Condições de processo mais rigorosas levam à remoção de nitrogênio, compostos mais pesados de enxofre e anéis aromáticos (SCHAEFFER e SZKLO, 2007).

O parâmetro mais importante para se alterar a severidade de um hidrotratamento é a temperatura de operação. No entanto, existem restrições cinéticas que definem o limite inferior da faixa de temperaturas de operação e restrições de metalurgia, danos ao catalisador e termodinâmicas (reações de desidrogenação) definem o limite superior. A pressão parcial de hidrogênio e a velocidade espacial do reator seguem a temperatura em ordem de importância com relação à severidade. Não existem comparações simples entre dois conjuntos de parâmetros operacionais diferenciados que permita a definição do mais severo (ZOTIN *et al.*, 2003).

2.2 Modelagem Fenomenológica da Unidade de HDT

Uma planta de hidrotratamento é composta por uma seção de reação – que inclui uma série de fornos de pré-aquecimento, os reatores, um sistema de flash de hidrogênio, um compressor de make-up para hidrogênio e uma seção de estabilização. A carga é pré-aquecida nos fornos e levado aos reatores, após mistura com hidrogênio para reação. Em seguida, o óleo hidrotratado passa por vasos separadores, onde os hidrocarbonetos se separam do hidrogênio. O hidrogênio é tratado em uma torre para remoção dos compostos

de enxofre e comprimido para reenvio (reciclo) aos reatores. Uma fonte de hidrogênio adicional (hidrogênio de reposição) é prevista, oriunda da unidade de geração de hidrogênio.

Na presente dissertação de mestrado, apenas a seção de reação será enfocada, onde dois reatores do tipo leito gotejante (trickle bed) são empregados, uma vez que a corrente de entrada está nas fases gasosa e líquida, compondo um sistema trifásico com hidrogênio e o leito sólido de catalisador.

O fluxograma da unidade pode ser visto na Figura 1.

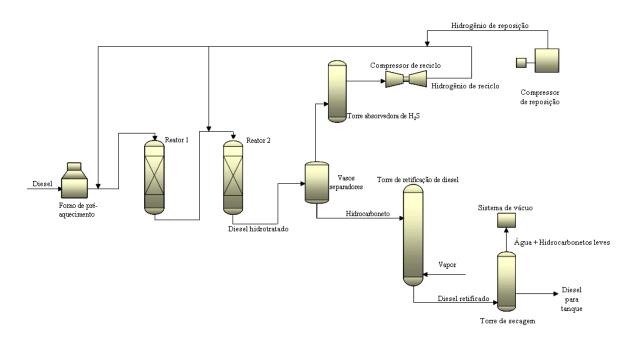


Figura 1-Fluxograma Simplificado do Processo (SALVATORE, 2007)

CARNEIRO (1992) descreve um modelo para as unidades de hidrogenação (HDT) de compostos de petróleo. Essas unidades possuem dois reatores. Em cada um, há dois leitos fixos catalíticos. Os inúmeros compostos presentes na carga de óleo das unidades reagem com hidrogênio, em reações paralelas, nos leitos fixos. O hidrogênio é misturado ao óleo em proporção muito maior que a estequiométrica. A temperatura ao longo dos leitos aumenta da entrada em direção à saída, em operação estacionária, dependendo do progresso das reações exotérmicas ao longo de hidrogenação.

As seguintes considerações são feitas a respeito do sistema reativo:

- ocorrência de apenas uma reação; que é irreversível e se passa na fase sólida, com cinética de primeira ordem (com relação à concentração média de apenas um reagente nos poros da fase sólida);
- a taxa de reação é do tipo Arrhenius;
- não ocorre variação de volume na reação;
- a fase fluida é gasosa, com propriedades físico-químicas constantes

O modelo descreve dois leitos em série, por onde escoa uma fase gasosa. CARNEIRO (1992) adotou o modelo de conjunto de estágios de reatores CSTR-CÉLULA em série de HLAVÁCEK (1982). Ele considera tanto a dispersão axial de massa e calor no leito, quanto a difusão de massa e o transporte de calor entre a fase fluida e o catalisador sólido.

As equações que descrevem o reator CSTR-CÉLULA são obtidas através de balanços de massa e energia em cada estágio.

A FIGURA 2 ilustra um estágio CSTR-CÉLULA. Nela, a letra "g" simboliza tanto o fluxo reverso de massa (g_m), quanto o de energia (g_t).

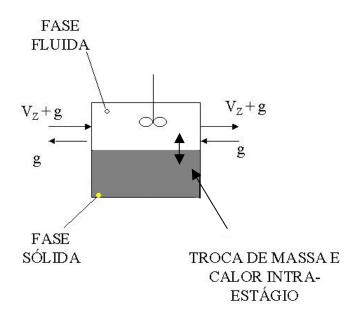


Figura 2-Estágio CSTR-CÉLULA

O leito é simulado com um número (n) de estágios, conforme ilustrado na Figura 3. Os mecanismos de transporte de massa e energia no sentido contrário à direção normal de escoamento, isto é, as retro-misturas, ocorrem entre cada estágio.

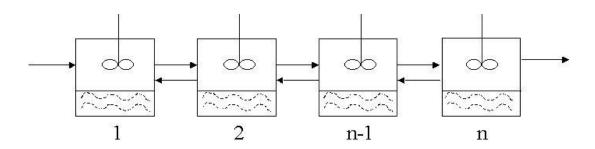


Figura 3-Estágios CSTR-CÉLULA em série

Seja primeiramente o fluxo de massa onde a fase fluida escoa da esquerda para a direita. Neste sentido o fluxo inter-estágios é composto de duas parcelas: V_z e g_m , tal que V_z é a vazão volumétrica da fase fluida e g_m é vazão volumétrica associada ao fluxo reverso de massa.

No sentido contrário (isto é, da saída para a entrada), ocorre somente o fluxo reverso: g_m . Note-se que g_m será considerado constante ao longo do leito e proporcional a V_z :

$$g_m = V_Z K_m \tag{2.2.1}$$

Assumiu-se a hipótese de que a única reação química possível foi:

$$A + H_2 \rightarrow B + C \tag{2.2.2}$$

onde o componente A é a carga a ser hidrotratada.

As vazões molares do componente A são, então:

$$(V_z + g_m) C = (I + K_m) V_z C$$
 [no sentido direto] (2.2.3)

$$g_m C = K_m V_z C$$
 [no sentido reverso] (2.2.4)

Para o transporte de calor associado ao escoamento, tem-se que g_t é a vazão de fluido, associada ao fluxo reverso de calor, tal que g_t é também proporcional a V_z :

$$g_t = V_z K_h \tag{2.2.5}$$

As expressões das taxas de transporte de calor inter-estágios são:

$$(V_z + g_t) \rho C_P (Te - Te^*) = (1 + K_h) V_z \rho C_P (Te - Te^*)$$
(2.2.6)

[no sentido direto]

$$g_t \rho C_P (Te - Te^*) = K_h V_z \rho C_P (Te - Te^*)$$
 (2.2.7)

[no sentido reverso]

O volume total de cada estágio é V. O volume da fase fluida é V_{fluido} e o da fase sólida é V_{S} . A porosidade do leito, isto é, porosidade inter-partícula é v.

$$V_{fluido} = V v \tag{2.2.8}$$

$$V_S = V(1 - v) (2.2.9)$$

A fase fluída está fora dos poros do catalisador e comporta-se como um tanque de mistura perfeita, em cada estágio.

O transporte de massa intra-estágio entre sólido e gás é baseado na superfície externa das partículas sólidas do catalisador. A concentração do fluido C_S no interior dos poros das partículas também é homogênea em cada estágio. O fluxo de massa é proporcional à diferença entre as concentrações interna e externa aos poros da partícula.

$$K_{g} a V (C - C_{s}) \tag{2.2.10}$$

O mecanismo de transporte de calor intra-estágio é descrito, simplificadamente, por meio de um coeficiente global de transmissão de calor, baseado na superfície externa das partículas. Supõe-se que o fluido nos poros do catalisador esteja na mesma temperatura do sólido. O fluxo de calor é proporcional às temperaturas em cada fase.

$$Ua\ V(Te_s - Te) \tag{2.2.11}$$

As equações de balanço em cada um dos "n" estágios CSTR-CÉLULA podem, agora, ser descritas:

Balanço de massa para o composto A na fase fluída do estágio i

{moles de A que acumulam}={moles de A que entram} - {moles de A que saem}

$$\left(vV\frac{dC_{i}}{dt}\right) = \left[V_{Z}(1+K_{m})C_{i-1} + V_{Z}K_{m}C_{i+1}\right] - \left[(2K_{m}+1)V_{Z}C_{i} + K_{g}aV(C_{i}-C_{is})\right]$$
(2.2.12)

Balanço de massa na região sólida do estágio i

{moles de A que acumulam}={moles de A que entram - moles de A que saem}{moles de A consumidos}

$$\left[V(1-v)\frac{dC_{is}}{dt}\right] = \left[K_{g}aV(C_{i}-C_{is})\right] - \left[V(1-v)k_{0}C_{is}e^{\frac{-E}{RT_{is}}}\right]$$
(2.2.13)

Balanço de energia na fase fluida do estágio i

{energia que acumula}={energia que entra} – {energia que sai}

$$\left[vV\rho C_{P} \frac{dTe_{i}}{dt} \right] = \left[V_{Z} (1 + K_{h}) \rho C_{P} Te_{i-1} + V_{Z} K_{h} \rho C_{P} Te_{i+1} + UaV \left(Te_{is} - Te_{i} \right) \right]$$

$$- \left[(2K_{h} + 1) V_{Z} \rho C_{P} Te_{i} \right]$$
(2.2.14)

Balanço de energia na região sólida do estágio i

{energia que acumula} = {energia que entra – energia que sai} + {energia gerada}

$$\left[V(1-v)\rho_{S}C_{P_{S}}\frac{dTe_{is}}{dt}\right] = \left[UaV\left(Te_{i_{i}} - Te_{is}\right)\right] + \left[(-\Delta H_{r})V(1-v)k_{0}C_{is}e^{\frac{-E}{(RT_{i_{s}})}}\right]$$
(2.2.15)

Cinética Química

r_A = {velocidade de reação do reagente A por unidade de volume do catalisador }

$$r_{A} = k_{0} C_{i_{s}} e^{\frac{-E}{(RT_{i_{s}})}}$$
 (2.2.16)

Modelagem do Forno

Para a modelagem do forno, CARNEIRO (1992) adotou uma abordagem empírica

$$\frac{dTe_f}{dt} = f_1 \left(Te_f - Te_{fin} \right) + f_2 \left(\frac{W_d}{V_Z} \right) + f_3 \left(Te_f - Te_{fin} \right)^2$$
(2.2.17)

onde:

W_d-vazão de combustível,

 $V_z-carga\ do\ reator\ e$ as constantes empíricas são dadas por: f_1 = 0,01 , f_2 = 0,1 e f_3 = 0,005

Modelagem do Misturador

Segundo CARNEIRO (1992), o modelo do misturador foi criado a partir de leis de conservação de energia e massa. O gás quente efluente do primeiro leito é misturado a uma corrente gasosa fria para reduzir a sua temperatura. Cada leito possui 12 estágios CSTR-CÉLULAS.

Balanço de Massa do Componente A no misturador

{moles que entram}={moles que saem}

$$\{V_zC_{12}\} = \{(V_z + V_q)C_{x0}\}$$
(2.2.18)

Balanço de energia no misturador

{energia que acumula}={energia que entra} – {energia que sai}

$$Vol_{mist} \rho C_p \frac{dTe_{x0}}{dt} = \left\{ V_z \rho C_p Te_{12} + V_q \rho C_p Te_q \right\} - \left\{ (V_z + Vq) \rho C_p Te_{x0} \right\}$$
(2.2.19)

Um algoritmo de simulação foi desenvolvido para representar o modelo e implementado no MatLab 6.5. A simulação foi procedida empregando o método ode15s (método de ordem variável que resolve equações diferenciais stiff e equações algébrico-diferenciais). Os parâmetros usados na simulação estão apresentados na Tabela 1.

Tabela 1-Parâmetros do Reator de HDT (CARNEIRO, 1992)

Parâmetros	Valores
$(-\Delta H_r)$	1,28 10 ⁵ J.mol ⁻¹
\mathbf{k}_0	$7.0 \ 10^6 \ s^{-1}$
E/R	1,0 10 ⁴ K ⁻¹ .
K _m	0
K _h	1
U a	1,4 10 ⁵ W. K ⁻¹ . m ⁻³
K _g a	5,6 s ⁻¹
ρ C _P	5,0 10 ⁴ J. K ⁻¹ . m ⁻³
$\rho_{\rm s} { m C}_{ m Ps}$	1,25 10 ⁶ J. K ⁻¹ . m ⁻³
a	1400 m ⁻¹
V_1	0,5 m ³
V_2	0,9 m ³
ν	0,4
n	12
A	0,48 m ²
L	35 m
L_1	12,5 m

2.3 Modelos Empíricos para a Unidade de HDT

Com o intuito de simplificar os cálculos, concedendo agilidade ao processo de identificação e diagnóstico de falhas, duas propostas de modelos empíricos foram idealizadas: Modelo Empírico baseado em Função de Transferência Clássica e o Modelo Empírico baseado na Função de Laguerre. Para os modelos descritos acima, as variáveis de entradas escolhidas foram à vazão de alimentação e a temperatura de entrada do leito. A variável de saída, assim como no modelo fenomenológico, foi a temperatura de saída do primeiro leito do primeiro reator.

2.3.1 Modelagem baseada em Função de Transferência

O uso da Transformada de Laplace permite a utilização de uma representação simples, conveniente e significativa dos processos químicos dinâmicos. Simples devido ao uso apenas de equações algébricas; conveniente porque permite uma análise rápida dos processos dinâmicos, e significativa porque se pode visualizar de maneira direta a relação entre a entrada e a saída do processo. Esta representação denomina-se Função de Transferência.

Função de Transferência de processos com uma única saída

Na presente dissertação de mestrado, empregou-se a função de transferência com uma única saída (temperatura de saída do leito) e duas entradas (vazão e temperatura de alimentação) para a modelagem do processo.

Segundo STEPHANOPOULOS (1984), considerando um processo simples com uma entrada e uma saída, representado na Figura 4

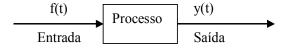


Figura 4-Processo com Simples Entrada – Simples Saída

pode ser representado pelo diagrama de blocos ilustrado na Figura 5.

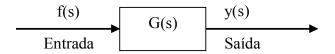


Figura 5-Diagrama de blocos de um processo de simples entrada e saída

O comportamento dinâmico do processo é descrito por meio de equações diferenciais lineares (ou não lineares que foram linearizadas) de ordem "n":

$$a_n \frac{d^n y}{dt^n} + a_{n-1} \frac{d^{n-1} y}{dt^{n-1}} + \dots + a_1 \frac{dy}{dt} + a_0 y = bf(t)$$
(2.3.1.1)

onde f(t) e y(t) são as entradas e a saída do processo, respectivamente. Ambas são expressas em termos de variáveis desvio.

Assumindo que o sistema está inicialmente no estado estacionário:

$$y(0) = \left[\frac{dy}{dt}\right]_{t=0} = \left[\frac{d^2y}{dt^2}\right]_{y=0} = \dots = \left[\frac{d^{n-1}y}{dt^{n-1}}\right]_{t=0} = 0$$
 (2.3.1.2)

Calculando a Transformada de Laplace em ambos os lados da equação acima e usando as condições iniciais, temos:

$$\frac{\overline{y}(s)}{\overline{f}(s)} \equiv G(s) = \frac{b}{a_n s^n + a_{n-1} s^{n-1} + \dots + a_1 s + a_0}$$
 (2.3.1.3)

G(s) é chamada de função de transferência do sistema, é uma representação algébrica simples entre a entrada e a saída

Se o processo possui duas entradas, que é o caso do processo de HDT em estudo pois se introduziram perturbações nas variáveis de entrada temperatura e vazão de alimentação, o modelo dinâmico tem a seguinte equação:

$$a_n \frac{d^n y}{dt^n} + a_{n-1} \frac{d^{n-1} y}{dt^{n-1}} + \dots + a_1 \frac{dy}{dt} + a_0 y = b_1 f_1(t) + b_2 f_2(t)$$
(2.3.1.4)

e fazendo uso das mesmas condições iniciais descritas pela equação 2.3.1.2, teremos:

$$\overline{y}(s) = \frac{b_1}{a_n s^n + a_{n-1} s^{n-1} + \dots + a_1 s + a_0} \overline{f_1}(s) + \frac{b_2}{a_n s^n + a_{n-1} s^{n-1} + \dots + a_1 s + a_0} \overline{f_2}(s)$$
(2.3.1.5)

ou de maneira análoga:

$$\overline{y}(s) = G_1(s)\overline{f}_1(s) + G_2(s)\overline{f}_2(s)$$
 (2.3.1.6)

com

$$G_1(s) = \frac{b_1}{a_n s^n + a_{n-1} s^{n-1} + \dots + a_1 s + a_0} \quad e \quad G_2(s) = \frac{b_2}{a_n s^n + a_{n-1} s^{n-1} + \dots + a_1 s + a_0} \quad (2.3.1.7)$$

onde, $G_1(s)$ e $G_2(s)$ são duas funções de transferência que relacionam a saída do processo com cada uma de suas entradas: $G_1(s)$ relaciona a saída y(s) com a entrada $f_1(s)$ ao passo que $G_2(s)$ relaciona a saída y(s) com a entrada $f_2(s)$.

2.3.2 Modelagem baseada em Função de Laguerre

Neste tópico, propõe-se uma modelagem matemática através de respostas em degrau empregando Funções de Laguerre. O método é baseado no fato matemático de que quaisquer funções arbitrárias podem ser expandidas através de uma série infinita de funções ortogonais, sendo a convergência da expansão garantida, para funções reais, onde o

conjunto das funções ortogonais é completo (WYLIE, 1960). As Funções de Laguerre são um exemplo de funções ortogonais completas.

As Funções de Laguerre são definidas como (LEE, 1960):

para qualquer p > 0

$$l_1(t) = \sqrt{2p} \left(e^{-pt} \right)$$

$$l_2(t) = \sqrt{2p}(-2pt+1)e^{-pt}$$

:

$$l_{i} = \sqrt{2p} \frac{e^{pt}}{(i-1)!} \frac{d^{i-1}}{dt^{i-1}} \quad \left(t^{i-1} e^{-2pt}\right) \tag{2.3.2.1}$$

tal que satisfaçam a seguinte propriedade ortonormal:

$$\int_{0}^{\infty} l_{i}^{2}(t)dt = 1 \tag{2.3.2.2}$$

e

$$\int_{0}^{\infty} l_i(t)l_j(t)dt = 0, \qquad i \neq j$$
(2.3.2.3)

Para WYLIE (1960), quaisquer funções arbitrárias f(t) podem ser expandidas por uma série infinita com base nas Funções de Laguerre. Fazendo-se uso de uma resposta a um impulso unitário h(t) de um sistema desconhecido como uma função f(t), teríamos:

$$h(t) = c_1 l_1 + c_2 l_2 + \dots + c_i l_i + \dots$$
(2.3.2.4)

onde, segundo LEE (1960):

$$c_1 = \int_0^\infty h(t) I_1(t) dt$$
 (2.3.2.5)

$$c_{2} = \int_{0}^{\infty} h(t)l_{2}(t)dt$$

$$\vdots$$

$$c_{i} = \int_{0}^{\infty} h(t)l_{i}(t)dt$$

$$(2.3.2.6)$$

Pode-se verificar que a Transformada de Laplace para a Função de Laguerre tem a seguinte forma:

$$L_{i}(s) = \int_{0}^{\infty} l_{i}(t)e^{-st} dt = \frac{\sqrt{2p(s-p)^{i-1}}}{(s+p)^{i}}$$
 (2.3.2.7)

Então, aplica-se a equação 2.3.2.7 na equação 2.3.2.4, a Função de Transferência G(s) de um sistema desconhecido pode ser escrito da seguinte forma:

$$G(s) = \sqrt{2p} \left[\frac{c_1}{s+p} + \frac{c_2(s-p)}{(s+p)^2} + \dots + \frac{c_i(s-p)^{i-1}}{(s+p)^i} + \dots \right]$$
 (2.3.2.8)

Os modelos matemáticos descritos pelas equações 2.3.2.4 e 2.3.2.8, na teoria, possuem expansões que se estendem até o infinito. Entretanto, a Função de Laguerre

completa (LEE, 1960) nos afirma que, para uma resposta a um impulso contínuo de uma função h(t) que obedeça a restrição abaixo:

$$\int_{0}^{\infty} h^2(t)dt < \infty \tag{2.3.2.9}$$

e para qualquer $\varepsilon_r > 0$, onde exista um inteiro N tal que:

$$\int_{0}^{\infty} \left[h(t) - \sum_{i=1}^{N} c_{i} l_{i}(t) \right]^{2} dt < \varepsilon_{r}$$

$$(2.3.2.10)$$

a condição indicada na equação 2.3.2.9 é satisfeita para sistemas lineares, constantes com o tempo, estáveis e que possuem funções de transferência bem definidas. A condição prevista na equação 2.3.2.10 indica que, dada uma tolerância ϵ_r , a série infinita pode ser truncada em uma série finita. Logo o modelo matemático com dimensão finita N para um sistema desconhecido é proposto como:

$$G_{A}(s) = \sqrt{2p} \left[\frac{c_{1}}{s+p} + \frac{c_{2}(s-p)}{(s+p)^{2}} + \dots + \frac{c_{N}(s-p)^{N-1}}{(s+p)^{N}} \right]$$
(2.3.2.11)

2.4 Conceitos Teóricos de Redes Neuronais

Operacionalmente, pode-se considerar uma rede neuronal como uma "caixa de processamento" que pode ser treinada para que, a partir de um conjunto de dados de entrada ("inputs"), possa gerar uma ou mais saídas ("outputs") (DE SOUZA JR., 1993).

Segundo DE CERQUEIRA, DE ANDRADE e POPPI, (2001), os neurônios artificiais: são as unidades básicas de processamento da informação, simulam o comportamento de neurônios biológicos que são compostos por corpo celular, contendo dois conjuntos de ramificações (dendritos e axônio). Os neurônios artificiais possuem um corpo de processamento de informação com duas ramificações denominadas entradas

(dendritos) e saída (axônio). A transmissão de sinais entre os neurônios biológicos é realizada através de sinapses; o sinal entra no neurônio através dos dendritos passa pelo corpo celular e, em seguida é transmitido para outros neurônios da rede neuronal, através do axônio. A quantidade de sinal trocado em uma sinapse depende de um parâmetro chamado de intensidade da sinapse. Em um neurônio artificial a intensidade da sinapse é um fator de ponderação chamado de peso da sinapse ou simplesmente peso.

A rede neuronal amplamente empregada tem uma configuração de multicamadas de neurônios com processamento em paralelo é comumente chamada de MLP ("*Multilayer Perceptron*") sendo composta por uma camada de entrada, uma camada escondida e uma camada de saída (Figura 6).

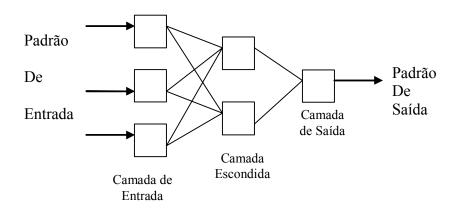


Figura 6-Exemplo de Configuração de uma Rede do tipo MLP

A camada de entrada possui um neurônio para cada variável de entrada. Cada neurônio na camada de entrada está conectado a cada uma das unidades na camada escondida subsequente. Por sua vez, cada neurônio na camada escondida conecta-se a cada uma das unidades na camada de saída. Para os problemas de regressão, que é o caso das redes neuronais desta dissertação, a camada de saída tem um número de neurônios igual ao de variáveis de saída.

Os sinais que chegam ao neurônio se encaminham para o corpo celular, onde são essencialmente somados com os outros sinais provenientes dos demais neurônios da camada anterior. Um neurônio "j" (Figura 7) de qualquer da camada (k+1) recebe um conjunto de entradas $s_{pi,k}$ ($i=1,...,n_k$) correspondentes às saídas ou ativações dos n_k

neurônios da camada anterior. Estas foram ponderadas, cada uma, pelo peso w_{jik} correspondente à sua conexão. O neurônio, então, soma essas entradas ponderadas e o valor resultante é por sua vez somado a um limite interno de ativação chamado de "bias" que pode ser representado por $\theta_{j,k+1}$. A resposta $s_{pj,k+1}$ é produzida pelo neurônio "j", para este sinal, de acordo com uma função de ativação f() empregada (DE SOUZA JR., 1993).

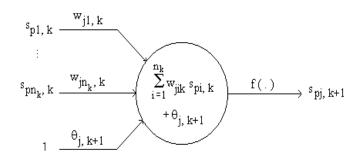


Figura 7-J-ésimo neurônio (DE SOUZA JR., 1993)

As funções de ativação mais comuns são respectivamente a linear, a sigmoidal e a tangente hiperbólica, representadas a seguir:

$$f(\lambda_{pj,k+1}) = \lambda_{pj,k+1} \tag{2.4.1}$$

$$f(\lambda_{pj,k+1}) = [1 + \exp(-\lambda_{pj,k+1})]^{-1}$$
(2.4.2)

$$f(\lambda_{pj,k+1}) = \tanh(\lambda_{pj,k+1})$$
(2.4.3)

As redes neuronais têm sido utilizadas extensivamente para representar a dependência não-linear entre saídas e entradas. É possível constatar na literatura que elas podem aproximar arbitrariamente bem qualquer função contínua. (FUNAHASHI, 1989; HECHT-NIELSEN, 1989; HORNIK *et al.*, 1989).

O método *Backpropagation* consiste em ajustar os pesos e "biases" da rede, modificando-os até que a aplicação de um conjunto de dados de entrada possa produzir saídas correspondentes aos valores alvo. Isto é realizado a partir do fornecimento de padrões de Entradas e Saídas. O treinamento consiste em minimizar a função objetivo não-

linear que apresenta o erro entre as saídas preditas e as saídas alvo, considerando os padrões informados.

O erro obtido na saída é propagado para trás para atualização dos pesos e "biases" a partir do método do gradiente descendente. O erro entre as saídas estimadas e a saídas "alvo" pode ser descrito por (DE SOUZA JR.,1993):

$$E = \sum_{p=1}^{Np} \frac{1}{2} \sum_{l=1}^{Nl} (s_{p1,L} - t_{pl})^2$$
 (2.4.4)

Segundo RUMELHART e MCCLELLAND (1986), a partir da estratégia de otimização do gradiente descendente utilizando a minimização da função objetivo, para a K-ésima iteração, com direção local de busca negativa, tem-se:

$$\Delta W_{k+1} = -\eta \nabla E(W_k) \tag{2.4.5}$$

onde: η é o passo fixo, chamado de taxa de aprendizagem, normalmente $0 < \eta < 1$

O método *backpropagation*, dependendo do valor atribuído à taxa de aprendizagem (η), pode apresentar convergência lenta, sobremaneira na região de solução. Por esta razão, soma-se à equação 2.4.5 um termo de momento (RUMELHART e MCCLELLAND, 1986; MCCLELLAND e RUMELHART, 1988).

$$\Delta W_{k+1} = -\eta \nabla E(W_k) + \varepsilon \Delta W_k \tag{2.4.6}$$

Porém, tal termo pode não ser suficiente para solucionar as oscilações, para ϵ fixo. Foram propostas diversas maneiras para a resolução dos problemas de convergência, dentre elas, o método do gradiente conjugado (LEONARD e KRAMER, 1990). Para a otimização no espaço dos pesos, emprega-se um gradiente com direções conjugadas, com ajuste dinâmico de η e ϵ . A direção de busca S_{k+1} na iteração k+1 é gerada de maneira recursiva (EDGAR e HIMMELBLAU, 1988):

$$\underline{S}_0 = -\underline{\nabla}E(\underline{W}_0) \tag{2.4.7}$$

$$\underline{S}_{k+1} = -\underline{\nabla}E(\underline{W}_{k+1}) + \varepsilon \underline{S}_{k} \tag{2.4.8}$$

$$\varepsilon = \frac{\nabla E(\underline{W}_{k+1})^T \nabla E(\underline{W}_{k+1})}{\nabla E(\underline{W}_k)^T \nabla E(\underline{W}_k)}$$
(2.4.9)

O vetor de pesos \underline{W}_{k+1} é calculado a partir de busca unidimensional de η .

$$\underline{W}_{k+1} = \underline{W}_k + \eta \underline{S}_k \tag{2.4.10}$$

Nesta dissertação, adotou-se a abordagem *backpropagation* aliada ao método do gradiente conjugado para o cálculo dos parâmetros internos das redes neuronais.

2.5 Lookup Table

Na ciência da computação, uma "Lookup Table" é um dado estruturado, usualmente uma matriz ou uma associação de matrizes, usada para devolver o valor de uma variável ou parâmetro com uma simples procura ou busca (KOLAITIS e FOUNTI, 2006). O ganho de velocidade pode ser significativo, uma vez que obter um valor tabelado é bem mais rápido e eficiente do que recalculá-lo sempre que necessário. Um exemplo prático é a tabela de trigonometria, calcular os valores do seno sempre que necessário pode ser proibitivo para algumas aplicações.

Antes do advento computacional, tabelas similares (precursores da Lookup Table) foram usadas para trigonometria, logaritmos e funções de densidades estatísticas. Existem também soluções intermediarias que emprega tabelas em combinação com cálculos computacionais, freqüentemente interpolação. Essa sinergia melhora a precisão dos cálculos para valores compreendidos entre dois valores tabelados. Este procedimento requer um irrisório esforço computacional e melhora de maneira significativa a precisão do valor da variável desejada.

Segundo VEKATASUBRAMANIAN *et al.* (2003b), a Lookup Table pode ser empregada para a localização dos sintomas ou causas do sistema de detecção e diagnóstico de falhas, baseado em modelos qualitativos.

2.6 Controle Estatístico de Processo

O controle estatístico do processo (CEP) é uma poderosa coleção de ferramentas para resolução de problemas, útil na obtenção da estabilidade estatística do processo e na melhoria da capacidade através da redução da variabilidade (MONTGOMERY, 2001).

Uma das principais ferramentas do CEP são as cartas de controle que permitem afirmar, facilmente, se o processo em estudo está sob as condições normais de operação (HIMMELBLAU, 1978).

A aplicação de uma estatística univariável pode ser usada para determinar os limites de variação aceitáveis para as variáveis observáveis, onde a violação sistemática destes limites pode ser interpretada como uma ocorrência de uma falha ou evento anormal no processo (CHIANG *et al.*, 2001).

Neste tópico, estudou-se mais especificamente aos Gráficos de Controle de Shewhart, CUSUM e MMEP.

2.6.1 Princípios Estatísticos dos Gráficos de Controle

A Figura 8 mostra a configuração clássica de uma carta de controle, que é a representação gráfica do comportamento de uma variável ao longo do tempo ou número de amostra. Observam-se três linhas horizontais fundamentais: O Limite Superior de Controle (LSC), a Linha Central (LC) e o Limite Inferior de Controle (LIC). Os limites de controle são escolhidos de modo que apresente, praticamente, a totalidade dos pontos entre estas linhas, quando o processo está sob controle. Ao passo que a LC representa a média dos pontos analisados. Pontos ultrapassando os limites de controle são interpretados como evidencia de que o processo está fora de controle, sendo necessárias investigações e a ações corretivas de modo a encontrar e eliminar as causas responsáveis por esse comportamento. Outra condição indispensável para que o processo esteja sob controle é que todos os pontos do gráfico devem ter padrão essencialmente aleatório, isto é, mesmo com todos os pontos entre os limites de controle, se apresentam uma tendência nítida ou não aleatória, então é uma indicação de que o processo está fora de controle (MONTGOMERY, 2001).

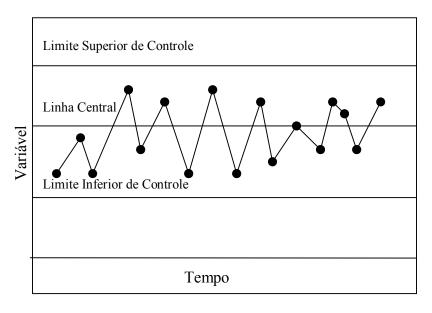


Figura 8-Gráfico de Controle de Shewhart

2.6.2 Gráfico de Controle de Shewhart para medidas individuais.

Há muitas situações onde o tamanho da amostra para monitoramento do processo é n igual a 1, isto é, a amostra consiste de uma única amostra individual. Em tais situações, o gráfico de controle para unidades individuais é útil. Em muitas aplicações, usa-se a amplitude móvel de duas observações consecutivas como base para estimar a variabilidade do processo. A amplitude móvel é definida como (MONTGOMERY, 2001):

$$MR_i = |x_i - x_{i-1}| (2.6.2.1)$$

Para o gráfico de medidas individuais, os parâmetros são:

$$LSC = \overline{x} + 3\frac{\overline{MR}}{d_2}$$
 (2.6.2.2)

$$LC = \overline{x} \tag{2.6.2.3}$$

$$LIC = \overline{x} - 3\frac{\overline{MR}}{d_2}$$
 (2.6.2.4)

Se uma amplitude móvel de n igual a 2 observações é usada, então d_2 = 1,128 (MONTGOMERY, 2001).

Nas equações 2.6.2.2 a 2.6.2.4:

$$\bar{x} = \sum_{i=1}^{j} \frac{x_i}{j} \tag{2.6.2.5}$$

$$\overline{MR} = \sum_{i=1}^{j} \frac{MR_i}{j-1}$$
 (2.6.2.6)

Processos monitorados pelas Cartas de Controle de Shewhart podem apresentar problemas com falsos alarmes e eventos ocorridos não detectados, onde o falso alarme é definido como uma indicação de falha, onde na realidade a falha não ocorreu, e o evento não detectado é definido como uma não indicação de uma falha quando na realidade a mesma aconteceu. Estes inconvenientes podem ser evitados com a aplicação de cartas que utilizam observadores com múltiplos instantes de tempo consecutivos, como o CUSUM e o MMEP (CHIANG *et al.*, 2001).

2.6.3 Gráficos da Soma Cumulativa e da Média Móvel Exponencialmente Ponderada

O gráfico da soma cumulativa, como o próprio nome já define, emprega uma soma cumulativa de uma variável randômica ou de uma função randômica a partir de um determinado tempo estabelecido como referência. A principal vantagem destes tipos de carta de controle sobre as cartas de Shewhart é eliminar a grande desvantagem de usar apenas a informação sobre o processo contida no último ponto plotado, e ignorar qualquer informação dada pela seqüência inteira de pontos (HIMMELBLAU, 1970).

Essa característica torna o gráfico de Shewhart relativamente insensível para pequenas mudanças no processo, por exemplo da ordem de 1,5σ (desvio padrão da amostra) ou menos. Naturalmente, outros critérios podem ser usados nos gráficos de Shewhart, tais como testes para seqüências e o uso de limites de alerta, que tentam incorporar informação de todo o conjunto de pontos no procedimento de decisão. No entanto, o uso destas regras sensibilizantes suplementares reduz a simplicidade e a facilidade de interpretação do gráfico de controle de Shewhart, aumentando o tempo entre a ocorrência da falha e a sua detecção (CHIANG *et al.*, 2001).

Além disso, o uso destas regras sensibilizantes pode reduzir dramaticamente o comprimento médio da sequência (CMS) quando o processo está sob controle, e isso pode não ser desejável. Sendo o CMS, o número esperado de amostras necessárias para se detectar um deslocamento ou alteração na variável (MONTGOMERY, 2001).

Logo, duas alternativas muito eficazes ao gráfico de controle de Shewhart podem ser usadas quando se suspeitar de pequenas mudanças: O gráfico de controle da soma cumulativa (CUSUM) e o gráfico de controle de média móvel exponencialmente ponderada (MMEP). Ambos serão discutidos com mais detalhes a seguir.

2.6.3.1 Gráficos de Controle da Soma Cumulativa

Esse gráfico consegue incorporar toda a informação proveniente do conjunto de dados obtidos com a amostra, plotando as somas acumuladas dos desvios do valor padrão ao longo do tempo. Pelo fato de extraírem informação de todas as amostras, este gráfico apresenta um desempenho muito melhor que o gráfico de Shewhart para detectar pequenas mudanças. Alem do mais, possuem uma ótima eficiência também para tamanhos de amostra igual a 1 (MONTGOMERY, 2001). A desvantagem deste método está no fato de que pequenas mudanças apenas deixarão de ser levadas em conta com a obtenção de uma nova informação (HIMMELBLAU, 1970).

Segundo MONTGOMERY (2001), estes gráficos foram propostos por PAGE (1954) e estudados por diversos autores, entre eles: EWAN (1963), GAN (1991), LUCAS (1976) e HAWKINS (1981).

2.6.3.1.1 O CUSUM Tabular

O CUSUM pode ser calculado e construído tanto para observações individuais, quanto para subgrupos racionais. Estando o processo sob controle, x_i tem uma distribuição normal com média μ_0 e desvio padrão σ . Em alguns casos, pode-se considerar a média como sendo o valor alvo para a característica de qualidade da variável. O CUSUM tabular trabalha acumulando desvios da média que estão acima do alvo, chamado de C^+ , e acumulando os desvios que estão abaixo da média, chamado de C^- . Estas parcelas são denominadas de cusum unilateral superior e inferior (MONTGOMERY, 2001).

$$C_i^+ = m\acute{a}x \left[0, x_i - (\mu_0 + K) + C_{i-1}^+ \right]$$
 (2.6.3.1.1.1)

$$C_{i}^{-} = m \acute{a} x \left[0, (\mu_{0} - K) - x_{i} + C_{i-1}^{-} \right]$$
 (2.6.3.1.1.2)

K é denominado de valor de referência, tolerância ou folga.

$$K = \frac{\delta\theta}{2} \tag{2.6.3.1.1.3}$$

onde δ geralmente é designado como 1 e θ o desvio padrão. Os limites superior e inferior são definidos como 5 θ .

2.6.3.1.2 CUSUM Padronizado

Muitas vezes é desejável padronizar a variável x_i, antes de realizar os cálculos.

$$y_i = \frac{x_i - \mu_0}{\sigma} \tag{2.6.4.1.2.1}$$

Com estes valores padronizados de x_i, os padrões do CUSUM serão:

$$C_i^+ = m \acute{a} x \Big[0, y_i - k + C_{i-1}^+ \Big]$$
 (2.6.4.1.2.2)

$$C_{i}^{-} = m \acute{a} x \left[0, -y_{i} - k + C_{i-1}^{-} \right]$$
 (2.6.4.1.2.3)

As duas principais vantagens em padronizar o CUSUM são que os gráficos podem agora ter os mesmos valores de k e h (valor dos limites superior e inferior), e as escolhas desses parâmetros não dependem mais de escala, isto é, não são função do desvio padrão. Aliado a isto, o CUSUM padronizado nos leva a um CUSUM para controle de variabilidade.

2.6.3.1.3 Gráfico de Controle da Média Móvel Exponencialmente Ponderada

O gráfico de controle de MMEP foi elaborado por ROBERTS (1959) sendo o mesmo definido por:

$$z_{i} = \lambda x_{i} + (1 - \lambda)z_{i-1}$$
 (2.6.4.1.3.1)

A MMEP é empregada em modelagens de séries temporais e em previsões (BOX, JENKINS e REINSEL, 1994) e MONTGOMERY, JOHNSON e GARDINER (1990). Como a MMEP é definida como a média ponderada de todas as observações passadas e correntes, esta metodologia é insensível à hipótese de normalidade.

Neste gráfico, o maior peso é dado para cada nova informação obtida, logo uma nova informação afasta a influência de uma pequena mudança ocorrida tempos atrás (HIMMELBLAU, 1970). Assim, é um gráfico ideal para a análise de observações individuais.

$$LSC = \mu_0 + L\sigma \sqrt{\frac{\lambda}{(2-\lambda)} \left[1 - (1-\lambda)^{2i}\right]}$$
 (2.6.4.1.3.2)

$$LC = \mu_0 \tag{2.6.4.1.3.3}$$

$$LIC = \mu_0 - L\sigma \sqrt{\frac{\lambda}{(2-\lambda)} \left[1 - (1-\lambda)^{2i} \right]}$$
 (2.6.4.1.3.4)

Onde os valores típicos de L e λ são respectivamente: 2,7 e 0.1 (MONTGOMERY, 2001).

2.7 Detecção e Diagnóstico de Falhas

2.7.1 Introdução

Nos últimos anos, o progresso computacional propiciou que novas tecnologias fossem implementadas na área de controle de processos, desta forma, as ações de controle, tais como o acionamento de uma válvula do processo, puderam ser operadas de maneira automática através de computadores com performance bastante elevada (VENKATASUBRAMANIAN *et al.*, 2003a).

Apesar dos benefícios obtidos na indústria, com o avanço tecnológico na implementação e desenvolvimento dos controles de processo, onde podemos citar em especial o controle preditivo, muitas das ações operacionais continuam dependendo da intervenção humana para obterem uma boa performance. Podemos citar, como exemplo, a resposta a eventos anormais que envolve a detecção das falhas em tempo hábil e o diagnóstico de suas causas, propiciando uma ação controladora supervisória que permite a volta do processo ao seu estado normal, de maneira segura. A esses passos descritos acima se convencionou chamar de gerenciamento de eventos anormais ("AEM – Abnornal Event Management") (VENKATASUBRAMANIAN et al., 2003a).

A automação do processo de detecção e diagnóstico de falhas é o primeiro passo no AEM. Devido à ampla gama de problemas de diagnóstico de falhas de processo e as dificuldades encontradas para resoluções em tempo real, várias aproximações computacionais e de modelagem têm sido desenvolvidas ao longo dos anos. (VENKATASUBRAMANIAN *et al*, 2003a).

No passado, usualmente os alarmes eram acionados e protegiam a planta industrial contra danos mais sérios aos equipamentos e ao meio ambiente, no entanto, as falhas ocorridas não eram detectadas a tempo de eliminar as perturbações antes da saída do processo das condições operacionais aceitáveis, então foram implementados métodos computacionais inteligentes que propiciaram maior agilidade na identificação e no diagnóstico das falhas (ISERMANN, 2005).

O diagnóstico de falhas, baseado em modelo, pode ser definido como a capacidade de distinguir os diferentes tipos de falhas ocorridas através da avaliação de um modelo do processo que descreve as características do sistema (PARK e HIMMELBLAU, 1987).

2.7.2 Nomenclatura Empregada

Neste tópico, abordam-se a nomenclatura e definições empregadas no procedimento de detecção e diagnóstico de falhas utilizadas por diversos autores.

2.7.2.1 Falha

Segundo ISERMANN (2005), a falha é uma condição anormal que inicia um defeito ou um mau funcionamento e que se caracteriza pela redução ou perda total da capacidade de uma unidade realizar uma função requerida, quer a unidade esteja em operação ou não. Pode se desenvolver de maneira suave ou abrupta., apresentando dificuldade em sua detecção se for de pequena magnitude.

Diversos autores têm definido o termo "falha" seguindo algumas definições. Segundo HIMMELBLAU (1978), a falha é geralmente definida como o distanciamento de um limite aceitável de uma variável observada ou parâmetro estimado para o processo. VENKATASUBRAMANIAN *et al.* (2003a) definem falha como uma anormalidade ou sintoma do processo, como uma alta temperatura ou uma baixa qualidade do produto. Segundo CHIANG *et al.* (2001), as falhas são perturbações ocorridas nos processos em que não foi possível, pela atuação dos controladores, manter a planta em operação dentro dos seus limites aceitáveis.

As falhas podem ser detectadas quando as condições do sistema ou a performance da observação (acompanhamento) diferem da performance normal (PARK e HIMMELBLAU, 1987).

Existe uma variedade de diferentes tipos de falhas, como por exemplo: mudanças de parâmetros, problemas nos atuadores, problemas nos sensores, falha de modelo, falha de *software*, falha de *hardware* etc (CHIANG *et al.*, 2001).

2.7.2.2 Defeito ou Mau Funcionamento

Segundo ISERMANN (1984), o mau funcionamento pode ser definido como sendo uma parada temporária do sistema ao realizar o serviço para o qual foi concebido.

VENKATASUBRAMANIAN *et al.* (2003a) definem o defeito como a consequência da anormalidade, como por exemplo a falha de uma bomba ou o defeito de um controlador, também é chamado de causa raiz ou evento. Existem três classes de defeitos ou mau funcionamento, que serão abordados no próximo tópico: Perturbações Grosseiras dos Parâmetros do Modelo, Mudanças Estruturais no Processo e Mau funcionamento dos sensores ou atuadores.

Defeitos em um equipamento da planta ou na instrumentação do processo levam a um aumento dos custos de operação (HIMMELBLAU, 1979).

ISERMANN (2005) define o defeito como uma interrupção permanente na habilidade do sistema de responder da maneira como foi projetado. Surge com o inicio da operação ou pelo aumento do *stress* do sistema. Provém de uma ou mais falhas, podendo ser classificado de acordo com o número de eventos anormais: simples ou múltiplos. Também é dividido quanto a sua predição: defeito randômico (impossível de ser previsto), defeito determinístico (previsível em certas condições) e defeito casual ou sistêmico, que depende das condições conhecidas.

2.7.3 Fontes dos Defeitos

O objetivo do sistema de detecção e diagnóstico de falhas é determinar o tipo de falha detalhando, tanto quanto possível, a sua extensão e localização, em tempo hábil, de modo a evitar danos mais sérios ao processo (ISERMANN, 2005). Desde que possamos ver a tarefa de diagnóstico de falhas como um problema de classificação, o sistema de diagnóstico pode ser referido como um classificador de diagnóstico. A Figura 9 mostra um sistema com um processo controlado e indica as principais fontes de defeitos no sistema (VENKATASUBRAMANIAN *et al*, 2003a).

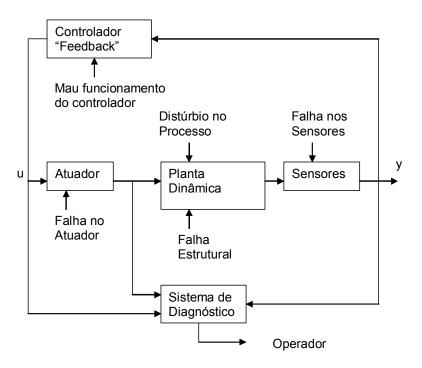


Figura 9-Estrutura geral de diagnóstico (VENKATASUBRAMANIAN et al., 2003)

Em geral, temos três classes de defeitos ou mau funcionamento, a saber:

2.7.3.1 Perturbações Grosseiras dos Parâmetros do Modelo

Em qualquer modelo, existem processos ocorrendo que não são detalhados na modelagem. São tipicamente aglomerados como parâmetros e estes incluem interações através do sistema de contorno. Defeitos nos parâmetros se iniciam quando existe um distúrbio entrando no processo pelo ambiente externo em uma ou mais variáveis independentes (VENKATASUBRAMANIAN *et al.*, 2003a). Um exemplo deste mau funcionamento é a mudança na concentração de um reagente de seu valor normal na alimentação do reator ou na temperatura ambiente. Pode-se também citar como um exemplo deste defeito o envenenamento do catalisador ou o "fouling" formado no trocador de calor (CHIANG *et al.*, 2001).

2.7.3.2 Mudanças Estruturais no Processo

Mudanças estruturais dizem respeito a mudanças no próprio processo. Elas ocorrem devido a defeitos importantes nos equipamentos. Maus funcionamentos estruturais resultam em mudanças no fluxo de informação entre as várias variáveis. Tratar tais defeitos em um sistema de diagnóstico poderia requerer a remoção de algumas equações de modelo apropriadas e a reestruturação de outras equações de modo a descrever a situação atual do processo (VENKATASUBRAMANIAN *et al.*, 2003a). A operação em condição de falha depende não somente do novo estado estacionário alcançado, mas também da dinâmica da perturbação imposta que muitas vezes leva a uma sobrecarga temporária dos equipamentos (HIMMELBLAU, 1978).

2.7.3.3 Mau funcionamento dos sensores ou atuadores

Sensores e sistemas de monitoramento de processo são elementos dinâmicos de transferência, onde apenas o comportamento da variável de saída está disponível. Sem a calibração correta do equipamento, o valor da variável é desconhecido (ISERMANN, 2005).

Erros grosseiros usualmente ocorrem com atuadores e sensores. Estes poderiam acontecer devido a um defeito fixo, a um "bias" (positivo ou negativo), ou a um defeito fora de escala (limites aceitáveis). Alguns destes instrumentos enviam sinais "feedback" que são essenciais para o controle da planta (VENKATASUBRAMANIAN *et al.*, 2003a). As perturbações de origem externa nos sensores são ocasionadas pelo ambiente em torno do sensor, geralmente induzidas pela influência eletromagnética. Perturbações internas são causadas pelo próprio sensor, ocasionadas pela perturbação no suprimento de força, capacitâncias, indutâncias, fricção etc (ISERMANN, 2005).

Um defeito em um destes instrumentos poderia causar na planta, variações de estado para valores além dos seus limites aceitáveis, podendo persistir nesta condição, até a anomalia ser detectada e ações corretivas implementadas. O diagnóstico precisa ter por finalidade detectar, rapidamente, qualquer alteração ou falha em um instrumento que

poderia degradar rapidamente a performance do controle do sistema (VENKATASUBRAMANIAN *et al*, 2003a).

2.7.4 Características do Sistema de Diagnóstico de Falhas

Diferentes aproximações ou hipóteses podem ser feitas, mas o sistema precisa apresentar uma série de requerimentos ou padrões. Nesta etapa, ilustram-se as principais características necessárias para um sistema de FDD, onde citam-se a definição e visão de diversos autores a respeito das características principais de um sistema de diagnóstico. Vale ressaltar que nesta dissertação de mestrado se explorou principalmente as características de Detecção e Diagnóstico Rápidos, Requisitos do Modelo e Requisitos Computacionais e de Armazenamento.

2.7.4.1 Detecção e Diagnósticos rápidos

O objetivo de um sistema FDD ser rápido é propiciar tempo suficiente para a ação de correção, reconfiguração, manutenção ou reparo da unidade, antes da saída das condições aceitáveis de operação (ISERMANN, 2005).

A detecção e o diagnóstico rápidos de um evento anormal no processo é de suma importância para a segurança da planta e para a manutenção da qualidade dos produtos (DETROJA *et al.*, 2007). No desenvolvimento de sistemas de detecção de falhas, um dos seus principais requisitos consiste em uma resposta rápida frente a uma ocorrência de anormalidade (HIMMELBLAU, 1978). O FDD deve responder com rapidez na detecção e diagnóstico de processos que apresentem um mau funcionamento. No entanto, respostas rápidas para diagnóstico de falhas e a tolerância quanto à performance durante a operação normal são dois alvos em conflito (WILLSKY, 1976).

Um sistema projetado para detectar defeitos de forma rápida (principalmente os que se desenvolvem de maneira abrupta) será sensível para as influências em alta freqüência. Isto torna o sistema sensível ao ruído, podendo levar a falsos alarmes mesmo com a planta operando em condições normais (VENKATASUBRAMANIAN *et al.*, 2003a).

2.7.4.2 Isolabilidade ou detectabilidade

Para um sistema de diagnóstico possuir isolabilidade é necessário que o sistema seja dotado de instrumentação suficiente para diagnosticar as mais variadas possíveis falhas ocorridas no processo. Desta forma, pode-se modelar as falhas do sistema através da interpretação do desvio dos parâmetros ou das variáveis do processo (PARK E HIMMELBLAU, 1987).

Para WILLSKY (1976), isolabilidade pode ser definida como a capacidade do sistema de detecção de determinar a fonte do defeito.

Segundo HIMMELBLAU (1978), a isolabilidade faz referência à resolução do sistema de FDD, descrevendo com qual precisão a falha pode ser identificada e selecionada dentro do conjunto de falhas disponíveis e catalogadas no sistema de detecção e diagnóstico.

A isolabilidade é a habilidade do sistema de diagnóstico em distinguir entre diferentes falhas. Existe um compromisso entre a isolabilidade e a rejeição das incertezas do modelo. Muito dos classificadores trabalham com várias formas de redundância de informação e portanto existe apenas um limitado grau de liberdade para o planejamento do classificador. Devido a este fato, um sistema de diagnóstico com alto grau de liberdade para isolamento, usualmente teria uma fraca performance em rejeitar incertezas do modelo e vice e versa (VENKATASUBRAMANIAN *et al.*, 2003a).

2.7.4.3 Robustez

Um dos objetivos do sistema de diagnóstico é desenvolver um padrão de classificação que venha a maximizar e equilibrar a isolabilidade e a robustez do classificador (CHIANG *et al.*, 2001).

É desejável que o sistema de diagnóstico seja robusto para os vários ruídos e para as incertezas de modelagem. Aconselha-se também que sua performance venha a se degradar de maneira suave ao invés de ser total e abrupta. A robustez torna impossível à prática de testes determinados para isolabilidade onde os limites estão muito próximos de zero. Na presença de ruído, estes limites podem ser escolhidos de maneira conservativa, porém, a

robustez do sistema precisa ser dosada com a sua performance (VENKATASUBRAMANIAN *et al.*, 2003a).

Quando um sistema de diagnóstico possui uma resposta muito rápida frente a uma falha, o mesmo pode tornar-se muito sensível a ruídos, e consequentemente gerar alarmes falsos com perda de sua robustez (HIMMELBLAU, 1978).

2.7.4.4 Identificação de Novos Eventos

O sistema de detecção e diagnóstico de falhas precisa ser capaz de informar se o processo está submetido às condições normais de operação ou se está sujeito a uma anormalidade, e neste caso, saber se esta anormalidade faz parte do seu banco de dados ou se é um evento não catalogado. Uma das dificuldades inerentes ao desenvolvimento de um sistema de detecção e diagnóstico de falhas é a falta de dados de processo para a modelagem do fenômeno, quando o mesmo está submetido a perturbações. Somente uma pequena quantidade de dados que cobrem apenas uma região do evento anormal está disponibilizada, logo, é possível que várias regiões que representam condições de anormalidade tenham sido modeladas de maneira não muito precisa, que venha a acarretar erros de diagnóstico (VENKATASUBRAMANIAN *et al.*, 2003a).

Mesmo com essas condições e dificuldades mostradas anteriormente, é necessário que o sistema de diagnóstico seja capaz de reconhecer a ocorrência de um novo evento e não classificá-lo como um evento presente em seu banco de dados (ou como operação normal).

2.7.4.5 Estimativa do Erro de Classificação

Uma das características desejáveis de um sistema de detecção e diagnóstico de falhas é a capacidade de predizer os erros apresentados no sistema, caso os mesmo ocorram, desenvolvendo o nível de confiança do usuário na credibilidade dos resultados das predições e recomendações dadas pelo sistema de diagnóstico (VENKATASUBRAMANIAN *et al.*, 2003a).

2.7.4.6 Adaptabilidade

Outro requisito importante dos sistemas de detecção de falhas é a sua capacidade de se adaptar ou adequar as novas condições ambientais, operacionais ou de requisito de qualidade de produto impostas ao processo. O sistema de detecção e diagnóstico de falhas necessita responder de maneira satisfatória e precisa, mesmo operando sob novas condições de processo ou ambientais (VENKATASUBRAMANIAN *et al.*, 2003a).

2.7.4.7 Facilidade de Explicação

O sistema de diagnóstico precisa justificar as suas recomendações para que o operador possa avaliar e decidir sobre a ação a ser tomada de acordo com a sua experiência. Além da habilidade de identificar a fonte do mau funcionamento, o sistema de detecção precisa também prover explicações sobre como a falha foi originada e propagada para a situação atual. Este é um fator de importância fundamental em montagens de sistemas que operam com decisões on-line. Esta funcionalidade requer a habilidade para concluir a respeito das relações causas e efeito no processo (VENKATASUBRAMANIAN *et al.*, 2003a).

2.7.4.8 Requisitos do Modelo

O esforço do modelo precisa ser o mínimo possível, devido à importância da velocidade e da facilidade de resolução principalmente em aplicações em tempo real. O sistema é desenvolvido para responder rapidamente a perturbações impostas ao processo, isto requer uma modelagem que possua uma resolução precisa e ágil (WILLSKY, 1976).

2.7.4.9 Requisitos Computacionais e de Armazenamento

Soluções em tempo real rápidas necessitam de algoritmos e implementações menos complexas, mas com alto espaço de armazenamento. O sistema de diagnóstico precisa pesar

essas duas diretrizes de maneira a achar uma posição viável para a resolução rápida e eficaz do problema em questão (VENKATASUBRAMANIAN *et al.*, 2003a).

2.7.4.10 Identificação de Múltiplas Falhas

A ocorrência de múltiplas falhas leva a interações sinergéticas entre as distintas falhas, e com os dados históricos disponíveis de falhas isoladas não é possível simular o seu efeito combinado. Por outro lado, modelar separadamente todas as combinações possíveis de falhas pode ser inviável para processos mais complexos. Por isso, é necessário chegar-se a um ponto otimizado entre essas duas diretrizes, de maneira a se conseguir a melhor performance para o sistema de diagnóstico. (VENKATASUBRAMANIAN *et al.*, 2003a).

2.7.5 Classificação das Técnicas de Diagnóstico de Falhas

Os dois principais componentes no classificador de diagnóstico são: o tipo de conhecimento "a priori" do processo e a técnica de busca empregada. A técnica de busca é uma função direta da representação do conhecimento do processo que por sua vez é fortemente influenciado pelo tipo de conhecimento disponível "a priori". Quanto ao tipo de conhecimento, o sistema FDD pode ser classificado em: Métodos baseados em modelos (Quantitativo e Qualitativo) e em dados históricos (VENKATASUBRAMANIAN *et al.*, 2003a).

Os métodos de diagnóstico baseados em modelos fazem uso das relações entre as varias medições para estabelecer uma possível mudança causada por falhas (ISERMANN, 2005).

O modelo é usualmente desenvolvido baseado nos mesmos fundamentos físicos do fenômeno, empregando os balanços de massa, energia e momento do processo, além das equações de estado e equilíbrio disponíveis. (ISERMANN, 1984).

Os sistemas de detecção e diagnóstico de falhas que fazem uso de uma coleção de dados históricos do processo, existindo diversos e diferentes caminhos que levam estes dados a se constituírem em um FDD, por exemplo, o uso de redes neuronais

(VENKATASUBRAMANIAN *et al*, 2003a), este método, segundo HIMMELBLAU (1978) é denominada de reconhecimento pelo exemplo *("pattern recognition")*.

Neste presente trabalho, empregou-se um classificador baseado em modelo quantitativo denominado de Classificador Geométrico.

2.7.5.1 Classificadores Geométricos

Classificadores geométricos determinam a que classe pertence um ponto dado, a partir da distância de referência aos pontos padrão. Estes pontos de referência são caracterizados pelos valores de sintoma s_{ref,i} e o pelo conhecimento da classe (Classe F₁ ou Classe F₂ etc.). A mais simples e famosa aproximação é a Classificação por vizinho mais próximo *("Neighbor Classification")* que é avaliada pela distância Euclidiana. Quando se deseja determinar a classe do dado do ponto s_j, em determinados instantes, comparam-se as distâncias deste ponto em relação a todos os pontos de referência e determina-se o mínimo (ISERMANN, 2005):

$$\min_{i}(d_{i}) = \min_{i} \left(\sqrt{\|s_{j} - s_{ref,i}\|^{2}} \right)$$
 $i \in \{1, ..., n_{ref}\}$ (2.7.5.1.1)

onde, n_{ref} denota o número de pontos de referência existentes. A classe do $s_{ref,i}$ mais próxima do ponto s_j , será tomada como a classe para o s_j . A Figura 10 ilustra o comportamento do algoritmo:

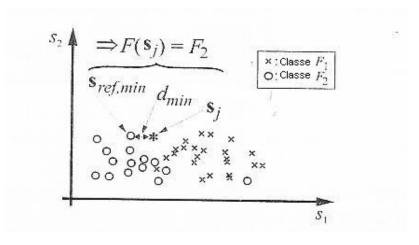


Figura 10-Algoritmo Geométrico (ISERMANN, 2005)

Na Figura 10, apresenta-se o mecanismo de classificação do vizinho mais próximo, onde a distância mínima de s_j é encontrada, sendo o ponto de referência correspondente a F_2 . Logo o resultado do algoritmo de classificação para s_j é F_2 .

2.8 Polinômio Interpolador de Lagrange

Nesta dissertação de mestrado, empregou-se o interpolador de Lagrange como ferramenta de cálculo dos parâmetros do modelo de Laguerre, para os pontos em que não estavam disponíveis os seus valores na tabela empregada para a construção da *Lookup Table*. Utilizou-se o interpolador pela sua característica de garantir a passagem da curva sobre os pontos fornecidos, além da sua facilidade de implementação.

Segundo CARNAHAN *et. al.* (1969), dados os pontos x_0 , x_1 ,, x_n que correspondem aos valores y_0 , y_1 ,..., y_n . O problema de interpolação consiste em encontrar uma função p tal que satisfaça a seguinte condição:

$$p(x_i) = y_i$$
 tal que i=0,1,...,n (2.8.1)

Logo, a função p é a função de interpolação dos dados. Para o polinômio de Lagrange tem-se:

$$p_n(x) = \sum_{i=0}^{n} L_i(x) y_i$$
 (2.8.2)

Sendo os polinômios na base de Lagrange definidos por:

$$L_{j}(x) = \frac{(x - x_{0})(x - x_{1})..(x - x_{j-1})(x - x_{j+1})..(x - x_{n})}{(x_{j} - x_{0})(x_{j} - x_{1})..(x_{j} - x_{j-1})(x_{j} - x_{j+1})..(x_{j} - x_{n})} = \prod_{\substack{k=0\\k\neq j}}^{n} \left(\frac{x - x_{k}}{x_{j} - x_{k}}\right), \quad j = 0,1,..n \quad (2.8.3)$$

Se na Equação 2.8.1, x_0 , x_1 , ..., x_n são pontos distintos, então para qualquer y_0 , y_1 ,..., y_n , existe um único polinômio p(x) de grau n ou menor, tal que:

Pode-se verificar que os polinômio de grau n satisfaz a seguinte condição:

$$L_{j}(x_{i}) = \begin{cases} 1 & se & i = j \\ 0 & se & i \neq j \end{cases}$$
 (2.8.4)

Por esta razão $L_j(x)y_j$ tem o valor 0 para todos os dados x_i , i=0,1,...n, com exceção de x_i , onde $L_i(x_i)y_i = y_i$ (CARNAHAN *et al.*, 1969).

2.9 Modelagem, Simulação, Detecção e Diagnóstico de Falhas em Unidades de Processos Industriais.

Segundo NIMMO (1995), a industria petroquímica perca cerca de 20 bilhões de dólares pela aplicação de técnicas AEM de baixa performance.

Por isso, diversos autores têm investido em pesquisas de novas técnicas de detecção e também no aperfeiçoamento das já existentes. Neste tópico, fez-se uma revisão da literatura científica da aplicação de FDD na engenharia química, tendo como base o ano de 1978, instituído como marco inicial dos trabalhos desta área, com o lançamento do Livro: **Fault Detection and diagnosis in chemical and petrochemical processes** (HIMMELBLAU, 1978).

Estudos e aplicações foram encontrados, onde se pode destacar trabalhos envolvendo:

Comparação e desenvolvimento de técnicas de FDD: LOU, BUDMAN e DUEVER (2003) compararam técnicas de detecção de falhas em um reator CSTR em estado transiente e estacionário. VENKATASUBRAMANIAN et al. (2003a,b,c) realizaram um "review" de praticamente toda a teoria envolvida no estudo de FDD. BAI, TIAN e SHI (2005) desenvolveram um filtro robusto para a detecção de falhas (RFDF) para problemas com modelos não lineares com entrada desconhecida. JIANG e CHOWDHURY (2005) elaboraram um estudo cujo foco principal foi à detecção e estimação de falhas e parâmetros em sistemas não lineares com funções não lineares de distribuição dos eventos anormais. ZHANG e NANDI (2006) desenvolveram um algoritmo genético robusto com alta performance para a detecção e diagnostico de falhas. BOUTROS e LIANG (2007)

desenvolveram uma técnica FFI (Fuzzy Fusion Index) que é a integração de uma lógica "fuzzy" capaz de detectar anormalidades repentinas e graduais que são resultado da integração de quatro condições de monitoramento da unidade.

Aplicações:

Industrias em geral: LI e KIM (1993) e JEON e LI (1995) elaboraram observadores dinâmicos não lineares para a detecção de falhas em compressores parafusos industriais. SIMANI e FANTUZZI (2006) e SIMANI e PATTON (2007) desenvolveram um observador dinâmico para detecção de falhas em turbinas a gás. THORNHILL e HORCH (2007) realizaram um estudo a respeito das vantagens do emprego das técnicas de detecção e diagnóstico de falhas em plantas industriais, estudando as causas dos distúrbios nos processos não lineares. LENNOX et al. (2001) utilizaram redes neuronais para o diagnóstico de falhas em unidades de vitrificação. MILETIC (2004) desenvolveu métodos estatísticos para a detecção de falhas em industrias de aço e papel.

Reatores: WATANABE e HIMMELBLAU (1984) aplicaram um filtro de Kalmán estendido e um estimador de estado linear a um reator simulado, FARELL e ROAT (1993) desenvolveram um sistema FDD baseado em dados histórico (Redes Neurais) aplicado a um CSTR contínuo na presença de ruídos e perturbações reais, via simulação, CHANG e CHEN (1995) estudaram a aplicação de Filtro de Kalmán estendido a reatores industriais, SEOK et al. (1997) desenvolvimento de árvore de sintomas, ZHANG et al. (1999) desenvolveram uma técnica de detecção e diagnóstico de falhas baseado em redes neuronais que foi aplicada a um processo de polimerização, YOON e MAcGREGOR (2001) empregaram análise de resíduos para a detecção e diagnóstico de falhas em CSTR com controle Feedback, MISRA et al. (2002) empregaram análise de componentes principais multi-escala em CSTR industrial. Sobre a técnica de PCA, vários autores se dedicaram ao estudo: TAMURA e TSUJITA (2007) realizaram um estudo desenvolvendo uma nova metodologia para a seleção do número de componentes principais empregados na técnica PCA para a detecção e diagnóstico de falhas, sendo este tópico objeto de estudo há algum tempo (CHIANG, RUSSEL, e BRAATZ (2001), KOURTI (2003); KRESTA,

MACGREGOR e MARLIN (1991) e MACGREGOR *et al.*(1994).). CHETOUANI (2004) utilizou um filtro de Kalmán estendido para a detecção de falhas em reator agitado que foi empregado em reatores para a oxidação de tri-sulfato de sódio por peróxido de hidrogênio.

Aplicações a Refinarias:

Colunas de Destilação e FCC: HIMMELBLAU (1979) investigou uma técnica de detecção e diagnóstico de falhas baseada na análise de ruídos em colunas recheadas. SHARMA et al. (2004) aplicação de redes neuronais em sistema de FDD em torres de destilação com recheios. VENKATASUBRAMANIAN et al. (1990) aplicaram redes neuronais para a detecção de falhas em torres de destilação. SUNDARRAMAN e SRINIVASAN (2003) desenvolveram um método de análise de tendências para detecção de falhas em colunas de destilação e unidades de FCC

Dessalgadoras: DAIGUJI et al. (1997) empregaram wavelets na detecção e diagnóstico de falhas.

Aplicações a Unidades de HDT: SALVATORE, PIRES, CAMPOS e DE SOUZA JR (2005) elaboraram um método de detecção e diagnóstico de falhas baseado em redes neuronais. DE SOUZA JR, CAMPOS e TUNALA (2006) desenvolveram uma técnica de detecção e diagnóstico de falhas com base na análise dinâmica de componentes principais, que tem por objetivo detectar distúrbios na concentração de enxofre na alimentação da unidade.

Os sistemas de diagnóstico necessitam de modelos que apresentem uma agilidade computacional, robustez e precisão nos resultados, e como a modelagem fenomenológica foi empregada como "processo real", pois não de dispunha de dados oriundos de plantas industriais, foi necessário o desenvolvimento de modelos empíricos.

Segundo a revisão bibliográfica, pode-se afirmar o pequeno emprego das Funções de Laguerre como modelagem simplificada de processos químicos. Os principais trabalhos encontrados foram: CLUETT e WANG (1991) empregaram uma modelagem simplificada empregando-se a Função de Laguerre para descrever o processo frente a uma perturbação degrau, obtendo ótimos resultados. Mais uma vez WANG e CLUETT (1995) empregaram

as Funções de Laguerre para modelar a função de transferência que descreve o processo em estudo através de dados obtidos em planta com ruídos presentes. WANG (2005) utilizou as Funções de Laguerre para modelagem do processo (Função de Transferência) para a utilização em controle preditivo discreto.

Quanto ao emprego da Técnica do Lookup Table, pode-se verificar a sua limitada utilização na literatura cientifica. ORILLE e SOWILAM (1999) empregaram a lookup table para o chaveamento das redes neurais que irão inicializar o controle de torque direcional do motor de indução obtendo chaveamentos ótimos. HEGRENÆS, GRAVDAHL e TØNDEL (2005) empregaram a técnica para armazenar os dados dos parâmetros dos componentes envolvidos no modelo para o controle preditivo da altitude de satélites espaciais. KOLAITIS e FOUNTI (2006) empregaram a técnica de Lookup Table para consultar de maneira ágil e confiável dados referentes aos parâmetros da reação cinética de oxidação do n-heptano.

Esta dissertação de mestrado visa o emprego destas técnicas apresentadas para a elaboração de uma metodologia para o desenvolvimento de sistema de diagnostico e detecção de falhas e aplicá-lo em uma unidade simulada de HDT.

3 - Metodologia

3.1 - Simulação do Modelo Fenomenológico

Por se tratar de um modelo descrito por dezenas de Equações Diferenciais Ordinárias (EDO's), o mesmo poderia apresentar um percalço no que se refere ao tempo de simulação quanto ao emprego do modelo para detecção e diagnóstico de falhas. Além disso, o modelo fenomenológico foi utilizado como "processo real", uma vez que não se dispunha de dados reais de planta industrial. Por esses motivos, foram propostos modelos empíricos que previam a alteração nas variáveis de entrada vazão e temperatura do componente A.

Foi necessária a simulação do modelo fenomenológico em condições operacionais pré-determinadas com o intuito de se obter dados para a calibragem dos modelos empíricos propostos.

Nestas simulações, a variável de entrada do modelo fenomenológico, concentração de entrada, foi mantida no valor do seu estado estacionário, a saber 22,0 mol/m³. A variável de entrada vazão, que possuía um valor de estado estacionário correspondente a 0,1 m³/s, foi alterada de ± 0,5 m³/s, onde cada passo de variação correspondeu a 0,005 m³/s. Concomitantemente, a variável temperatura de entrada, cujo valor de estado estacionário era 215,0 °C, foi alterada em 0,2°C, obedecendo os limites de ± 2,0 °C. Essas perturbações foram realizadas de maneira simultânea, isto é, para cada novo valor de temperatura de entrada, as vazões variavam em toda a sua amplitude. Desta forma, terminado o processo de análise, dispunha-se de um total de 441 casos simulados. O modelo fenomenológico foi simulado empregando-se o Software Matlab 6.5. O tempo de amostragem empregado na simulação foi de 50 segundos, perfazendo um total de 140 iterações, logo o tempo total de simulação foi de 7000 segundos.

3.2 - Modelagem Empírica Baseada na Função de Transferência Clássica

Para esta modelagem, configurou-se um modelo linear onde as contribuições da vazão de alimentação e da temperatura de alimentação foram separadas, calculadas isoladamente e depois somadas para o cômputo da estimativa da temperatura de saída do leito. Desta maneira, uma perturbação na vazão acarreta em uma resposta na função de transferência correspondente a esta variável, o mesmo ocorrendo com uma alteração na temperatura de alimentação. As equações, ilustradas a seguir, encontram-se no domínio de Laplace.

Resposta da Função de Transferência da Vazão de alimentação

Nesta etapa, isolou-se a influência da perturbação na vazão de alimentação do componente A sobre a temperatura de saída do primeiro leito do primeiro reator, através da identificação da função de transferência. O processo identificado contém três parâmetros: $K_p^{\ \nu}$, $\tau_1^{\ \nu}$ e $\tau_2^{\ \nu}$.

$$\Delta T_{v}(s) = Gu(s)\Delta u(s) \tag{3.2.1}$$

Onde:

$$G_u(s) = \frac{K_P^v}{\tau_1^v \tau_2^v s^2 + (\tau_1^v + \tau_2^v) s + 1}$$
(3.2.2)

Resposta da Função de Transferência da Temperatura da alimentação

Posteriormente, isolou-se a influência da perturbação na temperatura de alimentação do componente A sobre a temperatura de saída do primeiro leito do primeiro reator, através da identificação da função de transferência. O processo identificado apresentou três parâmetros: K_p^T , τ_1^T e τ_2^T .

$$\Delta T_T(s) = G_T(s)\Delta T(s) \tag{3.2.3}$$

Onde:

$$G_T(s) = \frac{K_P^T}{\left(\left(\tau_1^T s + 1\right)\left(\tau_2^T s + 1\right)\right)^4}$$
 (3.2.4)

Resposta Final do Modelo Empírico

A resposta final do modelo empírico em questão é obtida realizando-se a soma das parcelas da função de transferência da vazão com a função de transferência da temperatura de alimentação. Tem-se também que adicionar o valor do estado estacionário (236.3 °C) antes de impostas as perturbações desejadas, pois as funções de transferência apenas fornecem os valores referentes às variáveis desvios obtidas ao longo do tempo.

$$T_E = \Delta T_v + \Delta T_T + 236.3 \,^{\circ}C$$
 (3.2.5)

3.3 Modelagem Empírica Baseada na Função de Laguerre

Para esta modelagem, também se configurou um modelo linear em que as contribuições da vazão de alimentação e da temperatura de alimentação foram separadas e calculadas isoladamente e depois somadas para a estimativa da temperatura de saída do leito. Desta maneira, uma perturbação na vazão acarreta em uma resposta na função de transferência correspondente a essa variável, o mesmo ocorrendo com uma alteração na temperatura de alimentação.

Função de Laguerre para a Perturbação na Vazão de Alimentação

Para a perturbação na Vazão de Alimentação, a função de Laguerre foi truncada no terceiro termo da expansão, pois apresentou aderência aos dados padrões empregados como referência (modelagem fenomenológica).

$$\Delta T_{u}^{L} = G_{u}(s)\Delta u \tag{3.3.1}$$

onde:

$$G_{u}(s) = \sqrt{2p^{v}} \left[\frac{c_{1}^{v}}{s+p^{v}} + \frac{c_{2}^{v}(s-p^{v})}{(s+p^{v})^{2}} + \frac{c_{3}^{v}(s-p^{v})^{2}}{(s+p^{v})^{3}} \right]$$
(3.3.2)

Função de Laguerre para a Perturbação na Temperatura de Alimentação

Neste caso, também houve o truncamento da série infinita no terceiro termo da expansão, logo:

$$\Delta T_T^L = G_T(s)\Delta T \tag{3.3.3}$$

onde:

$$G_{T}(s) = \sqrt{2p^{T}} \left[\frac{c_{1}^{T}}{s+p^{T}} + \frac{c_{2}^{T}(s-p^{T})}{(s+p^{T})^{2}} + \frac{c_{3}^{T}(s-p^{T})^{2}}{(s+p^{T})^{3}} \right]$$
(3.3.4)

Resposta Final do Modelo de Laguerre

Semelhante ao modelo de Função de Transferência Clássica, os modelos descritos pelas Equações 3.3.1 e 3.3.3, descrevem a colaboração em termos de variação ao longo do tempo, logo para termos a resposta final, fez-se necessário somar as parcelas ao estado estacionário.

$$T_E^L = \Delta T_T^L + \Delta T_u^L + 236,30 \,^{\circ}C \tag{3.3.5}$$

3.4 Estimação

A etapa de estimação dos parâmetros dos modelos descritos no tópico anterior foi realizada com o emprego do Software MatLab 6.5.

Nesta dissertação, a função objetivo empregada foi a dos mínimos quadrados. O método de otimização determinístico utilizado foi a função "fmins" disponível no Matlab 6.5, com base no Método Simplex Nelder-Mead.

$$F_{OBJ} = \sum (y_{est} - y_{exp})^2 \tag{3.4.1}$$

onde: F_{OBJ} - É a função objetivo;

 y_{est} – É a estimativa da variável através do simulador;

 $y_{exp} - \acute{E}$ o valor real (experimental) da variável;

Cálculo dos Parâmetros $K_P^T e K_P^v$

Com os valores dos estados estacionários, inicial e final, e o valor da perturbação, é possível calcular o valor do ganho estático para cada perturbação imposta ao modelo: Primeiramente, é imposta uma perturbação na variável de entrada temperatura de alimentação:

$$K_P^T = \frac{y_{out} - y_{EE}}{\Delta T} \tag{3.4.2}$$

Logo após, é imposta uma perturbação na vazão de alimentação, logo conhecendo o ${K_P}^T$ e a perturbação na temperatura de alimentação, pode-se calcular o ${K_P}^v$, pela equação abaixo:

$$K_P^V = \frac{\left(y_{out} - y_{EE}\right) - \left(K_P^T \Delta T\right)}{\Delta u} \tag{3.4.3}$$

onde:

- y_{out} É o final da variável de saída do modelo (temperatura de saída do leito do reator);
- y_{EE} É o valor do estado estacionário, antes das perturbações, da temperatura de saída do leito do reator
- Δu- Perturbação imposta na vazão de alimentação do reator.
- ΔT Perturbação imposta na temperatura de alimentação do reator

3.4.1 Parâmetros do Modelo Função de Transferência

Para cada nova condição operacional simulada, o otimizador busca o ótimo para os parâmetros do novo modelo proposto.

A etapa de estimação foi dividida em duas partes, de maneira que para facilitar a busca pelo ponto de melhor performance, foram criadas duas funções objetivos. Na primeira etapa, apenas foi fornecida a perturbação na variável de entrada temperatura, onde foi acionado o programa estimador, que gerou os parâmetros ótimos para esta condição $(K_p^T, \tau_1^T e \tau_2^T)$. Essa resposta obtida, serviu de "chute inicial" para a otimização final que buscou a melhor resposta variando os parâmetros $\tau_1^v, \tau_2^v, \tau_1^T e \tau_2^T$ de maneira simultânea, ao passo que os parâmetros $K_p^T e K_p^v$ foram calculados através das equações 3.4.2 e 3.4.3, respectivamente.

3.4.2 Parâmetros do Modelo Função de Laguerre

A estimação dos parâmetros do modelo baseado em função de Laguerre seguiu o mesmo procedimento descrito no item anterior. Isto é, empregaram-se dados da simulação do modelo fenomenológico, para cada nova condição operacional simulada, o estimador procurou o ótimo para os parâmetros do novo modelo proposto.

A etapa de estimação também foi dividida em duas partes, de maneira a facilitar a busca pelo ponto ótimo dos parâmetros, foram criadas duas funções objetivos. Na primeira etapa, apenas foi fornecida a perturbação na variável de entrada temperatura, onde foi acionado o programa otimizador, que gerou os parâmetros ótimos para esta condição do modelo da função de Laguerre, para a temperatura (p^T, c₁^T, c₂^T e c₃^T),. Os resultados obtidos

serviram de "chute inicial" para a estimação final que buscou a melhor resposta variando os parâmetros p^v , c_1^v e c_2^v para a vazão e p^T , c_1^T e c_2^T para a temperatura, de maneira simultânea, ao passo que os parâmetros c_3^v e c_3^T foram calculados através das equações abaixo:

$$c_3^{\nu} = \frac{K_P^{\nu}}{\sqrt{\frac{2}{p^{\nu}}}} + c_2^{\nu} - c_1^{\nu} \tag{3.4.2.1}$$

$$c_3^T = \frac{K_P^T}{\sqrt{\frac{2}{p^T}}} + c_2^T - c_1^T \tag{3.4.2.2}$$

3.5 Problemas da Não Linearidade

Nas duas modelagens empíricas propostas, devido a não linearidade do processo em estudo, todos os parâmetros apresentaram valores diferentes para cada nova condição operacional simulada.

Para predizer os parâmetros para cada condição operacional foram empregadas redes neuronais para o modelo baseado em função de transferência, e a técnica de "Lookup Table" aliada à função interpoladora, para o modelo baseado na função de Laguerre.

3.6 Treinamento das Redes Neuronais

Para o treinamento das redes neuronais adotadas no modelo da função de transferência, foi empregado o recurso IPS ("Intelligent Problem Solver") do módulo "Statistica Neural Networks", do "software" "Statistica 7.1".

Segue uma descrição do procedimento utilizado para o desenvolvimento de cada rede neuronal.

As saídas das redes neuronais foram os Parâmetros do modelo: para a vazão: ${\tau_1}^v,\,{\tau_2}^v$ e ${K_p}^v)$ e para a função de transferência da variável temperatura: ${K_p}^T$, ${\tau_1}^T$ e ${\tau_2}^T$ e as

entradas (delta de vazão e o delta de temperatura). No "Statistica", todas as variáveis precisam ser classificadas entre contínuas ou categóricas, sendo o caso em estudo correspondente ao primeiro tipo.

No módulo IPS, solicitou-se o estudo de 1000 redes e a retenção das 5 melhores (com o menor erro de correlação). Esta metodologia foi repetida por diversas vezes até o melhor ajuste ser encontrado. As redes testadas foram do tipo linear e "*Multilayer Perceptron*", para as redes de temperatura e vazão, respectivamente, com uma camada escondida apenas (Para a rede MLP). Foram testadas redes com 1 a 10 neurônios na camada escondida.

Dentre os casos disponíveis, foram selecionados aleatoriamente 2/3 para treinamento, 1/3 para seleção, empregando-se a técnica de *Bootstrap resampling*: quando este botão é selecionado, na aba *Quick*, uma aba *Bootstrap* será adicionada à caixa de diálogo. Quando a amostragem *bootstrap* é feita, o subconjunto de *Treinamento* é reamostrado (com substituição) para criar um conjunto maior de casos para treinar a rede. O subconjunto de *Seleção* é tem tamanho fixo sendo removido antes que a amostragem dos casos remanescentes comecem a criar o subconjunto de *Treinamento* (o subconjunto de *Treinamento*) (DE SOUZA Jr., 2001a e b).

Na análise estatística, a razão SD representa a divisão entre o desvio padrão obtido da diferença entre os valores preditos e as saídas alvo, e o desvio padrão para a diferença entre as saídas alvo e sua média. Na prática, a razão SD é a razão entre o desvio da predição e o desvio dos dados reais em relação a sua média. Portanto, quanto menor é esta razão, melhor é o modelo de regressão. As redes com melhores desempenhos apresentam este valor o mais próximo de zero (DE SOUZA Jr., 2003).

Selecionadas as condições, o módulo IPS procede treinamentos e a seleção para encontrar a melhor rede, retornando, ao final, os valores da razão de regressão, do erro e da razão SD, de modo que, para esta variável, quanto mais próxima de zero, melhor a classificação da rede. Este procedimento pode ser repetido por várias vezes para retreinamento das redes e para obtenção de novas redes, sendo analisados gráficos dos valores preditos *versus* observados, parâmetros estatísticos e de sensibilidade, além dos erros e das performances (razões SD) para cada etapa do desenvolvimento.

Além da razão SD, a análise estatística do módulo de redes neuronais reporta ainda:

 Erro médio: erro médio obtido a partir da diferença entre o valor de saída alvo e o obtido pela rede;

$$EM = \frac{1}{n} \sum_{i=1}^{n} e_{i}$$
 (3.6.1)

tal que:

EM = Erro Médio

e_i = Erro para cada variável de saída (diferença entre o valor alvo e o estimado)

n = Número de variáveis

 Erro médio absoluto: Erro absoluto médio obtido a partir da diferença entre os valores alvo e os estimados.

$$EMA = \frac{1}{n} \sum_{i}^{n} |e_{i}|$$
(3.6.2)

tal que:

EMA = Erro Médio Absoluto

e_i = Erro para cada variável de saída (diferença entre o valor alvo e o estimado)

n = Número de variáveis

A análise de sensibilidade das variáveis de entrada demonstra as contribuições relativas de cada variável usada pelos modelos. Cada variável é tratada como se não estivesse disponível para análise, sendo substituída pelo seu valor médio. O erro total da rede quando a variável está "indisponível", é dividido pelo erro total da rede quando a mesma está "disponível", o que resulta em uma razão que deverá ter um valor maior que 1,0 se há contribuição da variável em questão para a solução do problema (STATISTICA, 1984).

O sumário do modelo apresenta as performances ou razões SD para treino e seleção e o erro para cada etapa. Este erro corresponde ao parâmetro minimizado durante o desenvolvimento da rede, cuja equação encontra-se em 2.4.4.

Ao final do desenvolvimento, a melhor rede escolhida pode ser codificada em linguagens C ++ e "statistica visual basic", para a confecção de uma interface amigável, voltando à tela de escolha do módulo e escolhendo "Code Generator".

Essa rede neuronal foi implementada em um programa escrito em FORTRAN, onde foi gerado um executável que por sua vez, era acionado pelo programa principal desenvolvido no MatLab 6.5.

3.7 Aplicação do Lookup Table

Esta técnica foi aplicada no modelo baseado na Função de Laguerre, empregou-se um arquivo organizado, contendo nas linhas as condições operacionais em ordem crescente, localizando-se nas duas primeiras colunas, sendo a primeira da vazão e a segunda da variável Temperatura e nas outras colunas, os parâmetros otimizados para o modelo de Laguerre.

3.8 Interpolação

A função interpoladora de Lagrange foi empregada no Modelo da Função de Laguerre para propiciar a obtenção dos valores dos parâmetros nas condições operacionais não simuladas com o Modelo Fenomenológico.

A interpolação foi procedida como descrito a seguir: Dadas as condições operacionais desejadas, o programa construído em FORTRAN 90 fez uma busca, através da técnica do "Lookup Table", de modo a saber qual vazão e temperatura estão mais próximas do ponto dado. De posse destes pontos, procede-se a interpolação quanto a primeira variável (temperatura) e após, empregando-se a saída da primeira interpolação, realiza-se a segunda, com relação à vazão. A subrotina interpoladora empregada foi a POLIN2.F90, que faz aplicação de uma outra função interpoladora (POLINT.F90) que é a subrotina de interpolação propriamente dita, ambas estão disponíveis na biblioteca pública Numerical Receipes (PRESS *et al.*, 2007).

3.9 Introdução do Ruído Randômico e Cálculo dos Resíduos.

A partir deste ponto, apesar das simplificações impostas ao modelo fenomenológico, será feita referência ao mesmo como sendo rigoroso e o modelo empírico como simplificado, apenas para fins de nomenclatura.

O ruído introduzido na variável temperatura de saída do primeiro leito do primeiro reator, seguiu a seguinte regra de formação:

$$Y_i^{RIG} = y_i^{RIG} + 0.001 \times y_i^{RIG} \times Rdo(i)$$
 (3.9.1)

onde Y_i^{RIG} é a nova saída com ruído da temperatura do leito em estudo para o modelo fenomenológico. Rdo é um ruído randômico gerado com distribuição normal com média zero e desvio padrão igual a 1.

Com a introdução dos ruídos, foi possível o cálculo dos resíduos, que foi realizado de acordo com a equação abaixo:

$$R_i = Y_i^{RIG} - y_i^{SIM}$$
 (3.9.2)

onde y_i^{SIM} é a variável de saída do modelo empírico (simplificado).

3.10 Controle Estatístico do Processo

Para analisar a variabilidade dos resíduos foram empregadas as cartas de Shewhart, para medidas individuais, uma vez que não tínhamos duplicatas nem triplicatas de todos os casos em estudo, o CUSUM Tabular, o CUSUM Padronizado e o MMEP. Para a construção dos limites de controle dos gráficos foram utilizados os dados dos resíduos relativos ao estado estacionário, sendo este o único caso em que se realizaram simulações em duplicata. O intuito desta análise, primordialmente, era comprovar que os resíduos do estado estacionário encontravam-se sob controle estatístico, bastando, para isso, que não apresentassem desvio significativo em sua média, ou pontos fora dos limites de controle. Também analisar qual a Carta a ser empregada para o acompanhamento do processo, sendo uma opção para a ativação do sistema FDD.

3.11 Detecção e Diagnóstico de Falhas

Casos Estudados

As condições operacionais da Tabela 2 foram empregadas para a realização de simulações do processo com o objetivo de elaborar o sistema de detecção e diagnóstico de falhas.

Tabela 2-Condições Operacionais dos Casos estudados

Caso	Concentração (mol/m³)	Vazão (m³/s)	Temperatura (°C)	Situação do Processo
1	22,0	0,100	215,0	Condição Normal
2	17,0	0,100	215,0	Condição Normal
3	22,0	0,070	215,0	Condição Normal
4	17,0	0,070	215,0	Condição Normal
5	24,5	0,115	215,0	Alta Concentração e Fluxo
6	24,5	0,055	215,0	Alta Concentração e Baixa Vazão
7	14,5	0,115	215,0	Baixa Concentração e Alta Vazão
8	14,5	0,055	215,0	Baixa Concentração e Vazão
9	24,5	0,100	215,0	Alta Concentração
10	14,5	0,100	215,0	Baixa Concentração
11	22,0	0,055	215,0	Baixa Vazão
12	22,0	0,115	215,0	Alta Vazão
13	17,0	0,055	215,0	Baixa Vazão
14	17,0	0,115	215,0	Alta Vazão
15	24,5	0,070	215,0	Alta Concentração
16	14,5	0,070	215,0	Baixa Concentração

O processo de detecção e diagnóstico de falhas consistiu na análise de uma dada condição operacional. Comparam-se os resíduos gerados com os resíduos dos 16 casos padrões (ver Tabela 2) em análise. Indica-se, desta forma, qual o mais próximo da condição operacional em análise. Como o modelo empírico possui como variáveis de entradas, apenas a vazão e a temperatura de alimentação, pode-se concluir facilmente que perturbações na concentração de entrada não podem ser previstas pelo modelo empírico, acarretando desta maneira, em um deslocamento das médias dos resíduos ao longo do tempo, isto é, o perfil dos resíduos apresenta uma clara tendência.

O algoritmo empregado para a localização do caso padrão mais próximo funciona da seguinte maneira:

-Simula-se o caso novo que corresponde (por analogia) aos dados do processo real em análise, tanto com o modelo fenomenológico quanto com o modelo empírico. De posse dos dados simulados, pode-se calcular o resíduo da nova condição operacional. Esse novo resíduo foi comparado ponto a ponto ao longo da simulação com os 16 casos padrões

mostrados na Tabela 2. Verifica-se para cada ponto qual o caso mais próximo, para tal compara-se o valor absoluto da diferença entre o resíduo do caso novo e os 16 casos. Logo após, verificou-se qual dos casos apresentou o maior número de pontos mais próximos do caso novo, obtêm-se, então o caso "vencedor". O programa foi configurado para proceder essa busca a cada 30 minutos, sendo o tempo de amostragem igual a 50 segundos e o tempo final da simulação igual a 7000 segundos.

Para os casos em que a variável de entrada, concentração, não sofreu alterações, os resíduos deveriam apresentar a média dos resíduos igual a zero, o algoritmo, neste caso, não possui capacidade de discernir entre os 4 casos que não apresentam alterações nesta variável (Casos 1, 3, 11 e 12 – ver Tabela 2). Então o programa simplesmente apresenta como saída a variável perturbada que no caso, sem dúvida, será a vazão, que pode ser facilmente lida na planta industrial, através do sistema supervisório.

4 - Resultados e Discussões

Neste capítulo são apresentados os resultados obtidos através dos modelos baseados na função de Transferência com parâmetros fornecidos pelas Redes Neuronais e na função de Laguerre com parâmetros obtidos empregando-se a técnica de Lookup Table aliada à interpolação de Lagrange, fundamentando, desta maneira, a escolha do modelo mais adequado ao modelo fenomenológico. Posteriormente, investigou-se o comportamento estatístico quanto à variabilidade dos resíduos obtidos com o melhor modelo empírico, através das construções dos gráficos de controle estatístico de Shewhart (Medidas individuais), CUSUM Tabular, CUSUM padronizado e MMEP. Em seguida, mostra-se o resultado obtido pelo emprego do método de classificação e diagnóstico de falhas.

4.1 Dinâmica do Processo de Hidrotratamento

Neste tópico é estudada a influência de perturbações nas variáveis de entrada (vazão de alimentação e temperatura de alimentação) na variável de saída, onde se empregou o modelo fenomenológico proposto por CARNEIRO (1992).

4.1.1 Influência da Perturbação na Temperatura de Alimentação

As Figuras 11 a 14 ilustram o comportamento da Temperatura de saída do primeiro leito do primeiro reator frente a uma perturbação na temperatura de alimentação inserida no tempo t=0.0s. A concentração de alimentação foi mantida constante com valor de 22,0 mol/m³, assim como a vazão de alimentação em 0,1 m³/s e a Temperatura de alimentação, antes de introduzida a perturbação era 215,0 °C.

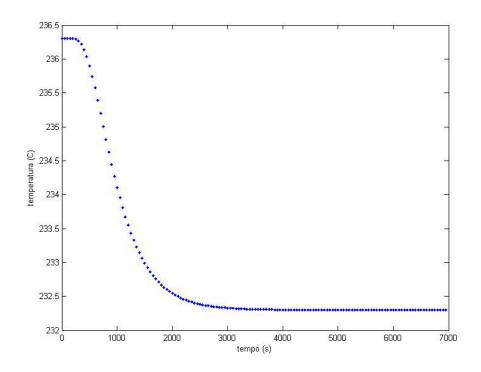


Figura 11-Temperatura de Saída do Reator com Temperatura de Alimentação de 213,0 °C

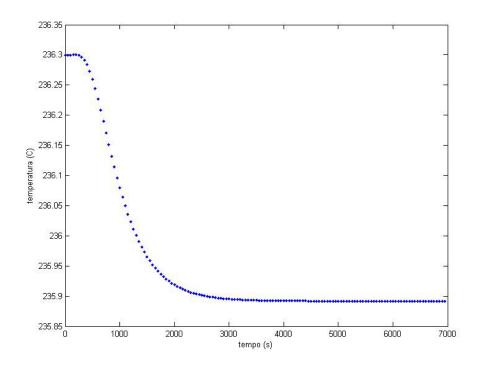


Figura 12-Temperatura de Saída do Reator com Temperatura de Alimentação de 214,8 °C

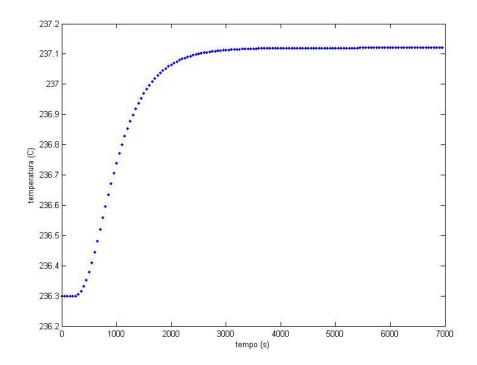


Figura 13-Temperatura de Saída do Reator com Temperatura de Alimentação de 215,4 °C

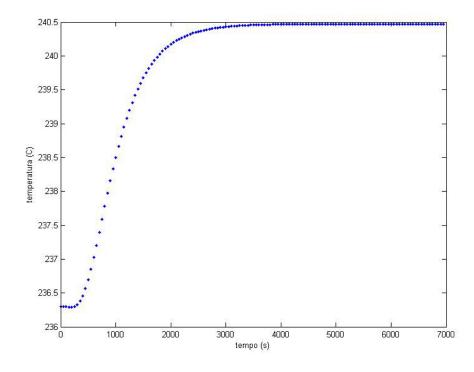


Figura 14-Temperatura de Saída do Reator com Temperatura de Alimentação de 217,0 °C

Pela análise das Figuras 11 a 14, pode-se verificar a influência direta da perturbação na temperatura de alimentação sobre a temperatura de saída do primeiro leito do primeiro reator, isto é, um aumento na temperatura de alimentação acarreta em uma elevação na temperatura de saída, justificando-se este fato devido ao aumento da taxa de reação e uma vez que as reações são exotérmicas, em sua maioria, a temperatura final de saída tende a se elevar. Também podemos verificar a existência de um tempo morto na dinâmica do processo, isto é, uma vez imposta a perturbação, o processo necessita de um certo tempo para refletir esta mudança, devido a modelagem do processo prever a passagem das variáveis através de doze reatores CSTR em série. Estes fatos fornecem a dimensão da complexidade da modelagem do processo em estudo. A Figura 11 apresentou um ganho estático igual a 2,000, enquanto que as Figuras 12, 13 e 14 apresentaram valores iguais a 2,041, 2,051 e 2,085 respectivamente, isso indica que o processo apresenta uma não-linearidade, possuindo valores diferentes de ganho estático para cada condição operacional simulada. No próximo tópico estudar-se-á a influência da perturbação na vazão de alimentação.

4.1.2 Influência da Perturbação na Vazão de Alimentação

Nas Figuras 15 a 18, analisa-se a influência da perturbação na vazão de alimentação sobre a temperatura de saída do primeiro leito do primeiro reator, mantendo-se inalteradas as variáveis temperatura e concentração em 215,0 °C, 22,0 mol/m³, respectivamente. O valor da vazão de alimentação antes da perturbação correspondia a 0,1 m³/s.

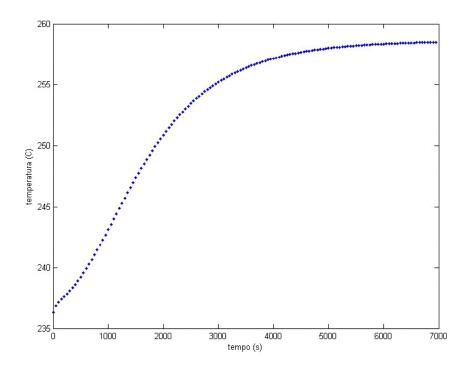


Figura 15-Temperatura de Saída do Reator com Vazão de Alimentação de 0,050 m³/s

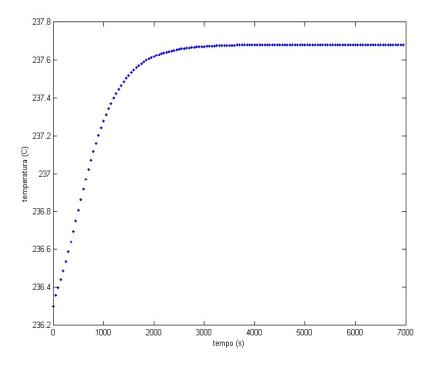


Figura 16-Temperatura de Saída do Reator com Vazão de Alimentação de 0,095 m³/s

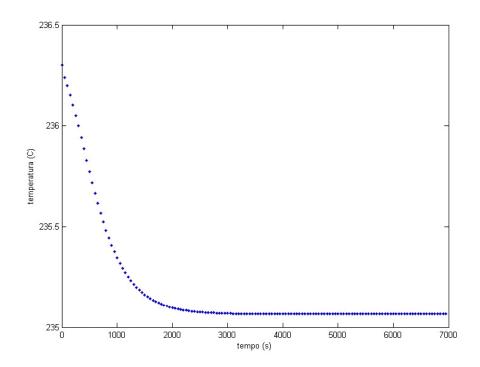


Figura 17-Temperatura de Saída do Reator com Vazão de Alimentação de $0,105~\text{m}^3/\text{s}$

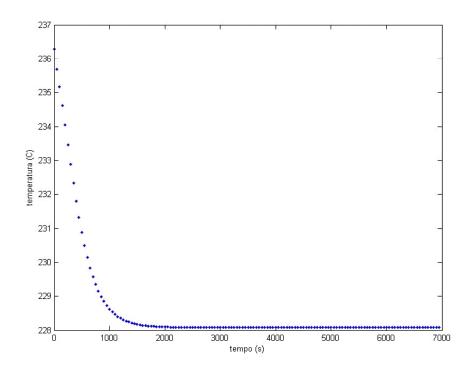


Figura 18-Temperatura de Saída do Reator com Vazão de Alimentação de $0,150~\text{m}^3/\text{s}$

Pela análise das Figuras 15 a 18, pode-se estudar influência inversa da perturbação na variável de entrada vazão de alimentação sobre a temperatura de saída do primeiro leito do primeiro reator, isto é justificado devido ao fato de que uma elevação na vazão de alimentação leva a um aumento na velocidade espacial mássica o que acarreta uma diminuição na severidade do processo – diminuição do tempo de residência, gerando assim menos calor através da reação química – e conseqüentemente, a uma temperatura menor da saída do reator.

Por meio do cálculo do ganho estático, para cada condição operacional, confirmouse a tendência do processo de apresentar uma não linearidade, pois os valores dos K_P 's apresentaram discrepâncias entre si. Para as Figuras 15, 16, 17, e 18, os valores do ganho estático foram -444,181; -276,338; -247,089 e -164,426.

Pela análise dos gráficos, pode-se afirmar que o modelo não apresenta tempo morto ou dinâmica inversa.

4.1.3 Influência combinada entre as perturbações na temperatura e vazão de alimentação

Nas Figuras 19 a 22, verifica-se o efeito das combinações das perturbações na vazão e temperatura de alimentação sobre a temperatura de saída do reator, mantendo-se constante a concentração de entrada em 22,0 mol/m³. Os valores do estado estacionário da vazão e temperatura de alimentação estão descritos nos tópicos 4.1.1 e 4.1.2.

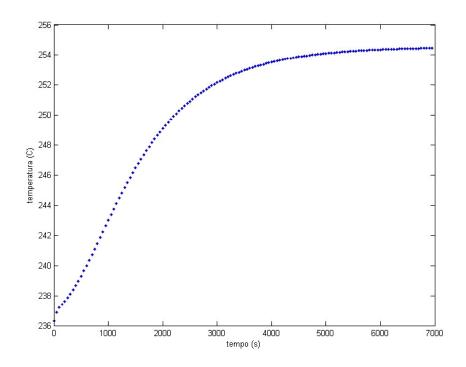


Figura 19-Temperatura de Saída do Reator com Vazão de Alimentação de 0,050 m³/s e Temperatura 213,0 °C

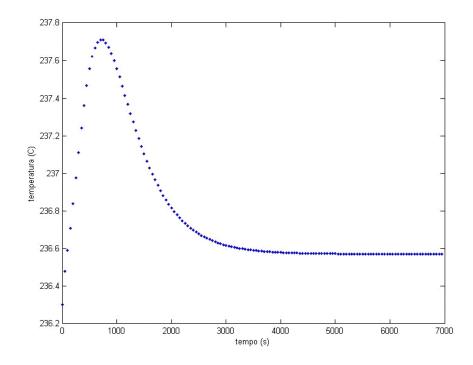


Figura 20-Temperatura de Saída do Reator com Vazão de Alimentação de 0,085 m³/s e Temperatura 213,0 °C

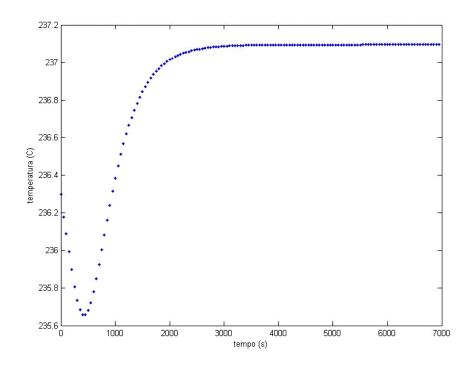


Figura 21-Temperatura de Saída do Reator com Vazão de Alimentação de 0,110 m³/s e Temperatura 216,6 °C

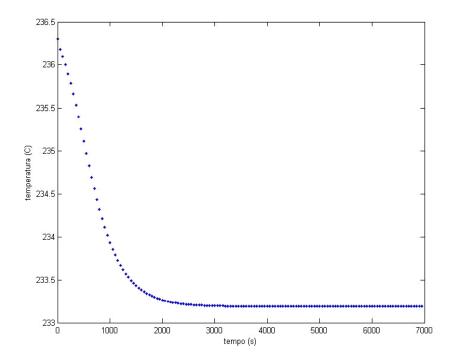


Figura 22-Temperatura de Saída do Reator com Vazão de Alimentação de 0,110 m³/s e Temperatura 214,6 °C

Pela análise da Figura 19, pode-se verificar o efeito combinado de perturbações com delta negativo em ambas as variáveis de entrada, evidencia-se, desta forma, a disputa entre efeitos antagônicos, pois uma diminuição na vazão acarreta em uma elevação da temperatura de saída do reator, ao passo que uma diminuição na temperatura de entrada propicia uma diminuição na referida temperatura, pode-se verificar que a dinâmica da vazão teve efeito preponderante neste caso.

Na Figura 20, onde se introduziu um delta negativo pequeno na vazão e em contrapartida um delta de maior magnitude para a temperatura de alimentação, verifica-se a existência da dinâmica inversa. Inicialmente, o delta negativo da vazão, por ser a dinâmica mais veloz leva a um aumento da temperatura de saída do reator, mas com o passar do tempo, a dinâmica da temperatura de alimentação passa a ser preponderante, forçando a diminuição da temperatura de saída.

Na Figura 21 tem-se o mesmo efeito reproduzido pelas condições do gráfico anterior, só que havendo a inversão do sinal dos deltas, a perturbação na vazão passa a ser positiva e a da temperatura negativa, mas aplicando-se os mesmos princípios, a análise é análoga à anterior.

Na Figura 22, apresentam-se condições operacionais que possuem efeitos similares. O aumento da vazão e a diminuição da temperatura levam a uma temperatura de saída mais baixa. Outro fato que precisa ser evidenciado é que devido à dinâmica da vazão ser muito rápida ela praticamente anula a presença do tempo morto inserido pela dinâmica da temperatura, podendo o mesmo ser observado quando se mantém a vazão em seu estado estacionário, fato que poder ser observado nas Figuras 11 a 14.

4.2 Função de Transferência

4.2.1. Estimação dos Parâmetros

A estimação dos parâmetros da função de Transferência proposta para o modelo empírico foi realizada empregando-se o otimizador determinístico disponível na função "fmins" do Software MatLab 6.5. Ao todo foram estimados 4 parâmetros de maneira simultânea ($\tau_1^{\ v}$ e $\tau_2^{\ v}$ – Para o modelo da vazão e $\tau_1^{\ T}$ e $\tau_2^{\ T}$ para o modelo da temperatura) enquanto que $K_p^{\ v}$ e $K_p^{\ T}$ (Ganhos estáticos das Funções de Transferência) foram calculados

através das equações (3.2.3 e 3.2.4). A função objetivo proposta para a referida otimização foi a dos mínimos quadrados, ver a equação 3.4.1.

Nesta etapa, o valor referente a variável concentração de alimentação foi mantida em seu estado estacionário, 22,0 mol/m³.

Nas Figuras 23 a 26, ilustra-se o resultado obtido com a etapa de estimação dos parâmetros da Função de Transferência Clássica, os gráficos foram selecionados de maneira a elucidar dois comportamentos da dinâmica do processo, direta ou inversa.

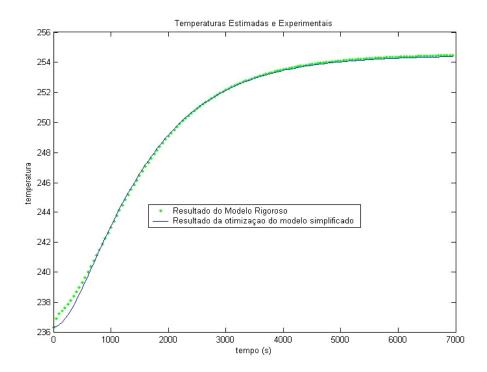


Figura 23-Resultado da Otimização dos parâmetros para a condição operacional: vazão -0,050 m³/s e temperatura 213,0 °C

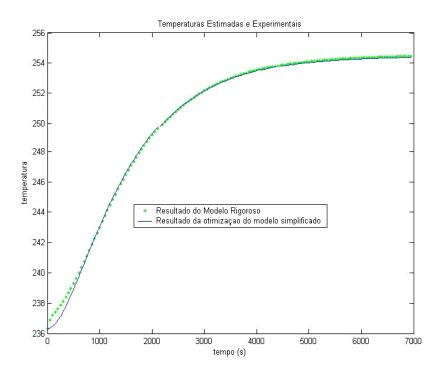


Figura 24-Resultado da Otimização dos parâmetros para a condição operacional: vazão -0,090 m³/s e temperatura 213,8 $^{\circ}$ C

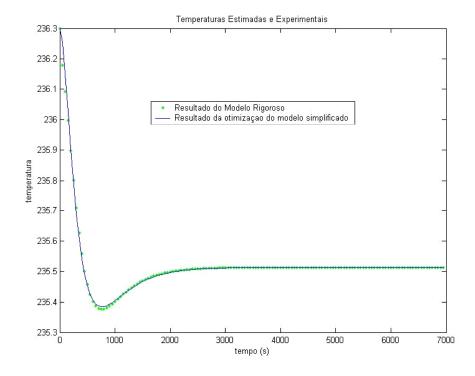


Figura 25-Resultado da Otimização dos parâmetros para a condição operacional: vazão -0,110 m³/s e temperatura 215,4 $^{\circ}\mathrm{C}$

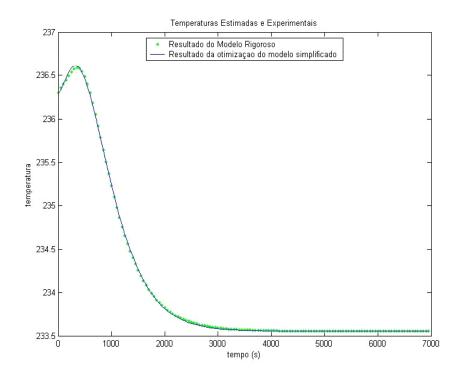
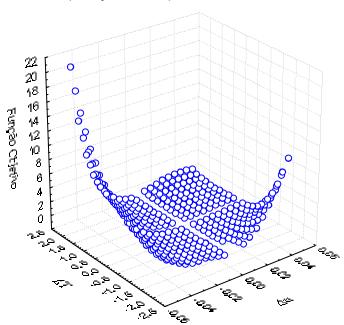


Figura 26-Resultado da Otimização dos parâmetros para a condição operacional: vazão -0,950 m³/s e temperatura 215,4 °C

Pela análise das Figuras 23 a 26, pode-se concluir que a otimização dos parâmetros proposta para o modelo fundamentado na função de Transferência, atendeu ao objetivo esperado. A função objetivo proposta sempre apresentou valores inferiores a 20, para um universo de 140 pontos de amostragem, para cada condição operacional proposta.

Na Figura 27, pode-se observar o comportamento da função objetivo em função dos deltas de vazão e temperatura. Essas funções objetivo referem-se ao valor final obtido ao final da estimação dos parâmetros. Observa-se que o maior valor obtido para a função objetivo foi menor que 20. Verifica-se que o otimizador encontrou dificuldades (resultados menos satisfatórios) para a região em que se introduziram perturbações elevadas na temperatura e vazão de alimentação com sinais de perturbação opostos, isto é, perturbação elevada positiva na temperatura e negativa na vazão ou vice-versa. No entanto, quando se perturbou de maneira suave umas destas variáveis, houve facilidade na convergência do otimizador, com uma função objetivo final diminuta. Apesar de apresentar uma função objetivo de maior magnitude, as condições operacionais de maior dificuldade de

convergência quando simuladas através do modelo simplificado mostraram aderência ao modelo fenomenológico.



Função Objetivo da Função de Transferência Clássica

Figura 27-Função Objetivo da Função de Transferência em relação a Delta V e Delta T

Parâmetros da Função de Transferência Clássica

Nas Figuras 28 a 33, ilustra-se o comportamento dos parâmetros $K_p^{\ v}$, $\tau_1^{\ v}$, $\tau_2^{\ v}$, $K_p^{\ T}$, $\tau_1^{\ T}$ e $\tau_2^{\ T}$ em função das perturbações impostas na temperatura e vazão de alimentação. Pode-se observar que os parâmetros $K_p^{\ v}$, $\tau_1^{\ v}$, $\tau_2^{\ v}$, Figuras 28, 29 e 30 respectivamente, apresentam uma grande variação em função das perturbações impostas. Para estes parâmetros, tanto Δv quanto ΔT apresentam uma grande influência, com uma dependência não linear. Justifica-se, desta maneira, o emprego de uma rede neuronal do tipo MLP para a predição destes parâmetros.

No entanto, quando analisa-se os parâmetros K_p^T , τ_1^T e τ_2^T - Figuras 31, 32 e 33 respectivamente, verifica-se que esses parâmetros não apresentam variações intensas e que não sofrem influências em virtude de perturbações impostas na vazão de alimentação. Neste caso, aplicou-se uma rede linear para a predição destes parâmetros.

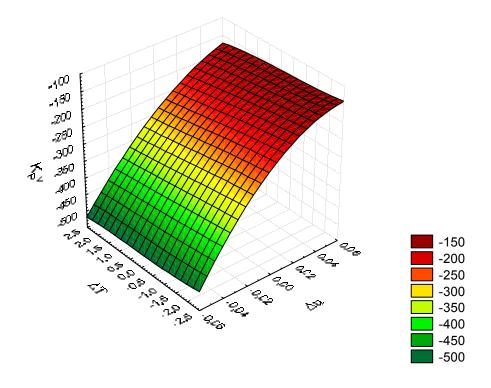


Figura 28- $K_P^{\ v}$ em função de Δu e ΔT

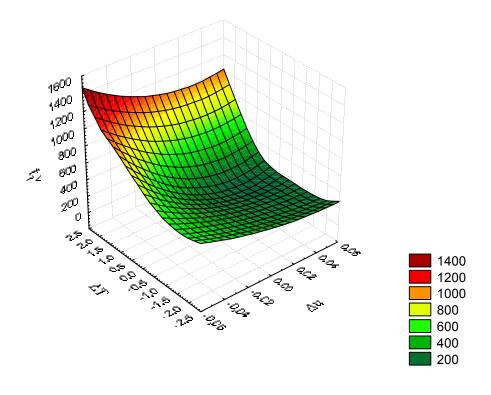


Figura 29- ${\tau_1}^v$ em função de Δu e ΔT

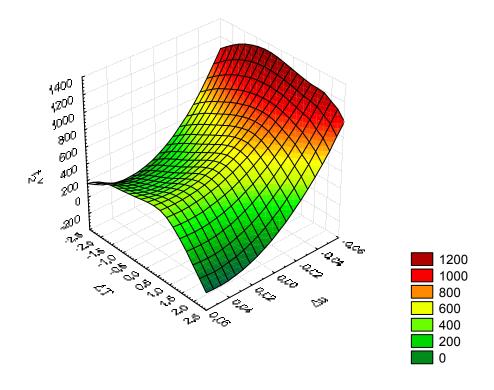


Figura 30- $au_2^{\, v}$ em função de Δv e ΔT

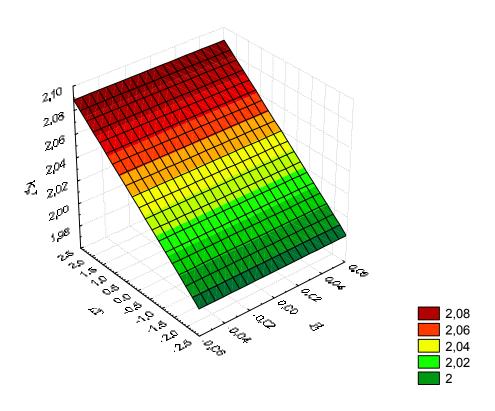


Figura 31- K_P^T em função de Δv e ΔT

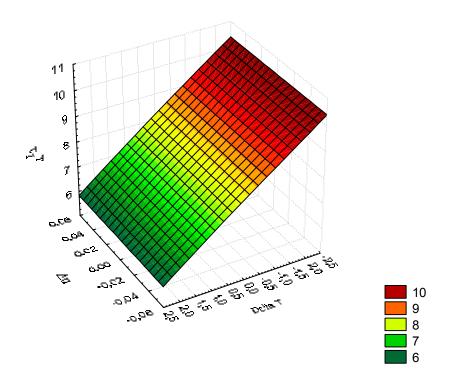


Figura 32- ${\tau_1}^T$ em função de Δu e ΔT

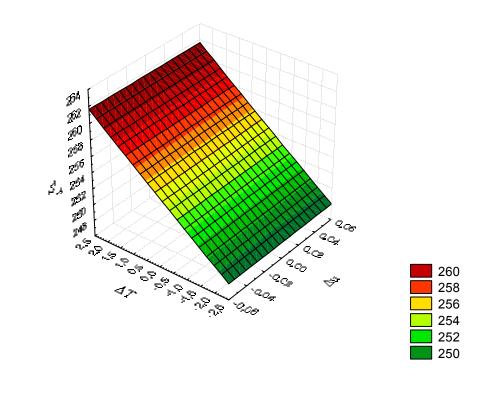


Figura 33- ${\tau_2}^T$ em função de Δu e ΔT

4.2.2 Treinamento das Redes

O conjunto de dados de empregados para o treinamento das redes neuronais perfez um total de 377 casos gerados para a estimação dos parâmetros do modelo.

4.2.2.1 Rede Neuronal para os Parâmetros K_p^T , $\tau_1^T e \tau_2^T$

As entradas para a rede neuronal selecionadas foram os deltas de vazão e temperatura e as variáveis de saída os parâmetros do modelo: Kp^T , τ_1^T , τ_2^T .

A melhor rede neuronal selecionada, indicada com uma performance de treinamento "excelente", foi uma Linear do tipo (1:3), a rede apresenta um neurônio na camada de entrada e três na camada de saída (não apresenta camada escondida). Os neurônios das camadas de entrada e saída apresentam funções de ativação lineares. O algoritmo "Pseudo Inversa" (PI) foi empregado para a otimização dos parâmetros internos da rede. Nas Tabelas 3 e 4 é possível visualizar a análise estatística e a análise de sensibilidade para a melhor rede Linear encontrada.

Tabela 3-Análise estatística para a rede neuronal da Temperatura

	Кр ^т	${f au_1}^{ m T}$	${f au_2}^{ m T}$
Média dos Dados	2,037	8,159	254,806
S.D. Dados	0,026	1,124	3,380
Média dos Erros	0,000	0,004	-0,003
S.D. Erros	0,000	0,022	0,024
Erro Absoluto	0,000	0,016	0,019
Razão S.D.	0,005	0,020	0,007
Correlação (R ²)	0,999	0,999	1,000

Pela análise da Tabela 3, destaca-se que a razão SD calculada apresentou um valor muito pequeno, o que leva a concluirmos que a rede originada apresenta uma capacidade excelente de predição, com todos as correlações apresentando valores muito próximos de 1,00.

Tabela 4-Análise de Sensibilidade

	ΔΤ
Razão	78,218
Importância	1

Pela Tabela 4, pode-se concluir que para a rede neuronal treinada para a predição dos parâmetros do modelo de temperatura, a entrada delta de vazão não apresentou uma importância significativa nos resultados, sendo eliminada na análise, portanto o delta da temperatura foi a única entrada necessária.

4.2.2.1.1 Predições dos Parâmetros da rede da temperatura

As Figuras 34 a 36 ilustram o comportamento dos dados dos parâmetros preditos contra os observados para K_P^T , τ^T_1 e τ^T_2 .

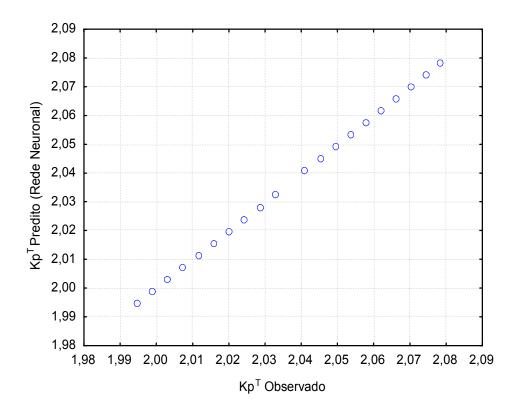


Figura 34-Observado x Predito para o Parâmetro K_P^T

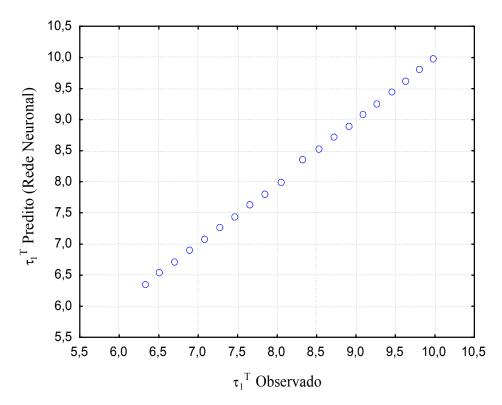


Figura 35-Observado x Predito para o Parâmetro τ_1^T

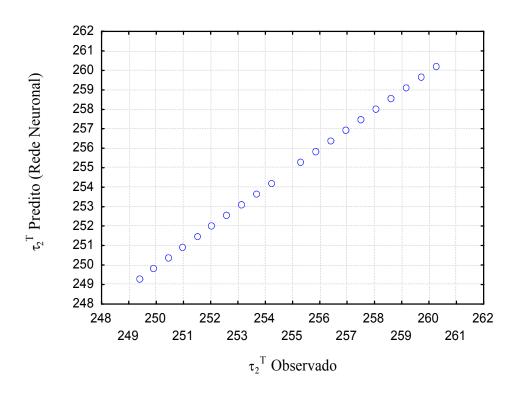


Figura 36-Observado x Predito para o Parâmetro τ_2^T

Observa-se através da análise das Figuras 34, 35 e 36, a excelente capacidade de predição da rede neuronal dos parâmetros (K_p^T , τ_1^T e τ_2^T) do modelo da temperatura.

4.2.2.2 Rede Neuronal para os Parâmetros $K_p^{\ \nu}$, $\tau_l^{\ \nu}e\ \tau_2^{\ \nu}$

As entradas para a referida rede neuronal inicialmente selecionadas foram os deltas de vazão e temperatura e as variáveis de saída os parâmetros do modelo: Kp^v , τ_1^v , τ_2^v . A melhor rede neuronal selecionada, indicada como uma performance de treinamento "muito boa" (razão SD entre 0,1 e 0,30), foi uma MLP do tipo (2:10:3), isto é, dois neurônios na camada de entrada, 10 na camada escondida e três na camada de saída. Os neurônios das camadas de entrada e saída apresentaram funções de ativação lineares sendo as funções de ativação dos neurônios da camada escondida tangentes hiperbólicas. O algoritmo empregado para a geração da melhor rede foi o "*Backpropagation*", aplicando 100 épocas, seguido pelo gradiente conjugado, utilizando 121 épocas. Nas Tabelas 5 e 6 é possível visualizar a análise estatística e a análise de sensibilidade para a melhor rede MLP encontrada.

Tabela 5-Análise estatística para a rede neuronal da vazão

	Κp ^v	${ au_1}^{ m v}$	${ au_2}^{ m v}$
Média dos Dados	289,982	408,308	520,521
S.D. dos Dados	91,704	247,225	294,759
Erro Médio	0,241	0,353	-0,464
S.D. dos Erros	4,366	80,311	82,146
Média dos Erros Absolutos	2,883	51,405	54,513
Razão S.D.	0,048	0,324	0,278
Correlação (R²)	0,999	0,945	0,960

Nota-se, pela Tabela 5, que a razão SD é bastante pequena, reforçando desta forma a escolha desta rede neuronal para representar o processo em questão. No entanto, pode-se afirmar que a correlação obtida para o Kp^v foi excelente, e boas para o τ_1^v e τ_2^v .

Tabela 6-Análise de Sensibilidade para a rede neuronal da vazão

Análise de Sensibilidade				
	Δu	ΔΤ		
Razão	4,143	2,708		
Importância	1	2		

Nela análise de sensibilidade apresentada na Tabela 6, verifica-se que todas as entradas apresentaram importância para a predição dos parâmetros sendo que o delta da vazão apresentou maior relevância para a rede em questão.

4.2.2.1.1 Predições dos Parâmetros da rede da vazão

As Figuras 37 a 39, ilustra-se o comportamento dos parâmetros preditos pela rede neuronal contra os observados para K_P^v , τ^v_1 e τ^v_2 .

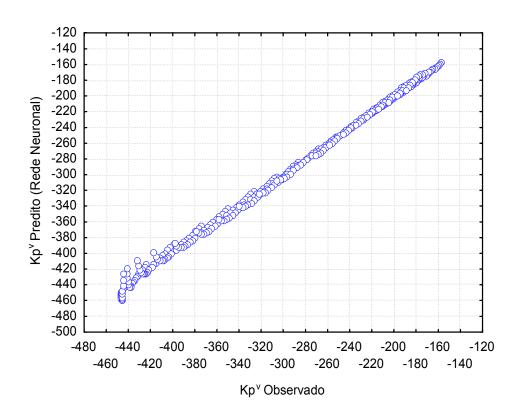


Figura 37-Observado x Predito para o Parâmetro K_P^v

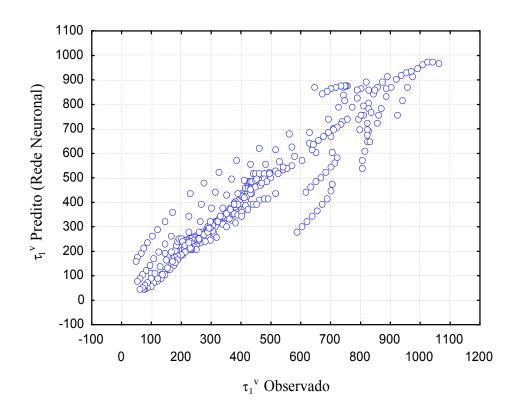


Figura 38-Observado x Predito para o Parâmetro τ^{v}_{1}

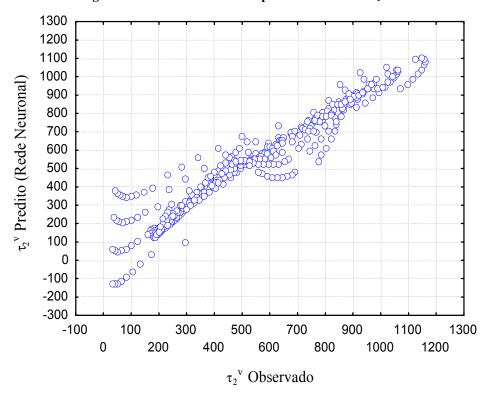


Figura 39-Observado x Predito para o Parâmetro τ^{v}_{2}

Pode-se observar o excelente ajuste e predição dos valores para o parâmetro K_p^V na Figura 37, ao passo que pode-se salientar que para as Figuras 38 e 39 $(\tau_1^v e \ \tau_2^v)$, os dados preditos acompanham relativamente bem a tendência dos dados observados, podendo a sua correlação ser considerada satisfatória.

4.2.3 Performance do Modelo Empírico – Função Transferência

Treinadas as redes neuronais, foi gerado o código fonte das mesmas em linguagem de programação C++. Essas redes foram implementadas ao Fortran onde foi criado um executável, sendo posteriormente acoplado ao programa escrito em MatLab com a finalidade de verificar a adequação do Modelo empírico fundamentado em Função de Transferência ao Modelo Fenomenológico.

Nas Figuras 40 a 44, ilustra-se a performance de aderência do modelo empírico com o modelo fenomenológico, em diferentes condições operacionais, manteve-se a concentração de alimentação em 22,0 mol/m³.

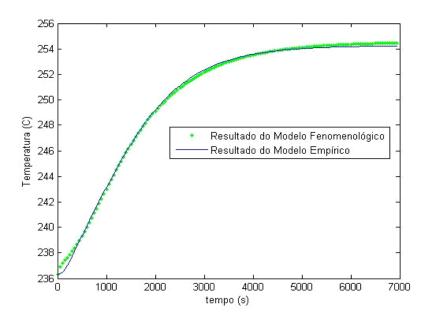


Figura 40-Resultado da Performance do Modelo Empírico para a Condição Operacional: vazão 0,050 m³/s e temperatura 213,0 °C

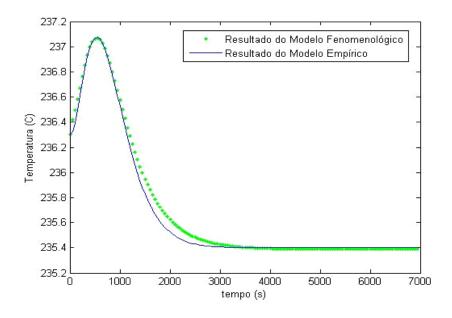


Figura 41-Resultado da Performance do Modelo Empírico para a Condição Operacional: vazão 0,090 $$\rm m^3/s$ e temperatura 213,2 °C

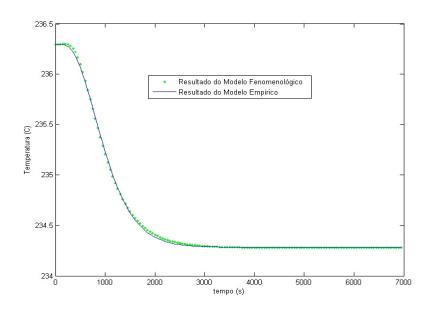


Figura 42-Resultado da Performance do Modelo Empírico para a Condição Operacional: vazão 0,100 $$\rm m^3/s$ e temperatura 214,0 °C

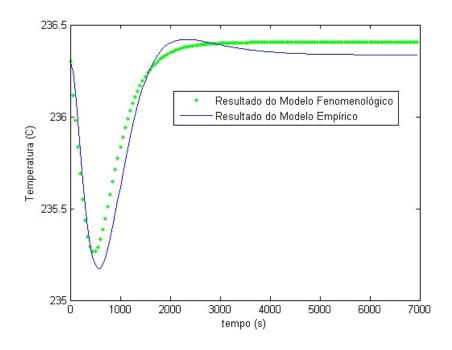


Figura 43-Resultado da Performance do Modelo Empírico para a Condição Operacional: vazão 0,115 m³/s e temperatura 216,8 °C

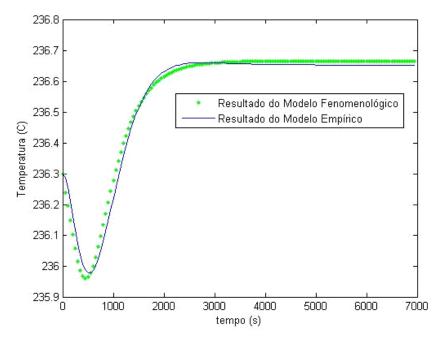


Figura 44-Resultado da Performance do Modelo Empírico para a Condição Operacional: vazão 0,105 m³/s e temperatura 215,8 °C

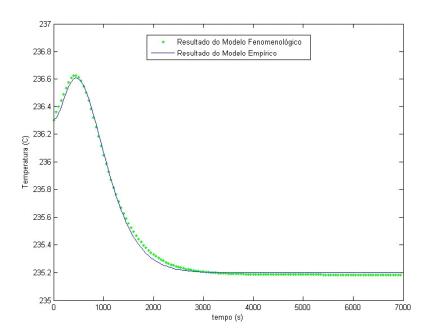


Figura 45-Resultado da Performance do Modelo Empírico para a Condição Operacional: vazão 0,095 m³/s e temperatura 213,8 °C

Pode-se observar que o modelo proposto apresentou uma ótima aderência ao modelo fenomenológico em todos os gráficos apresentados, as tendências foram seguidas e os valores do novo estado estacionário foram preditos com excelente performance, a exceção da Figura 43 que apresentou uma pequena discrepância entre os referidos valores. As condições operacionais foram escolhidas de maneira a ser possível visualizar as mais variadas dinâmicas apresentadas pelo processo evidenciando a sua complexidade.

4.3 Função de Laguerre

4.3.1 Estimação dos Parâmetros

A otimização dos parâmetros da função de Laguerre proposta para o modelo empírico foi realizada empregando-se, novamente, o otimizador determinístico disponível na função "fmins" do Software MatLab 6.5. Ao todo foram estimados 6 parâmetros de maneira simultânea (p^v, c₁^v e c₂^v para o modelo da vazão e p^T, c₁^T e c₂^T para o modelo da temperatura), enquanto que c₃^v e c₃^T foram calculados através das equações 3.4.2.1 e 3.4.2.2, com os demais parâmetros já determinados. A função objetivo proposta para a referida otimização foi a dos mínimos quadrados, ver a equação 3.4.1.

Nas Figuras 46 a 49, ilustra-se o resultado obtido com a etapa de estimação dos parâmetros da Função de Laguerre, os gráficos foram escolhidos de forma a evidenciar os comportamentos da dinâmica do processo. A variável concentração de alimentação foi mantida estável em 22,0 mol/m³.

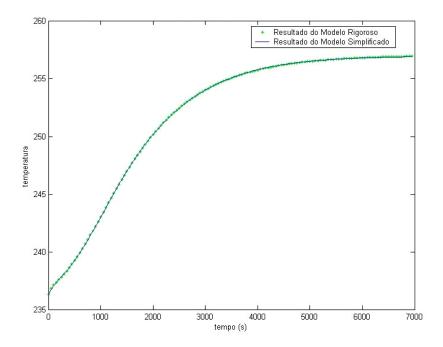


Figura 46-Resultado da Estimação dos parâmetros para a condição operacional: vazão 0,050 m³/s e temperatura 214,2 °C

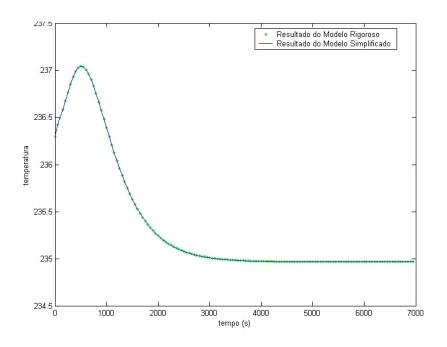


Figura 47-Resultado da Estimação dos parâmetros para a condição operacional: vazão 0,090 m³/s e temperatura 213,0 °C

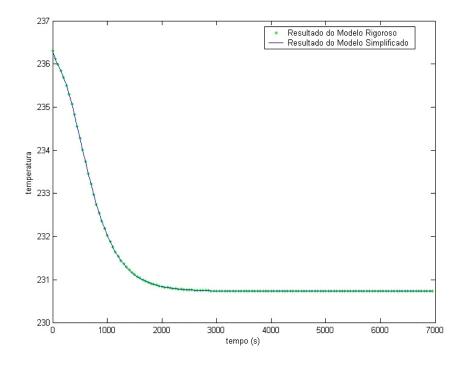


Figura 48-Resultado da Estimação dos parâmetros para a condição operacional: vazão $0,115~\text{m}^3/\text{s}$ e temperatura $213,8~^\circ\text{C}$

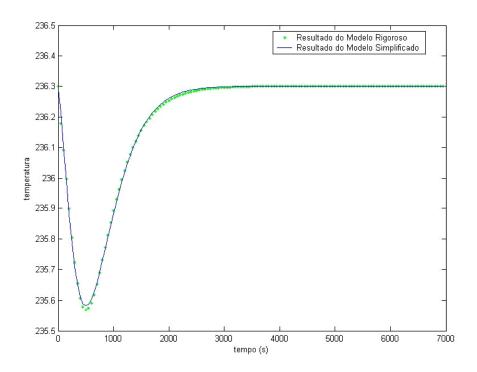


Figura 49-Resultado da Estimação dos parâmetros para a condição operacional: vazão 0,110 m³/s e temperatura 216,2 °C

Pela análise das Figuras 46 a 49, pode-se concluir que a otimização dos parâmetros proposta para o modelo fundamentado na função de Laguerre, atendeu ao objetivo esperado. A função objetivo proposta apresentou valores inferiores a 5, para um universo de 140 pontos de amostragem, para cada condição operacional proposta.

Mais uma vez as condições operacionais foram escolhidas de maneira a se verificar o comportamento da estimação dos parâmetros nos mais variados tipos de dinâmica apresentados.

Na Figura 50 pode-se ver a relação da função objetivo final obtida com a estimação dos parâmetros da função de Laguerre em relação aos ΔT e Δu . Podemos observar que o maior valor obtido para a referida função foi menor que 5, para um conjunto de pontos otimizados igual a 140. Verifica-se que a função apresentou maior dificuldade de convergência para os casos em que a perturbação na vazão de alimentação apresentou valores em torno de -0.05 m³/s (limite da perturbação). O maior valor da função objetivo

final foi encontrado na condição operacional de maior temperatura (217,0 °C) com menor vazão (0,050 m^3/s).

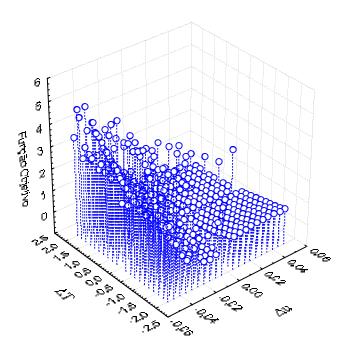


Figura 50-Função Objetivo (Laguerre) em relação a ΔT e Δu

Parâmetros da Função de Laguerre

Nas Figuras 51 a 57, ilustra-se o comportamento dos parâmetros $(p^v, c_1{}^v, c_2{}^v, c_3{}^v, p^T, c_1{}^T, c_2{}^T e c_3{}^T)$ da Função de Laguerre em relação a Δu e ΔT . Nota-se que os parâmetros variam em função de ambas as perturbações impostas na alimentação (vazão e temperatura). Não apresentam, também, uma tendência bem determinada em relação e essas perturbações, isto é, os parâmetros tendem a cair ou subir e repentinamente invertem essa tendência sem nenhuma causa aparente que justificasse tal perfil. Vale lembrar que os parâmetros $c_3{}^T$ e $c_3{}^v$ foram calculados em função dos outros parâmetros estimados.

Devido a esse comportamento, optou-se pelo método de predição destes parâmetros empregando-se a Look Table aliada a interpolação de Lagrange, esta metodologia é explica de maneira mais detalhada no próximo tópico.

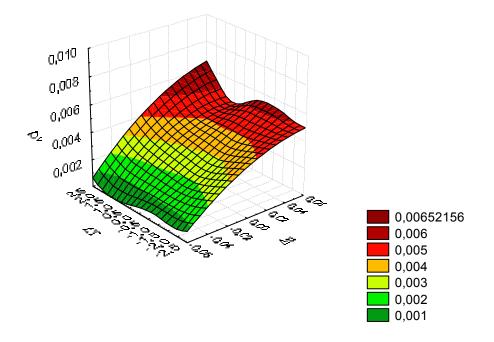


Figura 51-p v em relação a Δu e ΔT

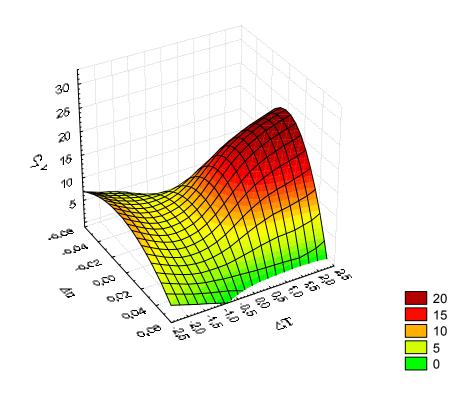


Figura 52- ${c_1}^v$ em relação a Δu e ΔT

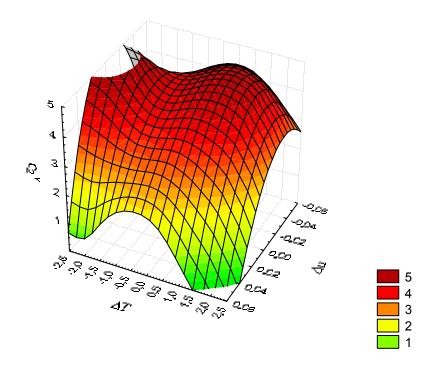


Figura-53 ${c_2}^v$ em relação a Δu e ΔT

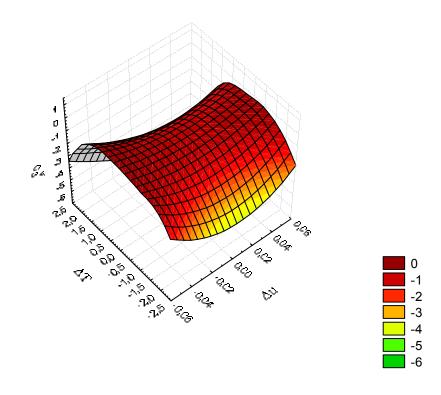


Figura 54- $c_3^{\ v}$ em relação a Δv e ΔT

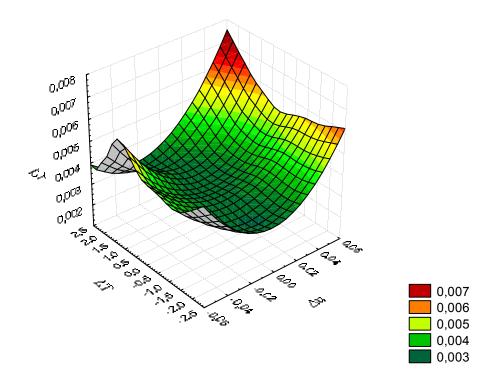


Figura 55- p^T em relação a Δu e ΔT

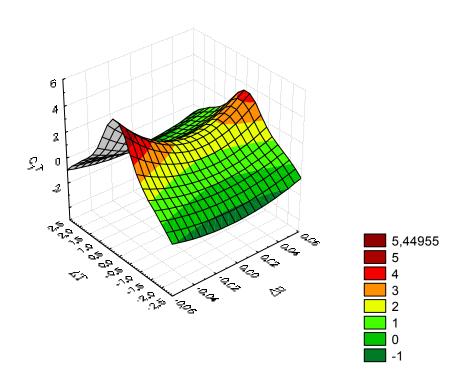


Figura 56- ${c_1}^T$ em relação a Δu e ΔT

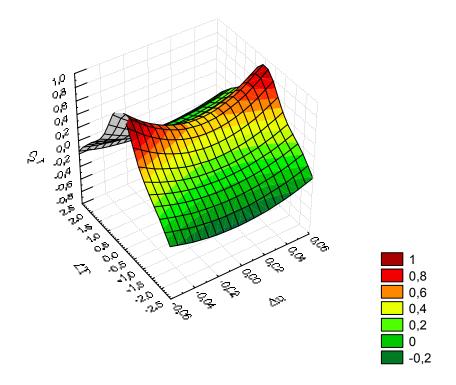


Figura 57- c_2^{T} em relação a Δu e ΔT

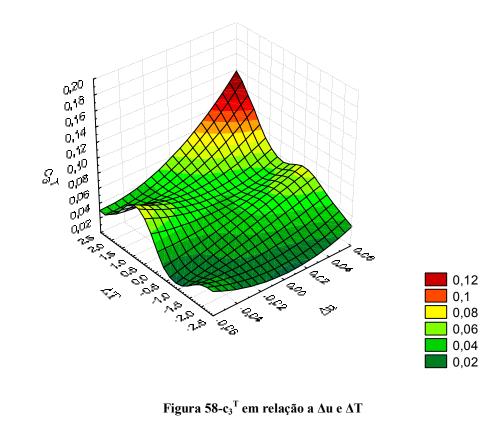


Figura 58- c_3^T em relação a Δu e ΔT

4.3.2 Estrutura de Predição dos Parâmetros do Modelo.

Para a predição dos parâmetros do modelo empírico de Laguerre, foi empregada a técnica de "Lookup Table", que consiste na localização dos parâmetros otimizados em uma tabela apropriada dadas as condições operacionais desejadas. A principal desvantagem desta técnica em relação às redes neuronais é a falta de dados para condições operacionais não otimizadas. Porém, esse percalço foi transposto com a implementação da função interpoladora de Lagrange. Desta forma, dada uma condição operacional não prevista na coleção de dados, o interpolador localiza o delta de vazão e de temperatura mais próximos do ponto dado, procedendo à interpolação dos parâmetros desejados.

Nas Figuras 59 a 64, analisa-se a performance de aderência do modelo proposto, juntamente com sua técnica de predição de parâmetros, ao modelo fenomenológico.

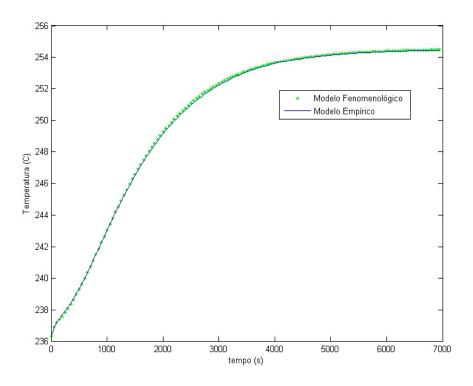


Figura 59-Resultado da Performance do Modelo Empírico de Laguerre na condição Operacional: vazão 0,0525 m³/s e temperatura 213,7 °C

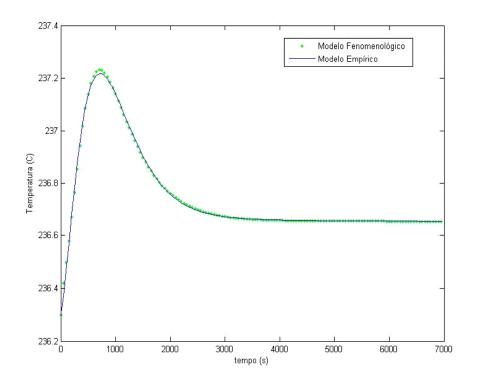


Figura 60-Resultado da Performance do Modelo Empírico de Laguerre na condição Operacional: vazão 0,090 $\rm m^3/s$ e temperatura 213,8 $^{\rm o}{\rm C}$

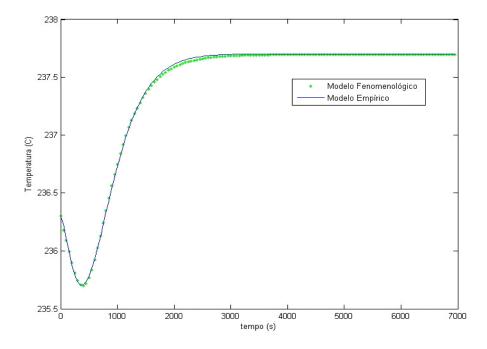


Figura 61-Resultado da Performance do Modelo Empírico de Laguerre na condição Operacional: vazão $0,\!110~\text{m}^3/\text{s}~\text{e}$ temperatura 216,9 °C

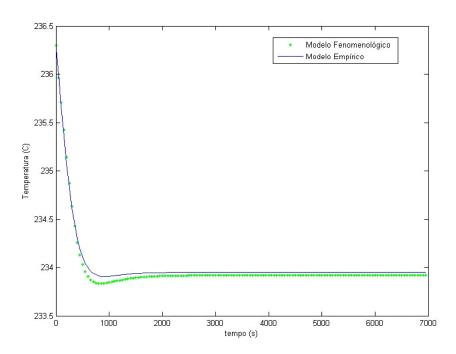


Figura 62-Resultado da Performance do Modelo Empírico de Laguerre na condição Operacional: vazão 0,128 m³/s e temperatura 216,7 °C

Pela análise das Figuras 59 a 64, pode-se concluir que a metodologia do "Lookup Table", aliada à interpolação dos dados empregando-se o polinômio de Lagrange, apresentou êxito em aderir aos dados obtidos pelo modelo fenomenológico. Todos os gráficos empregaram a técnica de interpolação, à exceção da Figura 60. A ilustração de apenas um exemplo no qual não é necessária a interpolação foi proposital, uma vez que sempre se faz a busca pelos valores tabelados, obtidos pela estimação, durante o processo de interpolação.

4.4 Comparação Entre os Modelos Empíricos

De posse dos dois modelos empíricos propostos, foi realizada uma comparação entre as suas performances, verificando qual o mais indicado para a continuidade do trabalho. O modelo baseado na função de Laguerre tem uma vantagem principal de apresentar menor número de parâmetros que o modelo fundamentado em redes neuronais, além disso, é preciso testar a aderência de ambos para as mesmas condições de trabalho.

Nas Figuras 65 a 70, pode-se comparar a performance dos modelos empíricos em relação ao modelo fenomenológico, simulados nas mesmas condições operacionais.

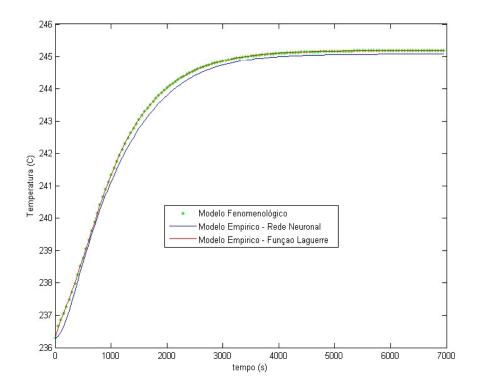


Figura 63-Comparação entre os modelos Empíricos e Fenomenológico na condição operacional: vazão 0,070 m³/s e temperatura 214,0 °C

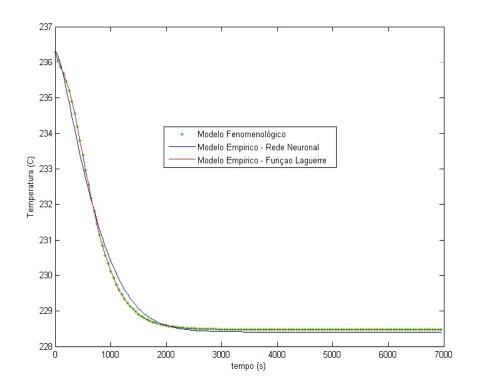


Figura 64-Comparação entre os modelos Empíricos e Fenomenológico na condição operacional: vazão $0,120~{\rm m}^3/{\rm s}$ e temperatura $213,0~{\rm ^oC}$.

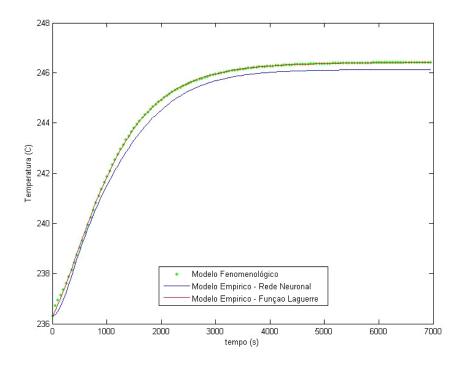


Figura 65-Comparação entre os modelos Empíricos e Fenomenológico na condição operacional: vazão $0,065~{\rm m}^3/{\rm s}$ e temperatura 213,4 °C

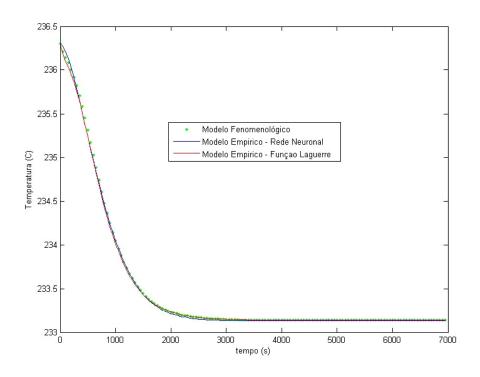


Figura 66-Comparação entre os modelos Empíricos e Fenomenológico na condição operacional: vazão 0,107 m³/s e temperatura 214,3 °C

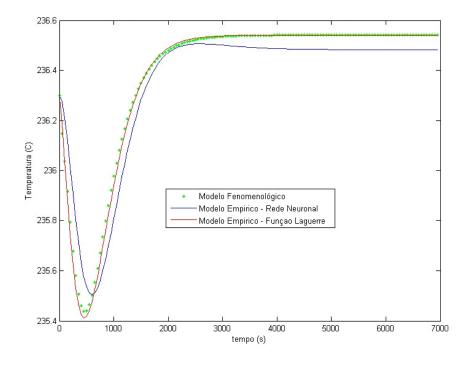


Figura 67-Comparação entre os modelos Empíricos e Fenomenológico na condição operacional: vazão 0,112 m 3 /s e temperatura 216,6 $^{\rm o}{\rm C}$

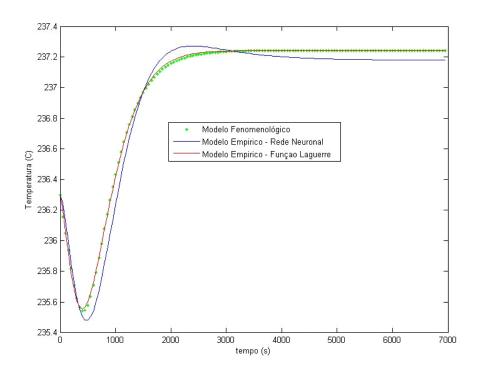


Figura 68-Comparação entre os modelos Empíricos e Fenomenológico na condição operacional: vazão 0,115 m³/s e temperatura 216,9 °C

Em todos os gráficos apresentados, ambos modelos conseguem descrever com relativa precisão os dados observados pelo modelo fenomenológico, com pequena vantagem para o modelo de Laguerre, principalmente quando a dinâmica do processo apresenta um comportamento inverso (ver Figuras 69 e 70). Por isso, o modelo escolhido para a continuidade do trabalho foi o modelo de Laguerre.

4.5 Controle Estatístico do Processo

Com o intuito de comprovar a estabilidade do processo no estado estacionário e verificar a condição de variabilidade do processo nos demais casos, foram construídas as cartas de Shewhart (Medidas Individuais), CUSUM Tabular, CUSUM padronizado e MMEP para os resíduos calculados nos 16 casos determinados na Tabela 2. Para o cálculo dos resíduos, foi introduzido um ruído à saída do modelo fenomenológico comparando-se a saída, nas mesmas condições operacionais, do modelo empírico (Função de Laguerre).

Na Figura 71, observa-se claramente a tendência ao deslocamento da média central dos resíduos, para alterações não contempladas no modelo empírico do processo. Em 4

casos (1, 3, 11 e 12), a média central zero foi mantida, pois os mesmos apresentavam variações preditas pelo modelo. O Caso 1 representa o estado estacionário que serviu como padrão. De posse destes resíduos, procedemos à análise estatística dos mesmos, através das técnicas enunciadas no início deste tópico.

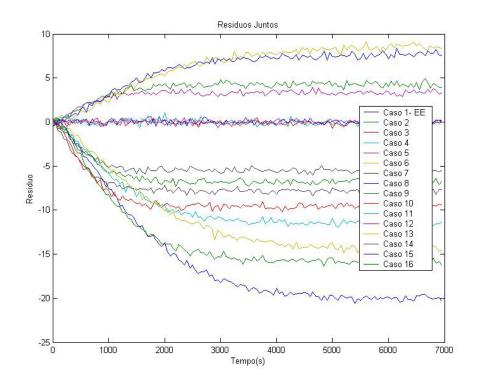


Figura 69-Resíduos dos 16 casos estudados (ver Tabela 2)

4.5.1 Carta de Shewhart (Medidas Individuais)

Os gráficos abaixo ilustram o comportamento dos resíduos mediante a construção da carta de Shewhart, relembrando que para a construção dos limites superior e inferior, além do limite central foram realizadas simulações em duplicata para a condição de estado estacionário (Caso 1) que serviu como base para essa metodologia.

As Figuras 72 a 75 ilustram as Cartas de Shewhart (para medidas individuais) para quatro casos escolhidos: Caso 1 (estado estacionário), Caso 2, Caso 3 e Caso 5. A escolha dos casos foi motivada de maneira a se visualizar todos os perfis encontrados durante a análise, processo sob-controle e os deslocamentos da média, para cima ou para baixo, ultrapassando os limites de controle.

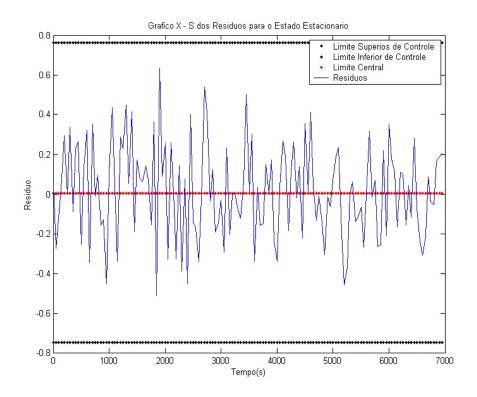


Figura 70-Carta de Shewhart para o Caso 1 (EE)

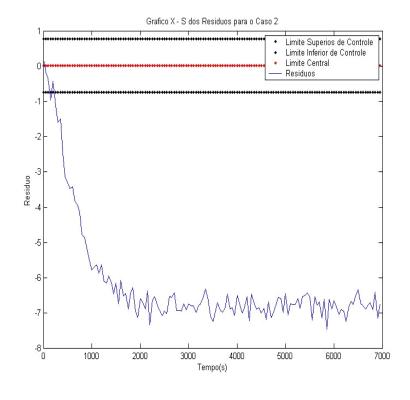


Figura 71-Carta de Shewhart para o Caso 2

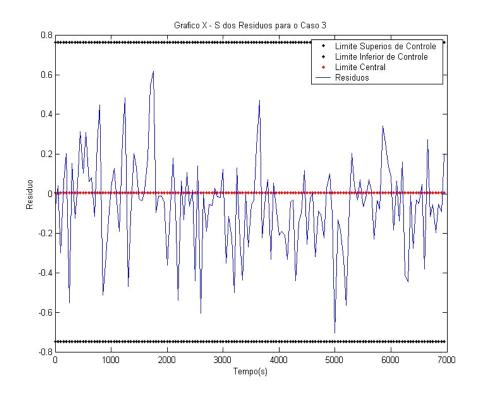


Figura 72-Carta de Shewhart para o Caso 3

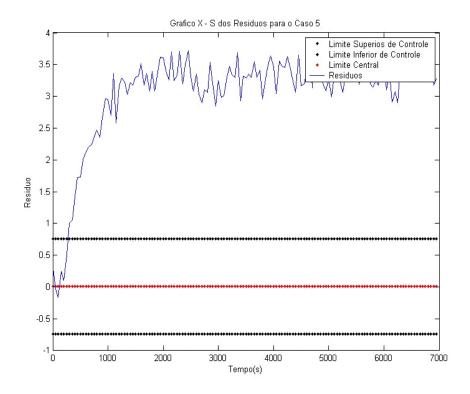


Figura 73-Carta de Shewhart para o Caso 5

Na Figura 72, observa-se o comportamento do resíduo calculado para o Estado Estacionário. Nessa Figura, verifica-se que não existem pontos fora dos limites de controle, muito menos na existência de um padrão consistindo de uma sequência em um dos lados da linha central, o que evidencia uma manutenção da media do processo ao longo do tempo.

Na Figura 74, não houve pontos fora dos limites de controle, mas houve um deslocamento da média do processo, indicando alguma alteração nas condições operacionais do processo em estudo. Nas Figuras 73 e 75, verifica-se uma profunda alteração nas condições operacionais não prevista pelo modelo empírico do processo, pois os pontos ultrapassam os limites de controle. Apresenta-se um grande deslocamento da média do processo.

A carta de Shewhart apresenta a desvantagem de não perceber pequenas alterações no processo, isto é, a referida carta apresenta uma baixa sensibilidade às mudanças de baixa intensidade, por usar a informação sobre o processo, contida no último ponto analisado. Ignora qualquer informação dada pela seqüência inteira de pontos. Isto justifica a construção das demais cartas apresentadas a seguir. Para a visualização das Cartas de Shewhart para os demais casos, ver Apêndice 1.

Na Tabela 7 ilustra-se um resumo com os resultados obtidos com a Carta de Shewhart. Pode-se observar que os casos 11 e 12 não apresentaram mudanças significativas na sua tendência central, fato este esperado na teoria, pois esses casos são perfeitamente reproduzidos pelo modelo empírico. O caso 11 apresentou um ponto ultrapassando o limite de controle superior, indicando um alerta para alguma alteração ocorrida nas condições operacionais, em relação ao estado estacionário. Como esperado, os demais casos apresentaram características de processo fora de controle (ultrapassando um dos limites de controle), uma vez que o modelo não poderia prever alterações na concentração de alimentação.

Para a visualização dos gráficos de Shewhart para os demais Casos, ver Apêndice 1.

Tabela 7-Resultado da Carta de Shewhart para os casos em estudo

Casos	Tendência Central	Pontos Fora dos Limites de Controle					
		Limite Superior	Limite Inferior				
4	Deslocada para Baixo	Não	Todos				
6	Deslocada para Cima	Todos	Não				
7	Deslocada para Baixo	Não	Todos				
8	Deslocada para Baixo	Não	Todos				
9	Deslocada para Cima	Todos	Não				
10	Deslocada para Baixo	Não	Todos				
11	Mantida	1	Não				
12	Mantida	Não	Não				
13	Deslocada para Baixo	Não	Todos				
14	Deslocada para Baixo	Não	Todos				
15	Deslocada para Cima	Todos	Não				
16	Deslocada para Cima	Todos	Não				

4.5.2 -CUSUM Tabular

As Figuras 76 a 79 ilustram o comportamento dos resíduos dos 3 primeiros casos e o caso 5, mediante a construção da carta de CUSUM Tabular. Vale ressaltar que, neste caso, também se empregaram simulações em duplicata do estado estacionário para a construção dos limites superior e inferior, além da linha central.

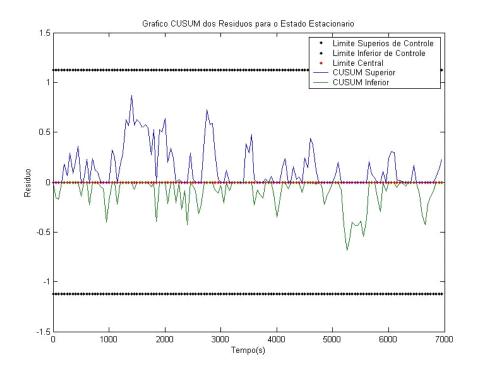


Figura 74-CUSUM Tabular para o Caso 1

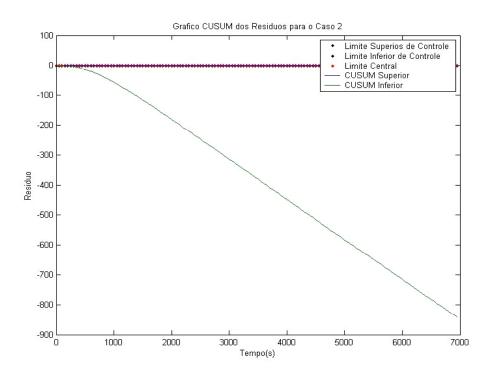


Figura 75-CUSUM Tabular para o Caso 2

107

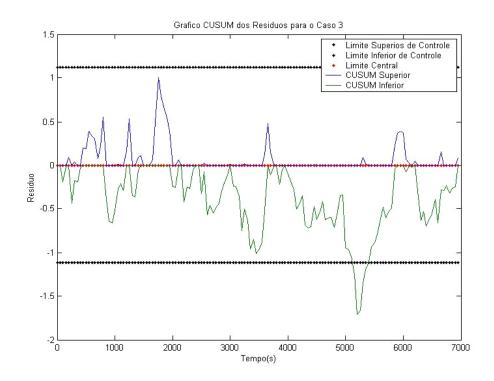


Figura 76-CUSUM Tabular para o Caso 3

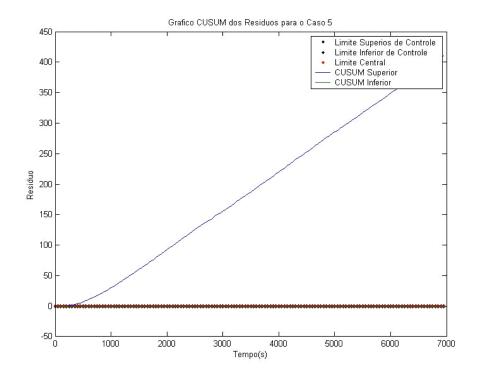


Figura 77 CUSUM Tabular para o Caso 5

108

Na Figura 76, observa-se o comportamento do resíduo calculado para o Estado Estacionário. Verifica-se que não existem pontos fora dos limites de controle, tanto para C_i^+ quanto para C_i^- , apesar da maior sensibilidade deste método.

Nas Figuras 77 e 79, verifica-se uma profunda alteração nas condições operacionais não prevista (alteração na concentração de alimentação) pelo modelo empírico do processo, pois os pontos ultrapassam o limite de controle para C_i^+ no caso da Figura 79 e o limite de controle para C_i^- na Figura 77, apresentaram um grande deslocamento das somas cumulativas ao longo do tempo.

Na Figura 78, pode-se ter uma pequena idéia da maior sensibilidade deste método, pois ele apresenta uma soma cumulativa superior ao limite de controle para C_i , ao passo que a análise feita pelo gráfico de Shewhart para este caso, não apresentou desvio.

A Tabela 8 contém um resumo com os resultados obtidos com a Carta de CUSUM tabular. Pode-se observar que apenas o caso 12 não apresentou mudanças significativas na sua tendência central, nem ultrapassou os limites de controle. O caso 11, que para a carta de Shewhart apresentou apenas 1 ponto além do limite de controle, nesta abordagem, mostrou diversos pontos fora dos limites de controle, o que evidencia uma mudança na condição operacional (em relação ao estado estacionário). Esse fato exemplifica a maior sensibilidade em relação à carta de Shewhart. Como esperado, os demais casos apresentaram características de processo fora de controle (ultrapassando um dos limites de controle), uma vez que o modelo não poderia prever alterações na concentração de alimentação. Para a Visualização as Cartas de CUSUM Tabular para os demais Casos, ver Apêndice 2.

Tabela 8-Resultado da Carta de CUSUM Tabular para os casos em estudo

Casos	Pontos Fora do Limite de Controle										
	Limite Superior	Limite Inferior									
4	Não	Todos									
6	Todos	Não									
7	Não	Todos									
8	Não	Todos									
9	Todos	Não									
10	Não	Todos									
11	6 Pontos Fora	2 Pontos Fora									
12	Não	Não									
13	Não	Todos									
14	Não	Todos									
15	Todos	Não									
16	Todos	Não									

4.5.3 - CUSUM Padronizado

Este tópico ilustra a elaboração do CUSUM padronizado para os resíduos, que tem a vantagem de não apresentar escala na escolha dos parâmetros do gráfico, ver tópico 2.7.4.1.2. Novamente, empregaram-se simulações em duplicata do estado estacionário para a construção dos limites superior e inferior, além do limite central.

As Figuras 80 a 83 analisam o comportamento dos resíduos dos 3 primeiros casos e o caso 5 para a carta CUSUM Padronizado. Essa escolha foi motivada de maneira a se visualizar todos os perfis encontrados durante a análise: processo sob-controle e os deslocamentos da média, para cima ou para baixo – ultrapassando os limites de controle.

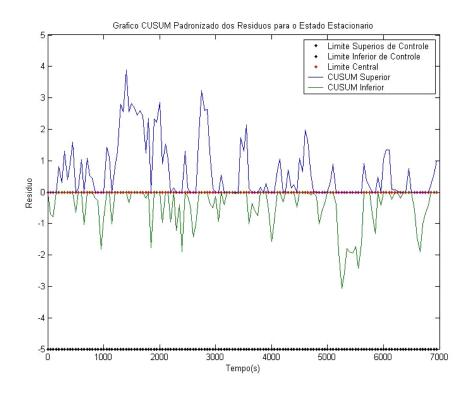


Figura 78-CUSUM Padronizado para o Caso 1

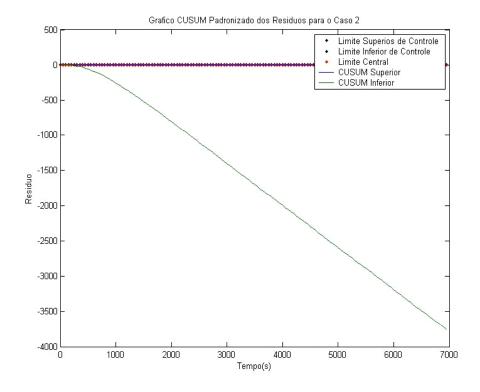


Figura 79 CUSUM Padronizado para o Caso 2

111

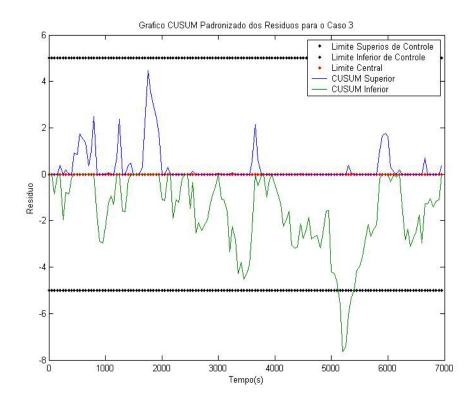


Figura 80-CUSUM Padronizado para o Caso 3

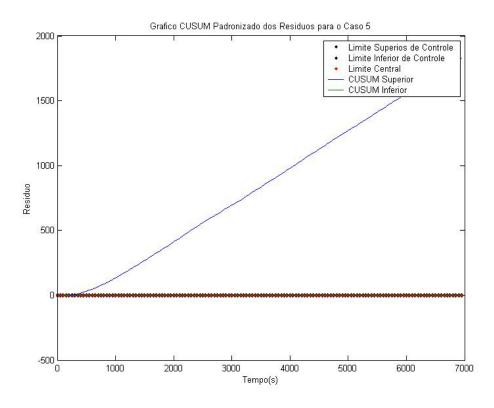


Figura 81-CUSUM Padronizado para o Caso 5

112

Na Figura 80, mostra-se o perfil do resíduo calculado para o Estado Estacionário. Na figura em questão verificamos que não existem pontos fora dos limites de controle, tanto para C_i^+ quanto para C_i^- .

Nas Figuras 81 e 83, observamos uma grande mudança nas condições operacionais não prevista pelo modelo empírico do processo, pois os pontos ultrapassam o limite de controle para C_i^+ , no caso da Figura 83, e o limite de controle para C_i^- na Figura 81, apresentando um grande deslocamento das somas cumulativas ao longo do tempo devido ao fato dos resíduos obtidos com a simulação destas condições operacionais, apresentar uma tendência nítida (crescente ou decrescente). A Figura 82 apresenta uma soma cumulativa ultrapassando o limite de controle para C_i^- , mesmo efeito percebido pelo CUSUM Tabular, mas segundo MONTGOMERY (2001), o mesmo encontra-se com o processo fora de controle.

Na Tabela 9, observa-se um resumo com os resultados obtidos com a Carta de CUSUM padronizado. Os resultados obtidos foram análogos com os obtidos com a análise do CUSUM tabular. O caso 12 foi o único que pôde ser considerado como processo sob controle. O caso 11 apresentou os mesmos pontos ultrapassando os limites de controle o que caracteriza um processo fora de controle, bem como todos os demais casos apresentados na Tabela 9. Para a observação das Figuras referentes aos demais Casos, ver Apêndice 3.

Tabela 9-Resultado da Carta de CUSUM Padronizado para os casos em estudo

Casos	Pontos Fora do Limite de Controle									
	Limite Superior	Limite Inferior								
4	Não	Todos								
6	Todos	Não								
7	Não	Todos								
8	Não	Todos								
9	Todos	Não								
10	Não	Todos								
11	6 Pontos Fora	2 Pontos Fora								
12	Não	Não								
13	Não	Todos								
14	Não	Todos								
15	Todos	Não								
16	Todos	Não								

4.5.4 -MMEP

O Gráfico de controle da média móvel exponencialmente ponderada (MMEP) é também uma boa alternativa ao gráfico de controle de Shewhart, quando se está interessado em pequenas mudanças. Empregaram-se, também, simulações em duplicata do estado estacionário para a construção dos limites superior e inferior, além do limite central.

As Figuras 84 a 87 ilustram o comportamento dos resíduos dos 3 primeiros casos e o caso 5 para a carta MMEP.

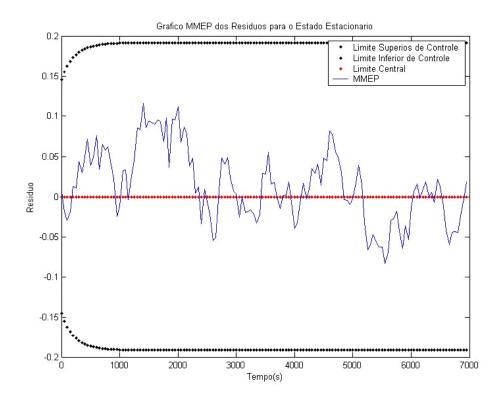


Figura 82-Gráfico MMEP para o Caso 1

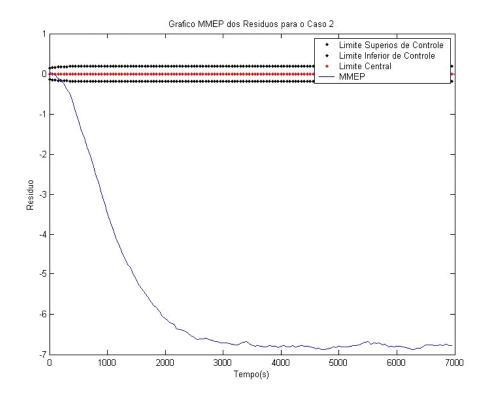


Figura 83-Gráfico MMEP para o Caso 2

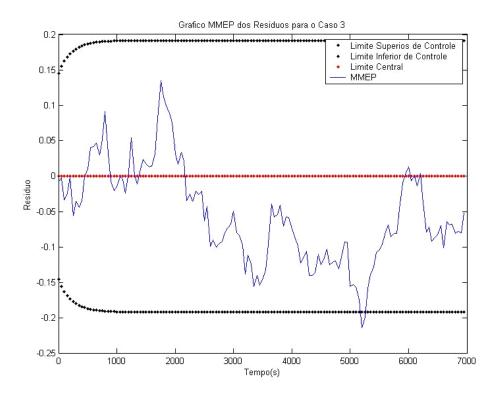


Figura 84-Gráfico MMEP para o Caso 3

115

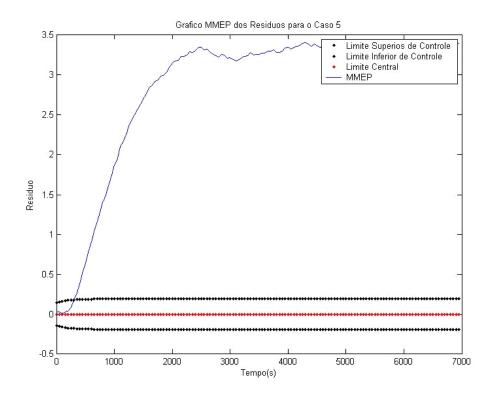


Figura 85-Gráfico MMEP para o Caso 5

Seguindo a mesma tendência das análises anteriores, apesar da maior sensibilidade do método, podemos visualizar que o Estado Estacionário está dentro do controle estatístico (Figura 84). O caso 3 (Figura 86) apresenta 1 ponto fora de controle (processo fora de controle) e as Figuras 85 e 87 apresentadas neste tópico caracterizam-se como um processo fora de controle, isto é, ultrapassaram os limites de controle estatístico do processo.

A Tabela 10 contém um resumo com os resultados obtidos com a Carta de MMEP. Pode-se observar que para o caso 11, houve uma redução no número de pontos que ultrapassaram os limites de controle, mas ainda assim o processo é considerado como fora de controle. Os demais casos analisados não apresentaram discrepâncias de resultados em relação as outras cartas de controle discutidas anteriormente. Para a observação das Figuras referentes aos demais Casos, ver Apêndice 4.

Tabela 10-Resultado da Carta de MMEP os casos em estudo

Casos	Pontos Fora do Limite de Controle									
	Limite Superior	Limite Inferior								
4	Não	Todos								
6	Todos	Não								
7	Não	Todos								
8	Não	Todos								
9	Todos	Normal								
10	Não	Todos								
11	2 Pontos Fora	Não								
12	Não	Não								
13	Não	Todos								
14	Não	Todos								
15	Todos	Não								
16	Todos	Não								

A Carta de Controle de MMEP apresenta sensibilidade para detectar pequenas mudanças e, ao mesmo tempo, demonstra robustez contra falsos alertas de mudanças no processo. Devido a isto, recomenda-se a sua utilização para monitorar o processo, uma vez que pode ser empregada como um primeiro alerta de que o processo apresenta uma tendência de sair de sua condição operacional estabelecida.

Logo, a MMEP pode ser usada:

- sozinha, para detectar situações não previstas pelo modelo, ou seja, perturbações na concentração de entrada em relação ao seu valor estacionário (Casos 2, 4, 5, 6, 7, 8, 9, 10, 13, 14, 15 e 16)
- ou combinada a um classificador estatístico, para diagnosticar o processo para todos os casos pré-estabelecidos.

4.6 Classificação e Diagnóstico de Falhas

Neste tópico, abordaram-se os resultados obtidos com a técnica empregada no diagnóstico e classificação das falhas no processo. Foram estudados os 16 casos apresentados na Tabela 2.

4.6.1 Estudos de Caso

Neste tópico, foram estudados os 16 casos propostos e verificou-se a performance do algoritmo de classificação implementado. Na Tabela 11, pode-se observar um resumo com os resultados obtidos com os estudos de caso. Apresentam-se os percentuais de indicação dos 16 casos para cada estudo bem como a sua condição operacional.

Tabela 11-Resultado dos Estudos de Caso com sua respectiva condição operacional.

	Caso Mais Próximo															
Caso	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	27,78%	2,78%	19,44%	2,78%	0,00%	0,00%	0,00%	2,78%	0,00%	0,00%	16,67%	25,00%	2,78%	0,00%	0,00%	0,00%
2	2,78%	52,78%	2,78%	16,67%	0,00%	0,00%	0,00%	8,33%	0,00%	2,78%	0,00%	2,78%	2,78%	8,33%	0,00%	0,00%
3	19,44%	0,00%	30,56%	0,00%	5,56%	0,00%	0,00%	0,00%	0,00%	2,78%	22,22%	13,89%	0,00%	0,00%	2,78%	2,78%
4	2,78%	11,11%	0,00%	50,00%	0,00%	0,00%	13,89%	8,33%	2,78%	0,00%	0,00%	0,00%	11,11%	0,00%	0,00%	0,00%
5	0,00%	0,00%	2,78%	0,00%	55,56%	2,78%	0,00%	0,00%	25,00%	0,00%	5,56%	0,00%	2,78%	0,00%	5,56%	0,00%
6	2,78%	0,00%	0,00%	0,00%	8,33%	55,56%	0,00%	0,00%	19,44%	0,00%	2,78%	2,78%	0,00%	0,00%	8,33%	0,00%
7	0,00%	5,56%	0,00%	2,78%	0,00%	0,00%	52,78%	8,33%	0,00%	16,67%	0,00%	0,00%	8,33%	2,78%	0,00%	2,78%
8	0,00%	5,56%	0,00%	8,33%	0,00%	0,00%	2,78%	61,11%	2,78%	0,00%	2,78%	0,00%	2,78%	2,78%	0,00%	11,11%
9	2,78%	0,00%	2,78%	0,00%	16,67%	13,89%	2,78%	2,78%	41,67%	0,00%	0,00%	0,00%	0,00%	0,00%	16,67%	0,00%
10	2,78%	0,00%	0,00%	0,00%	0,00%	0,00%	16,67%	8,33%	0,00%	52,78%	0,00%	0,00%	5,56%	2,78%	0,00%	11,11%
11	16,67%	0,00%	16,67%	0,00%	0,00%	2,78%	0,00%	0,00%	5,56%	0,00%	41,67%	11,11%	0,00%	0,00%	0,00%	5,56%
12	16,67%	5,56%	13,89%	0,00%	5,56%	0,00%	0,00%	2,78%	0,00%	0,00%	22,22%	33,33%	0,00%	0,00%	0,00%	0,00%
13	0,00%	5,56%	2,78%	16,67%	2,78%	0,00%	5,56%	2,78%	0,00%	0,00%	2,78%	0,00%	52,78%	5,56%	0,00%	2,78%
14	2,78%	13,89%	2,78%	0,00%	0,00%	0,00%	2,78%	13,89%	0,00%	5,56%	0,00%	2,78%	0,00%	50,00%	0,00%	5,56%
15	0,00%	0,00%	0,00%	0,00%	8,33%	16,67%	0,00%	0,00%	16,67%	2,78%	2,78%	0,00%	2,78%	0,00%	50,00%	0,00%
16	0,00%	2,78%	0,00%	0,00%	0,00%	0,00%	2,78%	11,11%	2,78%	8,33%	0,00%	2,78%	0,00%	5,56%	2,78%	61,11%
С	22,0	17,0	22,0	17,0	24,5	24,5	14,5	14,5	24,5	14,5	22,0	22,0	17,0	17,0	24,5	14,5
٧	0,100	0,100	0,070	0,070	0,115	0,055	0,115	0,055	0,100	0,100	0,055	0,115	0,055	0,115	0,070	0,070
T	215,0	215,0	215,0	215,0	215,0	215,0	215,0	215,0	215,0	215,0	215,0	215,0	215,0	215,0	215,0	215,0

T – Temperatura de alimentação (°C), V- Vazão de alimentação (m³/s) e C – Concentração de alimentação (mol/m³)

4.6.1.1 Caso 1

Na Figura 88, pode-se analisar o comportamento dos resíduos mais próximos do caso em estudo (Caso 1). O modelo proposto consegue prever alterações na vazão e temperatura de alimentação, mantendo-se sempre constante (no valor do estado estacionário) a variável de concentração na entrada do reator (22,0 mol/m³). Desta forma. os Casos 1, 3, 11 e 12 apresentam resíduos com média em torno de zero. Assim, como facilmente pode-se obter o valor da vazão de alimentação (através do sistema supervisório ou PI), conclui-se que quando o perfil dos resíduos do caso em estudo apresentar uma

média em torno de zero, e admitindo-se que a temperatura de alimentação esteja sob controle (em torno do estado estacionário), a condição operacional alterada, para estes casos, será a vazão, cujo valor pode ser monitorado ao longo do tempo pelo sistema supervisório, e conseqüentemente, para o sistema de detecção e diagnóstico. No Caso em questão, a vazão possui o valor de 0,100 m³/s. O sistema de diagnóstico fornece uma resposta após 30 minutos de monitoramento.

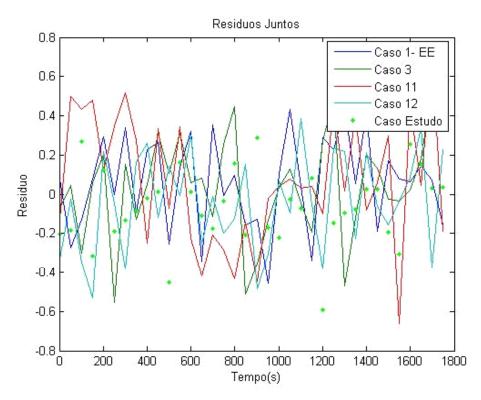


Figura 86-Estudo do Caso 1

4.6.1.2 Caso 2

Na Figura 89, pode-se estudar o comportamento do resíduo em estudo (Caso 2). Observa-se que o mesmo apresenta um desvio da média para valores abaixo de zero. Este comportamento dos resíduos calculados indica uma nova condição operacional não prevista pelo modelo empírico, sendo esta alteração ocorrida na variável de concentração de alimentação. Verifica-se também que, o caso em estudo apresenta uma aderência aos resíduos tratados estatisticamente, além da saída do programa indicar que o perfil mais próximo do caso em estudo é o próprio Caso 2 com um percentual de indicação igual a 52,78% (Ver Tabela 11).

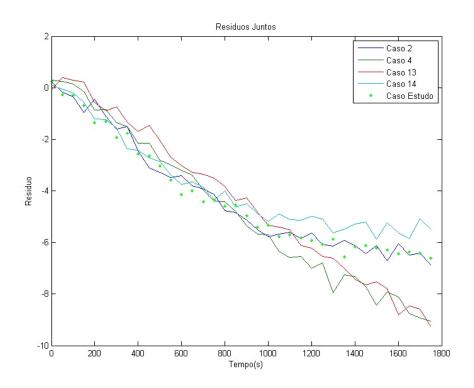


Figura 87-Estudo do Caso 2

4.6.1.3 Caso 3

Na Figura 90, ilustra-se o comportamento do resíduo do Caso 3 em relação aos casos mais próximos (Casos 1, 11 e 12). Similarmente ao que foi exposto na análise da Figura 89, o modelo proposto consegue prever somente alterações na vazão e na temperatura de alimentação. Como foi mantida a concentração no valor do estado estacionário (22,0 mol/m³), o Caso 3 apresenta resíduos com média em torno de zero. Conclui-se que, quando o perfil dos resíduos do caso em estudo apresentar uma média igual a zero e a temperatura de alimentação estiver sob controle (próximo do estado estacionário – 215,0 °C), a condição operacional alterada, para estes casos, será a vazão. Como pode-se obter o valor da vazão de alimentação através do sistema supervisório, neste caso a vazão possui o valor de 0,070 m³/s. O sistema de diagnóstico fornece uma resposta após 30 minutos de monitoramento. Esta condição condiz com uma situação normal de operação (Ver Tabela 2).

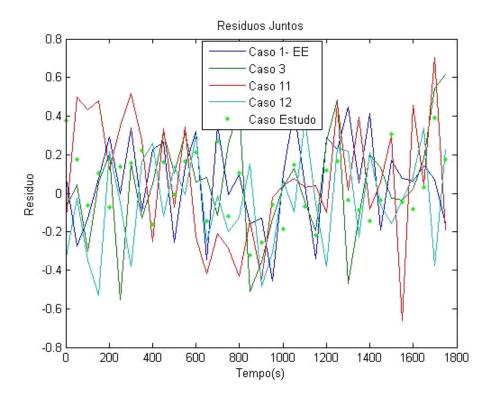


Figura 88-Estudo do Caso 3

4.6.1.4 Caso 4

Na Figura 91, pode-se observar o comportamento do resíduo em estudo (Caso 4). Observa-se que o mesmo apresenta um desvio de sua média para valores abaixo de zero (em torno de -10). Este comportamento dos resíduos calculados indica uma nova condição operacional não prevista pelo modelo empírico, sendo esta alteração ocorrida na variável de concentração de alimentação. Verifica-se também que o Caso em estudo apresenta uma aderência aos resíduos tratados estatisticamente, além da saída do programa indicar que o perfil mais próximo do Caso em estudo é o próprio Caso 4 com um percentual de indicação igual a 50,00% (Ver Tabela 11). Segundo a Tabela 2, esta condição operacional representa uma situação normal de operação.

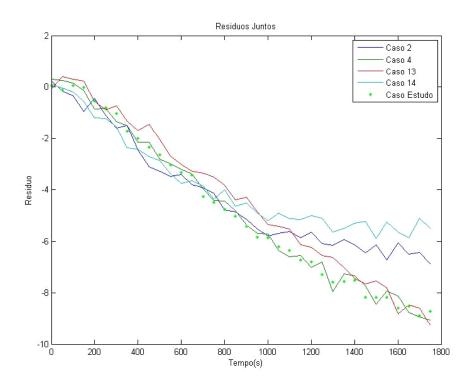


Figura 89-Estudo do Caso 4

4.6.1.5 Caso 5

Na Figura 92, analisa-se o perfil do resíduo em estudo (Caso 5). Evidencia-se que os resíduos apresentam uma tendência de apresentar para valores acima de zero (aproximadamente 3,5). Pode-se afirmar que este comportamento dos resíduos calculados evidencia uma nova condição operacional não prevista pelo modelo empírico, sendo esta alteração ocorrida na variável de concentração de na alimentação. Verifica-se também que o caso em estudo apresenta uma aderência aos resíduos tratados estatisticamente, além da saída do programa indicar que o perfil mais próximo do Caso em estudo o próprio Caso 5 com um percentual de indicação igual a 55,56% (Ver Tabela 11). Segundo a Tabela 2, esta condição operacional representa uma situação de alta concentração e baixa vazão.

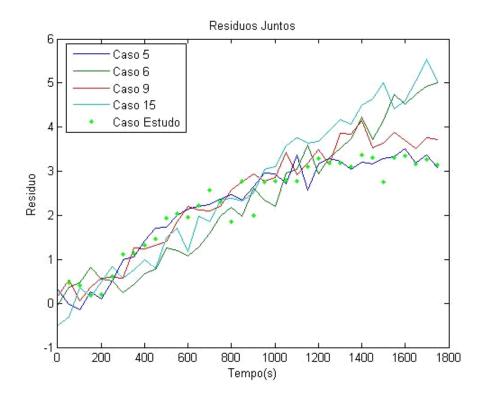


Figura 90-Estudo do Caso 5

4.6.1.6 Caso 6

Na Figura 93, estudou-se o comportamento dos resíduos calculados para o caso 6. Nesse caso, houve o deslocamento da media dos resíduos de zero para um valor acima de zero. Evidencia-se, mais uma vez, uma alteração nas condições operacionais do processo, onde a mudança ocorre na variável concentração de entrada do reator. A saída do programa indica o caso 6 como o perfil mais próximo do caso em estudo, com um percentual de indicação igual a 55,56% (Ver Tabela 11). Segundo a Tabela 2, esta condição operacional representa uma situação de baixas concentração e vazão de alimentação.

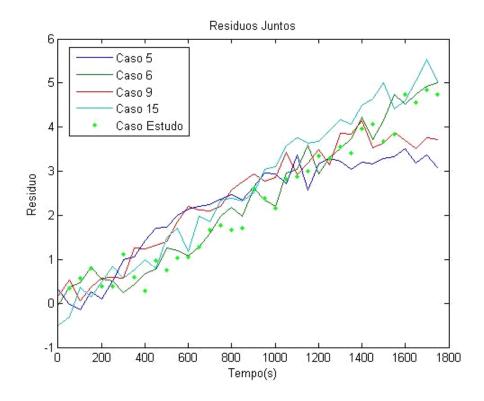


Figura 91-Estudo do Caso 6

4.6.1.7 Caso 7

Na Figura 94, observa-se o perfil dos resíduos ao longo do tempo de monitoramento para o caso 7. Verifica-se que o deslocamento da media dos resíduos de zero para um valor abaixo de zero. Evidencia-se, novamente, uma alteração nas condições operacionais do processo, onde a mudança ocorre na variável concentração de entrada do reator. A saída do programa indicou o caso 7 como o perfil mais próximo do caso em estudo, com um percentual de indicação igual a 52,78% (Ver Tabela 11). Segundo a Tabela 2, esta condição operacional representa uma situação de baixa concentração e alta vazão de alimentação.

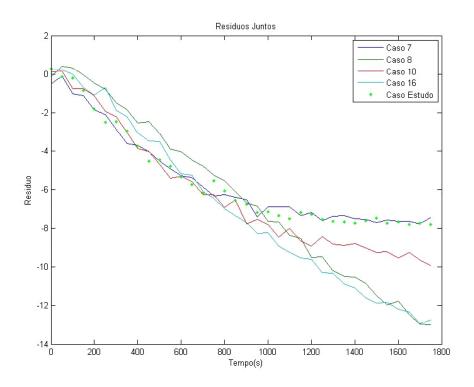


Figura 92-Estudo do Caso 7

4.6.1.8 Caso 8

Na Figura 95, estuda-se o comportamento dos resíduos ao longo do tempo de monitoramento para o caso 8. Observa-se que o deslocamento da media dos resíduos de zero para um valor abaixo de zero. Evidencia-se, novamente, uma alteração nas condições operacionais do processo, onde a mudança ocorre na variável concentração de entrada do reator. A saída do programa indicou o caso 8 como o perfil mais próximo do caso em estudo, com um percentual de indicação igual a 61,11% (Ver Tabela 11). Segundo a Tabela 2, esta condição operacional representa uma situação de baixa concentração e vazão de alimentação.

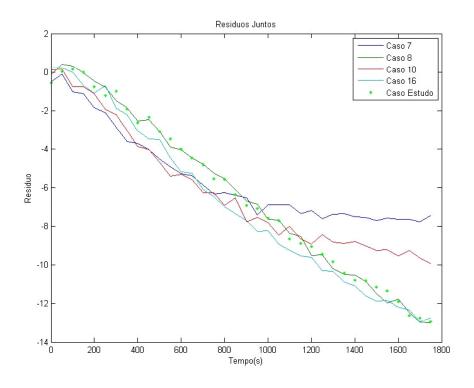


Figura 93-Estudo do Caso 8

4.5.1.9 Caso 9

Na Figura 96, estuda-se o comportamento dos resíduos ao longo do tempo de monitoramento para o caso 9. Observa-se que o deslocamento da media dos resíduos de zero para um valor acima de zero. Evidencia-se, novamente, uma alteração nas condições operacionais do processo, onde a mudança ocorre na variável concentração de entrada do reator. A saída do programa indicou o caso 9 como o perfil mais próximo do caso em estudo, com um percentual de indicação igual a 41,67% (Ver Tabela 11). Segundo a Tabela 2, esta condição operacional representa uma situação de alta concentração de alimentação.

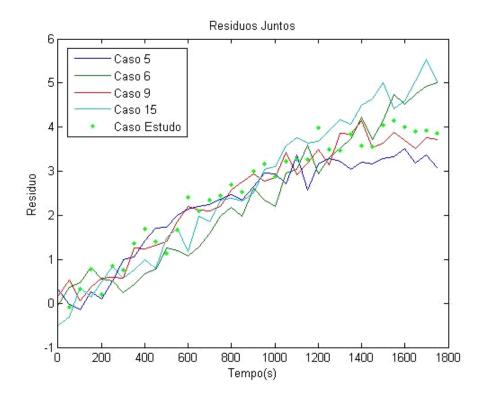


Figura 94-Estudo do Caso 9

4.6.1.10 Caso 10

Na Figura 97, analisa-se o perfil dos resíduos ao longo do tempo de monitoramento para o caso 10. Verifica-se que o deslocamento da media dos resíduos de zero para um valor abaixo de zero. Confirma-se, mais uma vez, uma alteração nas condições operacionais do processo, onde a mudança ocorre na variável concentração de entrada do reator. A saída do programa do Sistema de detecção e diagnóstico de falhas (Distâncias Euclidianas) indicou o caso 10 como o perfil mais próximo do caso em estudo, com um percentual de indicação igual a 52,78% (Ver Tabela 11). Segundo a Tabela 2, esta condição operacional representa uma situação de baixa concentração de alimentação.

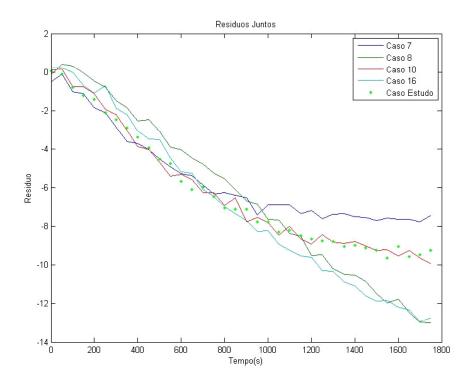


Figura 95-Estudo do Caso 10

4.6.1.11 Caso 11

Na Figura 98, ilustra-se o comportamento do resíduo do caso 11 em relação aos casos mais próximos (caso 1, 3 e 12). Similarmente ao que foi exposto na análise das Figuras 89 e 90, o modelo proposto consegue prever somente alterações na vazão e na temperatura de alimentação. Como foi mantida a concentração no valor do estado estacionário (22,0 mol/m³), o caso 11 apresenta resíduos com média em torno de zero. Conclui-se que, quando o perfil dos resíduos do caso em estudo apresentar uma média igual a zero e a temperatura de alimentação estiver sob controle (em torno do estado estacionário 215,0 °C), a condição operacional alterada, para estes casos, será a vazão. Como facilmente pode-se obter o valor da vazão de alimentação através do sistema supervisório, neste caso a vazão possui o valor de 0,055 m³/s. O sistema de diagnóstico fornece uma resposta após 30 minutos de monitoramento. Esta condição condiz com uma situação operacional de baixa vazão de alimentação (Ver Tabela 2).

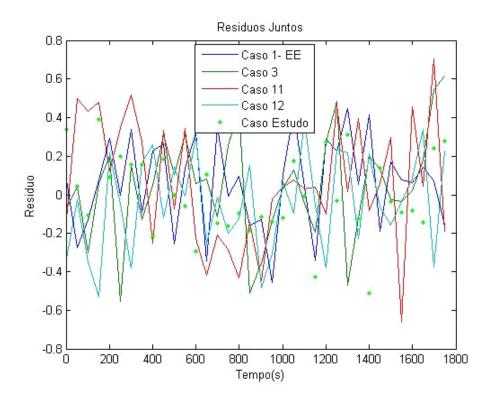


Figura 96-Estudo do Caso 11

4.6.1.12 Caso 12

Na Figura 99, ilustra-se o perfil do resíduo do Caso 12 em relação aos casos mais próximos (Caso 1, 3 e 11). As análises são as mesmas realizadas para o Caso 11 (Figura 98). Conclui-se que como é possível obter o valor da vazão de alimentação através do sistema supervisório, a vazão possui o valor de 0,115 m³/s. O sistema de diagnóstico fornece uma resposta após 30 minutos de monitoramento. Esta condição condiz com uma situação operacional de alta vazão de alimentação (Ver Tabela 2).

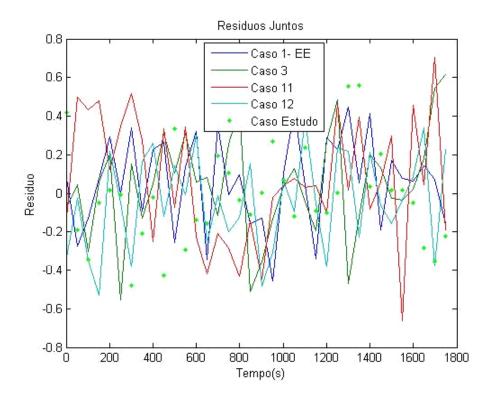


Figura 97-Estudo do Caso 12

4.6.1.13 Caso 13

Na Figura 100, analisa-se o perfil dos resíduos ao longo do tempo de monitoramento para o Caso 13 em relação aos Casos mais próximos (2, 4, 14). Verifica-se que o deslocamento da média dos resíduos de zero para um valor abaixo de zero. Ocorreu uma alteração nas condições operacionais do processo, onde a mudança aconteceu na variável concentração de entrada do reator. A saída do programa do Sistema de detecção e diagnóstico de falhas (Distâncias Euclidianas) indicou o próprio Caso 13 como o perfil mais próximo do caso em estudo, com um percentual de indicação igual a 52,78% (Ver Tabela 11). Segundo a Tabela 2, esta condição operacional representa uma situação de baixa vazão de alimentação.

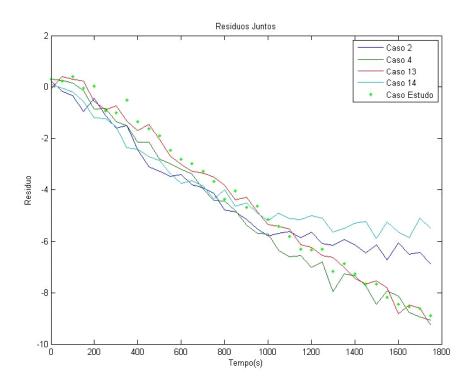


Figura 98-Estudo do Caso 13

4.6.1.14 Caso 14

Na Figura 101, estuda-se o perfil dos resíduos ao longo do tempo de monitoramento para o Caso 14 em relação aos Casos mais próximos (2, 4, 13). Observa-se que o deslocamento da média dos resíduos de zero para um valor abaixo de zero. Ocorreu uma alteração nas condições operacionais do processo, onde a mudança aconteceu na variável concentração de entrada do reator. A saída do programa do Sistema de detecção e diagnóstico de falhas (Distâncias Euclidianas) indicou o próprio Caso 14 como o perfil mais próximo do caso em estudo, com um percentual de indicação igual a 50,00% (Ver Tabela 11). Segundo a Tabela 2, esta condição operacional representa uma situação de alta vazão de alimentação.

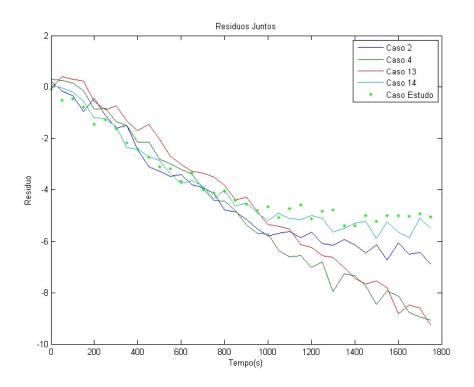


Figura 99-Estudo do Caso 14

4.6.1.15 Caso 15

Na Figura 102, observa-se o perfil dos resíduos ao longo do tempo de monitoramento para o Caso 15 em relação aos casos mais próximos (5, 6, 9). Observa-se que o deslocamento da média dos resíduos de zero para um valor acima de zero. Ocorreu uma alteração nas condições operacionais do processo, onde a mudança aconteceu na variável concentração de entrada do reator. A saída do programa do sistema de detecção e diagnóstico de falhas (Distâncias Euclidianas) indicou o próprio caso 15 como o perfil mais próximo do caso em estudo, com um percentual de indicação igual a 50,00% (Ver Tabela 11). Segundo a Tabela 2, esta condição operacional representa uma situação de alta concentração de alimentação.

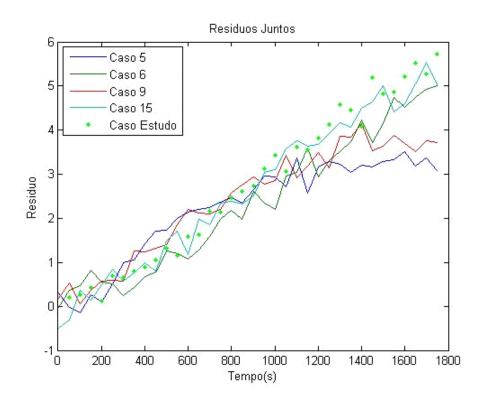


Figura 100-Estudo do Caso 15

4.6.1.16 Caso 16

Na Figura 103, observa-se o comportamento dos resíduos ao longo do tempo de monitoramento para o Caso 16 em relação aos casos mais próximos (7, 8, 10). Observa-se que o deslocamento da media dos resíduos de zero para um valor abaixo de zero. Ocorreu uma alteração nas condições operacionais do processo, onde a mudança aconteceu na variável concentração de entrada do reator. A saída do programa do indicou o próprio caso 16 como o perfil mais próximo do caso em estudo, com um percentual de indicação igual a 61,11% (Ver Tabela 11). Segundo a Tabela 2, esta condição operacional representa uma situação de baixa concentração de alimentação.

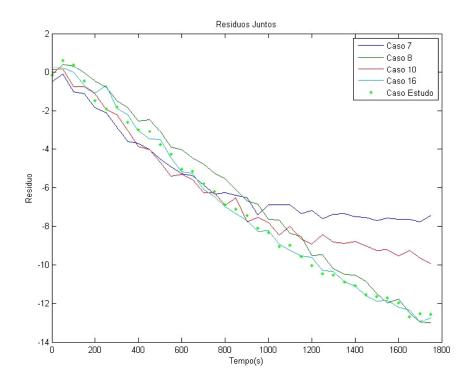


Figura 101-Estudo do Caso 16

4.6.2 Estudo de Novos Casos

De maneira a testar a capacidade de predição e extrapolação do sistema de detecção e diagnóstico de falhas, foram propostas quatro novas condições operacionais. A Tabela 12 ilustra essas novas situações com o respectivo caso mais próximo presente no banco de dados.

Tabela 12-Condições Operacionais dos Testes Propostos com indicação do Caso Mais Próximo

Teste	Condi	Caso Previsto		
	Concentração (mol/m ³)	Vazão (m ³ /s)	Temperatura (°C)	- Caso 1 10 visto
I	30	0,070	215,0	15
II	10	0,070	215,0	16
III	17	0,060	215,0	13
IV	10	0,200	215,0	7

Na Tabela 13, pode-se observar um resumo com os resultados obtidos com os quatro testes propostos. Apresentam-se os percentuais de indicação dos 16 casos para cada teste assim como a sua condição operacional.

Tabela 13-Resultado dos Testes com sua respectiva condição operacional

		Caso Mais Próximo														
Teste	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
l	0,00%	0,00%	0,00%	2,78%	25,00%	5,56%	0,00%	0,00%	16,67%	0,00%	0,00%	0,00%	2,78%	0,00%	47,22%	0,00%
II	2,78%	0,00%	0,00%	0,00%	0,00%	2,78%	13,89%	11,11%	0,00%	19,44%	0,00%	0,00%	0,00%	0,00%	0,00%	50,00%
Ш	0,00%	13,89%	0,00%	25,00%	0,00%	2,78%	5,56%	5,56%	0,00%	5,56%	0,00%	0,00%	27,78%	13,89%	0,00%	0,00%
IV	0,00%	19,44%	0,00%	8,33%	0,00%	2,78%	30,56%	2,78%	0,00%	19,44%	0,00%	0,00%	8,33%	8,33%	0,00%	0,00%
С	22,0	17,0	22,0	17,0	24,5	24,5	14,5	14,5	24,5	14,5	22,0	22,0	17,0	17,0	24,5	14,5
٧	0,100	0,100	0,070	0,070	0,115	0,055	0,115	0,055	0,100	0,100	0,055	0,115	0,055	0,115	0,070	0,070
T	215,0	215,0	215,0	215,0	215,0	215,0	215,0	215,0	215,0	215,0	215,0	215,0	215,0	215,0	215,0	215,0

T – Temperatura de alimentação (°C), V- Vazão de alimentação (m³/s) e C – Concentração de alimentação (mol/m³)

4.6.2.1 Resultado do Teste I

Na Figura 104, analisa-se o resultado obtido pelo sistema de diagnóstico para o Teste I. Pôde-se visualizar os casos mais próximos a condição operacional imposta pelo Teste I. Previa-se que o caso mais próximo desta condição operacional seria o Caso 15, que indica uma alta concentração de alimentação. Pode-se observar também que todos os casos situados próximos ao caso em teste apresentam a condição operacional de alta concentração de alimentação e variações, entre si, na vazão de alimentação (Casos 5, 6, 9 e 15). A saída do programa escolheu o Caso 15 como "vencedor" para a referida condição simulada, com um percentual de 47,22% (Ver Tabela 13) das indicações.

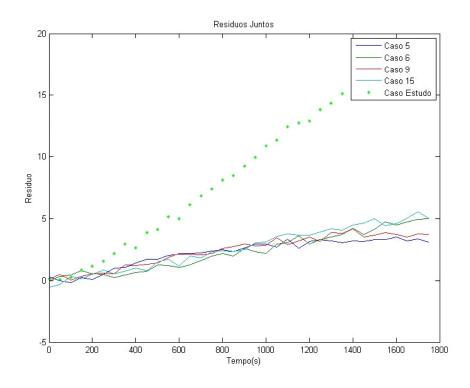


Figura 102-Resultado do Teste I

4.6.2.2 Resultado do Teste II

Na Figura 105, observa-se o resultado obtido pelo sistema de diagnóstico para o Teste II. Pôde-se visualizar os casos mais próximos a condição operacional imposta pelo Teste I. Previa-se que o caso mais próximo desta condição operacional seria o Caso 16, que indica uma baixa concentração de alimentação. Pode-se observar também que todos os casos situados próximos ao caso em teste apresentam a condição operacional de baixa concentração de alimentação e variações, entre si, na vazão de alimentação (Casos 7, 8, 10 e 16). A saída do programa apontou o Caso 16 como "vencedor" para a referida condição simulada, com um percentual de 50,00% (Ver Tabela 13) das indicações.

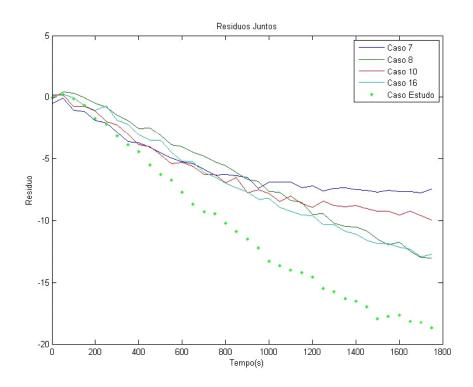


Figura 103-Resultado do Teste II

4.6.2.3 Resultado do Teste III

Na Figura 106, analisa-se o resultado obtido pelo sistema de diagnóstico para o Teste III. Pôde-se visualizar os casos mais próximos a condição operacional imposta pelo Teste III. Previa-se que o caso mais próximo desta condição operacional seria o Caso 13, que indica uma baixa vazão de alimentação. Pode-se observar também que todos os casos situados próximos ao caso em teste apresentam a condição operacional de baixa concentração de alimentação e variações, entre si, na vazão de alimentação (Casos 2, 4, 13 e 14). A saída do programa apontou o Caso 13 como "vencedor" para a referida condição simulada, com um percentual de 27,77% (Ver Tabela 13) das indicações, mas seguido de muito perto do Caso 4 (Condição Normal), com indicação de 25,00% dos casos. Pode-se afirmar que o sistema de diagnóstico apresenta uma dificuldade em prever alterações apenas na vazão isoladamente (baixa ou alta vazão), uma vez que a concentração de 17,0 mol/m³ é considerada normal. Nestes casos, necessita-se do monitoramento desta variável (vazão de alimentação) através do sistema supervisório para a confirmação do resultado.

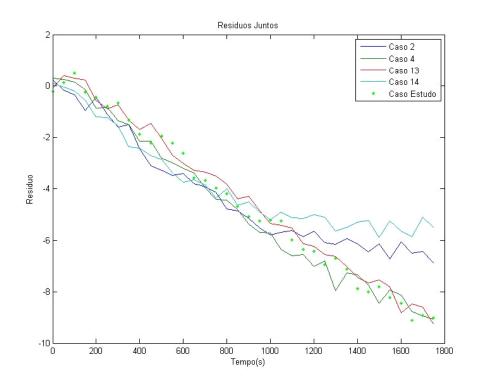


Figura 104-Resultado do Teste III

4.6.2.3 Resultado do Teste IV

Na Figura 107, analisa-se o resultado obtido pelo sistema de diagnóstico para o Teste IV. Neste teste, estudou-se a capacidade de extrapolação do sistema de diagnóstico, enquanto que, nos Testes I, II e III estudou-se casos de interpolação. Previa-se que o caso mais próximo desta condição operacional seria o Caso 7, que indica uma baixa concentração e alta vazão de alimentação. Pode-se observar também que todos os casos situados próximos ao caso em teste apresentam a condição operacional de baixa concentração de alimentação (em relação ao caso padrão 22,0 mol/m³) e variações, entre si, na vazão de alimentação (Casos 2, 7,10 e 16). A saída do programa apontou o Caso 7 como "vencedor" para a referida condição simulada, com um percentual de 30,55% (Ver Tabela 13) das indicações, mas seguido do Caso 2 (Condição Normal), com indicação de 19,44% dos casos. Observa-se que caso o sistema de diagnóstico empregasse mais tempo para o monitoramento, o Caso vencedor seria o Caso 2. Pode-se afirmar que o sistema de

diagnostico apresenta uma dificuldade em prever condições de extrapolação. Apesar da predição indicada estar correta, deve-se ter muita cautela para o emprego deste Sistema de Classificação para condições extrapoladas para a vazão e temperatura de alimentação, uma vez que a técnica de interpolação empregada na predição dos parâmetros do modelo (Polinômio de Lagrange) não é recomendada para tal uso.

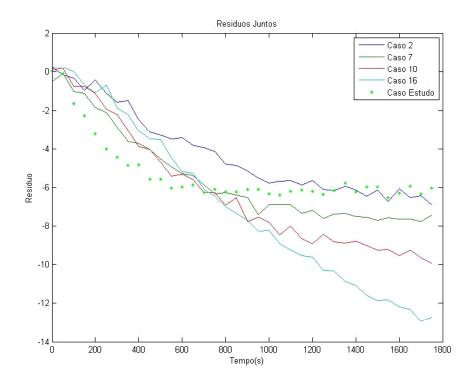


Figura 105-Resultado do Teste IV

5 - Conclusões e Sugestões

Esta dissertação de mestrado abordou a aplicação de uma técnica relativamente simples para a detecção e diagnostico de falhas em unidades de HDT. O sistema diagnóstico necessita de uma modelagem que apresente velocidade de resolução sem detrimento à qualidade da resposta obtida e empregou-se a modelagem fenomenológica como "processo real", pois dados reais de planta industrial não estavam disponíveis. Devido a este fato, modelos empíricos foram comparados de modo a apresentar um bom ajuste dos dados de processo, obtidos por simulação do modelo fenomenológico proposto por CARNEIRO (1992). Logo, concluí-se que as redes neuronais treinadas através do Software "Statistica 7.0" e a sua consequente implementação em Fortran 90 e posterior acoplamento ao Software Matlab 6.5 conseguiram uma ótima performance de aderência. Mesmo assim, quando comparada à eficiência de performance da Função de Laguerre, onde se empregou a técnica de Lookup Table juntamente com a interpolação de Laguerre, verificou-se que a segunda opção apresentou resultados mais consistentes e próximos do ideal para a grande maioria dos casos testados, além de apresentar um número menor de parâmetros que a modelagem envolvendo redes neuronais. A modelagem empírica baseada nas Funções de Laguerre forneceu o melhor modelo interno para a técnica FDD.

O estudo estatístico dos resíduos mostrou que os mesmos apresentavam a qualidade necessária para a realização do estudo, principalmente para o estado estacionário. Evidenciou-se também a sensibilidade mais apurada das técnicas de CUSUM e MMEP frente à carta de controle de Shewhart, quando impostas pequenas perturbações. Indica-se o emprego da Carta de MMEP para o acompanhamento do processo em estudo, com a finalidade de indicar mudanças sutis nas condições operacionais e posterior acionamento do sistema de detecção e diagnóstico de falhas.

O sistema de diagnóstico proposto apresentou excelente performance de predição quando estudos os casos propostos. Ele consegue prever variações na variável concentração de entrada indicando qual o caso mais próximo do cenário em estudo. Afirma-se que apesar da dificuldade inerente ao estudo de falhas combinadas, pode-se aperfeiçoar o modelo baseado nas Funções de Laguerre, para facilitar a decisão do sistema de classificação.

Os testes realizados com as novas condições operacionais mostraram que a metodologia empregada possui uma excelente resolução para a predição de modificações na variável concentração de alimentação e para falhas ocorridas na concentração e vazão de alimentação de forma isolada. Segundo o Teste III, o sistema não apresentou uma boa resolução para falhas combinadas, isto é, concentração de alimentação fora de seu valor considerado padrão para o modelo empírico (22,0 mol/m³) e vazão de alimentação fora de seus valores considerados normais (0,070 e 0,100 m³/s). Sugere-se o aumento do banco de dados empregado para a formulação do sistema de diagnóstico para contornar o problema das falhas combinadas.

Não é recomendada a extrapolação para as variáveis de alimentação, devido à falta de capacidade para tal utilização do polinômio Interpolador de Lagrange.

A metodologia desenvolvida pode ser facilmente utilizada em outras unidades de processo de refino.

É fundamental testar a aplicação do modelo baseado na função de Laguerre para os demais leitos e reatores presentes na unidade empregada como exemplo nesta dissertação de mestrados, e posterior aplicação do sistema de classificação a este sistema completo, verificando a sua eficácia para situações mais complexas. É de importância primordial, a validação da metodologia desenvolvida com dados experimentais extraídos de plantas industriais. Sugere-se a comparação com outras metodologias encontradas na literatura, como por exemplo as presentes no artigo do VENKATASUBRAMANIAN *et al.* (2003a).

Deve-se incluir novas perturbações em outras variáveis do processo, de modo a melhorar a performance do modelo e da metodologia desenvolvida para o FDD.

Pode-se desta forma salientar uma grande contribuição desta dissertação de mestrado para o desenvolvimento científico, pois a literatura acerca dos sistemas FDD aplicados a industria de petróleo, e em especial na Unidade de HDT, é bastante limitada. Evidenciam-se mais duas enormes contribuições para o desenvolvimento da ciência e pesquisa, uma vez que a revisão bibliográfica demonstrou poucos trabalhos científicos em que houve o emprego de modelagens simplificadas ou da técnica de Lookup Table, sendo esta dissertação de mestrado, praticamente, um trabalho pioneiro no emprego destas técnicas na Engenharia Química e mais especificamente na área de petróleo.

6 - Referências Bibliográficas

BAI, L., TIAN, Z. e SHI, S. Robust fault detection for a class of non-linear time-delay systems. Journal Of de Franklin Institute 344, pages 873-888, 2007.

BOUTROS, T. e LIANG, M. **Mechanical fault detection using fuzzy index fusion.** International Journal of Machine Tools & Manufacture 47, pages 1702–1714. 2007

BOX, G. E. P., JENKINS, G. M. e REINSEL, G. C., Time Series Analysis, Forecasting, and Control, 3rd edition, Prentice-Hall, Englewood Cliffs, NJ, 1994

CARNAHAN, B., LUTHER, H. A.e WILKES, J. O. **Applied Numerical Methods**. John Wiley & Sons. New York. 1969

CARNEIRO, H. P., Controle Robusto de Reator Químico de Leito Fixo, Dissertação de mestrado, PEQ/COPPE/UFRJ, 1992.

CHANG, C. T., RUSSEL, E. L. e CHEN, J. W. Implementation Issues Concerning the **EKF-Based Fault Diagnosis Techniques**. *Chemical Engineering Science*, Vol. 50, No. 18, pp, 2861 2882, 1995

CHETOUANI, Y. Fault detection by using the innovation signal: application to an exothermic reaction. Chemical Engineering and Processing 43, pages 1579–1585. 2004

CHIANG, L. H. e BRAATZ, E.L. Fault detection and diagnosis in industrial systems. London: Springer. 2001

CLUETT, W. R. e WANG, L. Modelling And Robust Controller Design Using Step Response Data. Chemical engeneerin Science, Vol. 46, No 8, pp. 206-2077, L991. 1991

DAIGUJI, M., KUDO, O. e WADA, T. Application of Wavelet Analysis to Fault Detection in Oil Refinery. *Computers'' chem. Engng*, Vol. 21, Suppl., pp. S 1117-S 1122, 1997

DE CERQUEIRA, E., O.; DE ANDRADE, J. C. e POPPI, R. J.; "Redes Neurais e suas Aplicações em Calibração Multivariada", Quim. Nova, Vol. 24, No. 6, 864-873, 2001.

DE SOUZA JR., M.B. **Redes Multicamadas Aplicadas a Modelagem e Controle de Processos**. 118 p. Tese (Doutorado em Ciências em Engenharia Química), PEQ/COPPE/UFRJ. 1993

DE SOUZA JR., M.B. Redes Multicamadas Não-lineares Treinadas pelo Método *Backpropagation*, Universidade Federal do Rio de Janeiro, Escola de Química, Curso de Mestrado em Tecnologia de Processos Químicos e Bioquímicos, 2001a.

DE SOUZA JR., M.B. **Redes Neurais na Engenharia Química com Aplicações no** *Neural Network Toolbox*, Universidade Federal do Rio de Janeiro, Escola de Química, Curso de Mestrado em Tecnologia de Processos Químicos e Bioquímicos, 2001b.

DE SOUZA JR., M.B. **Redes Neurais com** *Statistica*, **curso de treinamento para a versão 6.** Universidade Federal do Rio de Janeiro, Escola de Química, Curso de Mestrado em Tecnologia de Processos Químicos e Bioquímicos, 2003.

DE SOUZA, M. B.; CAMPOS, M. C. M. M.; TUNALA, L. F. . **Dynamic Principal Component Analysis Applied to the Monitoring of a Diesel Hydrotreating Unit**. In: Luca Ferrarini (Politecnico di Milano - Italy). (Org.). Control and Optimization of Continuous Processes. Ontario-Canada: ISA/O3NEDIA, v. 1. 2006

DETROJA, K. P., GUDI, R. D.e PATWARDHAN, S. C. **Plant-wide detection and diagnosis using correspondence analysis.** Control Engineering Practice Volume 15, Issue 12, Pages 1468-1483. 2007

EDGAR, T.F. e HIMMELBLAU, D.M., **Optimization of Chemical Processes**, McGraw-Hill Book Company, New York, 1988.

EWAN, W. D., When and How to Use Cu-Sum Charts. Technometrics, Vol 5, 1963

FARELL, A.E.e ROAT, S. D. Framework for Enhancing Fault Diagnosis Capabilities of Artificial Neural Networks. Computers them. Engng Vol. 18. No. 7. pp. 613-635, 1993

FUNAHASHI, K. On the Approximate Realization of Continuous Mappings by Neural Networks, Neural Networks, 2, 183-192, 1989.

GAN, F. F., An Optimal Design of CUSUM Quality Control Charts, Journal of Quality Technology, Vol 23, 1991.

GOMES, A.C.L., NUNES, M.H.O., DA SILVA, V.T. e MONTEIRO, J.L.F. **Thiophene Hydrodesulfurization Using 13-Mo2c/Mcm-41 As Catalyst.** Studies in Surface Science and Catalysis, volume 154. 2005.

HAWKINS, D. M., A CUSUM for a Scale Parameter. Journal of Quality Technology, Vol 13, 1981.

HECHT-NIELSEN, R.. Theory of the Backpropagation Neural Network, IEEE Int. Conf. on Neural Networks, Vol. I, 593-605, San Diego, 1989.

HEGRENÆS, Ø., GRAVDAHL, J. T.e TØNDEL, P. **Spacecraft attitude control using explicit model predictive control** Automatica, Volume 41, Issue 12, Pages 2107-2114, December 2005.

HILMELBLAU, D. M., **Process Analysis by Statistical Methods.** New York. John Wiley & Sons. 1970

HILMELBLAU, D. M., Fault Detection and diagnosis in chemical and petrochemical processes. Amsterdam: Elvesier press, 1978

HILMELBLAU, D. M. Fault Detection In Chemical Plant Equipment Via Fluid Noise Analysis. Computers & Chemical Engeneering Vol. 3, pages 507-510, 1979

HLAVÁCEK, V. **Fixed bed Reactors, flow and chemical reaction.** Residence Time Distribution Theory in Chemical Engeneering. Verlag Chemie, Weinheim, 103-111. 1982

HORNIK, K.; STINCHCOMBE, M. e WHITE, J.,. Multilayer Feedforward Networks are Universal Approximators, Neural Networks, 2, 359-366, 1989.

ISERMANN, R., Fault-Diagnosis Systems – An Introduction from Fault Detection to Fault Tolerance, 1°Edição, Springer, Germany, 2005

ISERMANN, R., Process fault detection base on modelling and estimation methods- a survey. Automática 20 (4), 387-404, 1984

JEON, Y. C. e LI, C. J. Non-Linear Arx Model-Based Kullback Index For Fault detection Of A Screw Compressor. *Mechanical Systems and Signal Processing* 9(4), pages 230_247. 1995.

JIANG,B. e CHOWDHURY, F. N. Parameter fault detection and estimation of a class of nonlinear systems using observers. Journal of the Franklin Institute 342, pages 725–736. 2005

KOLAITIS, D.I. e FOUNTI, M.A. **Heterogeneous Mixtures and Combustion Systems.** Combustion and Flame Volume 145, Issues 1-2, Pages 259-271, April 2006

KOURTI, T. Abnormal Situation Detection, Three-Way Data and Projection Methods; Robust Data Archiving and Modeling for Industrial Applications. Annual Reviews in Control 27, pp 131–139. 2003

KRESTA, J. V., MACGREGOR, J. F. e MARLIN, T.E. **Multivariate statistical monitoring of process operating performance**. Canadian Journal of Chemical Engineering, 69, 34-47. 1991.

LEE, Y., Statistical Theory of Communication. John Wiley, New York, 1960

LEES, F. P., Loss prevention in process industries: hazard identification, assessment and control. London: Butterworth-Heinemann, 1996

LENNOX, B., MONTAGUE, G. A., FRITH, A. M., GENT, C. & BEVAN, V. Industrial Application of Neural Networks – An Investigation. Journal of Process 11, pages 497-507. 2001.

- LEONARD, J. e KRAMER, M. A., **Improvement of the backpropagation Algorithm for Training Neural Networks**, Computers chem. Eng., vol. 14, no 3, pp. 337-341, 1990.
- LI, C. J.e KIM, T. Linear Model-based Fault Detection and Isolation for a Screw Compressor. Mechanical Systems and Signal Processing 8(3), pages 259-273. 1993 LIMA, A. D. M., Modelos de Inferência para Teor de Óleo em Parafinas de Petróleo, Dissertação de Mestrado, Escola de Química/UFRJ, 2007
- LOU ,S.J., BUDMAN ,H. e DUEVER , T.A., **Comparison of fault detection techniques.** Journal of Process Control 13, pag 451–464. 2003
- LUCAS, J. M., The Design na Use of Cumulative Sum Quality Control Schemes. Journal of Quality Technology, Vol 8, 1976.
- MACGREGOR, J. F., JAECKLE, C., KIPARISSIDES, C. & KOUTOUDI, M. Process monitoring and diagnosis by multiblock PLS methods. AIChE J., 40, pages 826-838. 1994.
- MCCLELLAND, J. e RUMELHART, D. E.,. Explorations in Parallel Distributed Processing. Cambridge, MA: MIT Press, 1988.
- MILETIC. I., QUINN, S. DUDZIC, M., VACULIK, V. e CHAMPAGNE, M. An industrial perspective on implementing on-line applications of multivariate statistics. Journal of Process Control 14 821–836. 2004
- MISRA, M., YUE, H. H. QIN, S. J. E LING, C. Multivariate process monitoring and fault diagnosis by multi-scale PCA. Computers and Chemical Engineering 26, pp 1281–1293. 2002
- MONTGOMERY, D. C., JOHNSON, L. A., e GARDINER, J. S., Forecasting and Time Series Analysis, 2nd Edition, McGraw-Hill, New York, 1990.
- MONTGOMERY, D.C. Introdução ao Controle Estatistico da Qualidade, 4º Edição LTC, Rio de Janeiro, 2001
- MUNÕZ, J. A. D., ALVAREZ, A., ANCHEYTA, J. , RODRIGUEZ, M. A. e MARROQUIN, G. **Process heat integration of a heavy crude hydrotreatment plant, ,** Catalysis Today 109 (2005) 214–218 , 2005.
- NIMMO, I. **Adequately address abnormal situation operations**. Chemical Engeneering Progress 91 (9), 36-45. 1995.
- ORILLE, A. L. e SOWILAM, G. M. A. **Application of neural networks for direct torque control.** Computers & Industrial Engineering, Volume 37, Issues 1-2, 391-394, October 1999.
- PAGE, E. S., Continuous Inspection Schemes. Biometrics, Vol 41, 1954

- PARK, S. W., HIMMELBLAU, D. M. Structural Design For Systems Fault Diagnosis. Cornput. them. Engng, Vol. 11, No. 6, pages. 713-722, 1987
- PRESS, W. H., TEUKOLSKY, S. A., VETTERLING, W. T. e FLANNERY, B. P. Numerical Recipes: The Art of Scientific Computing (Hardware). Third Edition. 2007.
- ROBERTS, S. W., Control Chats Test Base don Geometric Movin Averages, Technometrics, Vol 1, 1959
- RUMELHART, D. E. e MCCLELLAND, J. L. **Parallel Distributed Processing: Explorations in The Microstructure of Cognition**, Volume 1: Foundations, The Mit Press, Cambridge, 1986.
- SALVATORE, L. Inferência do Teor de Enxofre em Unidades de Hidrotratamento de Diesel Baseada em Modelagem Heurística. Dissertação de Mestrado, Escola de Química/UFRJ, 2007
- SALVATORE, L.; PIRES, B. N.; CAMPOS, M. C. M. M.; DE SOUZA, M. B. A **Hybrid Approach to Fault Detection and Diagnosis in a Diesel Fuel Hydrotreatment Process.** In: Fifth International Enformatika Conference (IEC05), Praga. IEC05 Proceedings. Praga: International Enformatika Society, 2005. v. 1. p. 379-384. 2005,
- SCHAEFFER, R. e SZKLO, A. Fuel specification, energy consumption and CO₂ emission in oil refineries. Energy 32 pages 1075–1092. 2007
- SEOK, Y., YOON, J. H., NAM, D. E HAN, C. Intelligent Fault Diagnosis Based on Weighted Symptom Tree Model and Fault Propagation Trends. Computer chem. Engng, Vol. 21, Suppl., pp, 941-946, 1997
- SHARMA, R., SINGH, K., SINGHAL, D. E GHOSH, R. Neural Network Applications for Detecting Process Faults in Packed Towers. Chemical Engineering and Processing 43, pp 841–847. 2004
- SILVA, R. M. C. F. Apostila de Hidrorrefino. PETROBRAS (SEREC/CEN-SUD), 1997.
- SIMANI, S. e FANTUZZI, C. Dynamic system identification and model-based fault diagnosis of an industrial gas turbine prototype. Mechatronics 16, pages 341–363. 2006.
- SIMANI, S., e PATTON, R. J. Fault diagnosis of an industrial gas turbine prototype using a system identification approach. Control Engineering Practice, 2007
- SPEIGHT, J. G., CENTENO, G., ANCHEYTA, J., TREJO, F. Asphaltene characterization as function of time on-stream during hydroprocessing of Maya crude Catalysis Today 109, pages162–166, 2005.

STEPHANOUPOULOS, G. Chemical Process Control – An Introduction to Theory and Practice. Prentice-Hall, New Jersey. 1984

SUNDARRAMAN, A. e SRINIVASAN, R. Monitoring transitions in chemical plants using enhanced trend analysis. Computers and Chemical Engineering 27 pages 1455_1472. 2003

TAMURA, M. e TSUJITA, S. A Study on the Number of Principal Components and Sensitivity of Fault Detection Using PCA. Computers and Chemical Engineering 31, pages 1035–1046. 2007

THORNHILL, N.F. e HORCH, A. Advances and new directions in plant-wide disturbance detection and diagnosis. Control Engineering Practice 15, pages 1196–1206, 2007

VENKATASUBRAMANIAN, V. VAIDYANATHAN, R e YAMAMOTO, Y. Process Fault Detection and Diagnosis Using Neural Networks-I. Steady-State Processes. Computers them. *Engng, Vol.* 14, No. 7. pp. 699-712, 1990

VENKATASUBRAMANIAN, V., RENGHUNATHAN, R., YIN, K., KAVURI, S. N., A review of process fault detection and diagnosis Part I: Quantitative model- based methods. Computers and Chemical Engineering, vol. 27, pp. 293-311, 2003a.

VENKATASUBRAMANIAN, V., RENGHUNATHAN, R., KAVURI, S. N. A review of process fault detection and diagnosis Part II: Qualitative models and search strategies. Computers and Chemical Engineering, vol. 27, pp. 313-326, 2003b.

VENKATASUBRAMANIAN, V., RENGHUNATHAN, R., KAVURI, S. N., YIN, K, A review of process fault detection and diagnosis Part III: Process history based methods. Computers and Chemical Engineering, vol. 27, pp. 327-346, 2003c.

WANG, L. Discrete model predictive controller design using Laguerre functions. Journal of Process Control 14 pages 131–142 2005

WANG, L. e CLUETT, W. R. Building Transfer Function Models From Noisy Step Response Data Using The Laguerre Network. *Chemical Enaineering Science*, Vol. 50, No. 1, pp. 149-161, 1995

WATANABE, K. e HIMMELBLAU, D. M. Incipient Fault Diagnosis of Nonlinear Processes with Multiple Causes of Faults. Chemical Engineering Science Vol 39, N° 3, pp 491-508, 1984

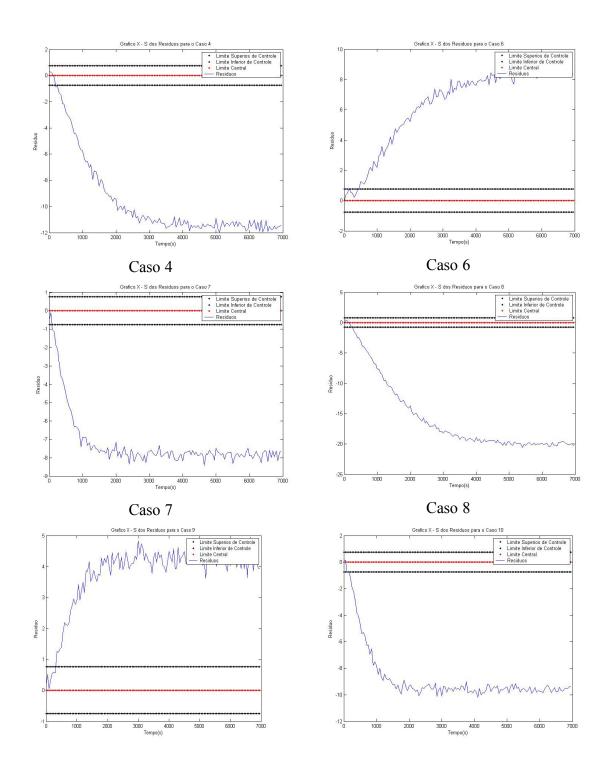
WILLSKY, A. S., A survey of design methods for failure detection in dinamic system,. Automática 12, 601-611, 1976

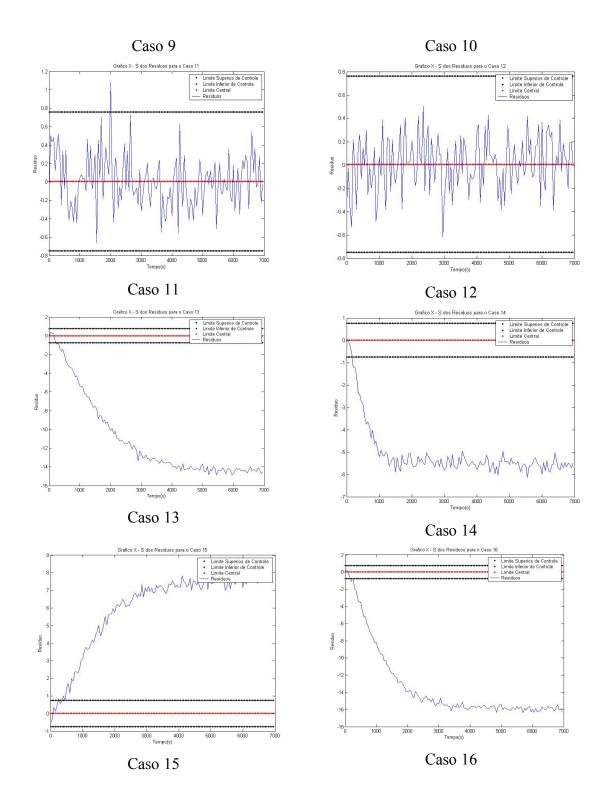
WYLIE, C. R., Advanced Engineering Mathematics. McGraw-Hill, New York, 1960.

- YOON, S. e MACGREGOR, J. F. Fault Diagnosis with Multivariate Statistical Models Part I: Using Steady State Fault Signatures. Journal of Process Control 11, 387-400. 2001.
- ZHANG, L. e NANDI, A. K. Fault classification using genetic programming. Mechanical systems and signal processing 21, pages 1273-1284, 2007
- ZHANG, J., MORRIS, A. J. MARTIN, E. B. e KIPARISSIDES, C. Estimation of impurity and fouling in batch polymerisation reactors through the application of neural networks. Computers and Chemical Engineering 23, pages 301-314. 1999
- ZOTIN, J. L. Curso de Operadores de HDT da REPAR Catalisadores de HDT: Conceitos e Funções. CENPES / HPE, 2003.
- ZOTIN, J.L. FERREIRA, R. M. C., CHIARO, S. S. X. Apresentação: Processos e Reações de HDR. CENPES/PDAB/HPE CENPRO, 2003.

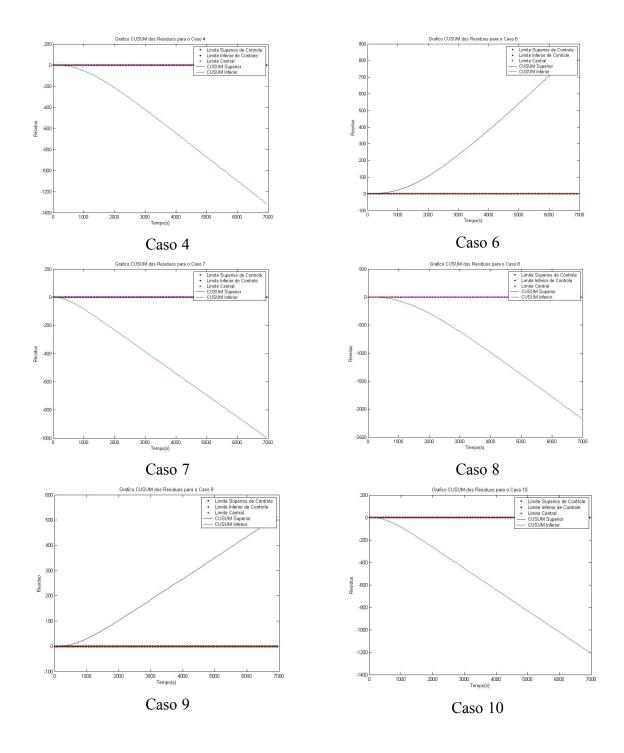
7 - APÊNDICES

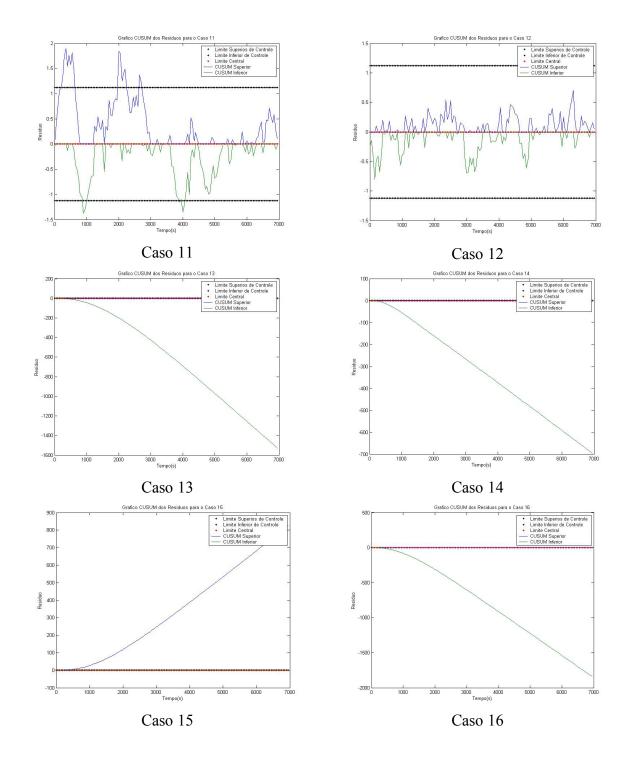
Apêndice 1 – Cartas de Shewhart



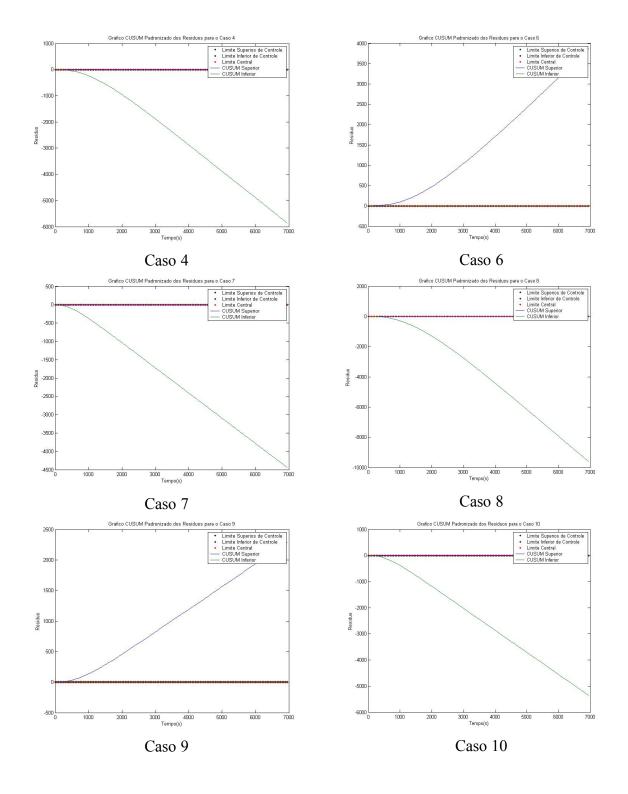


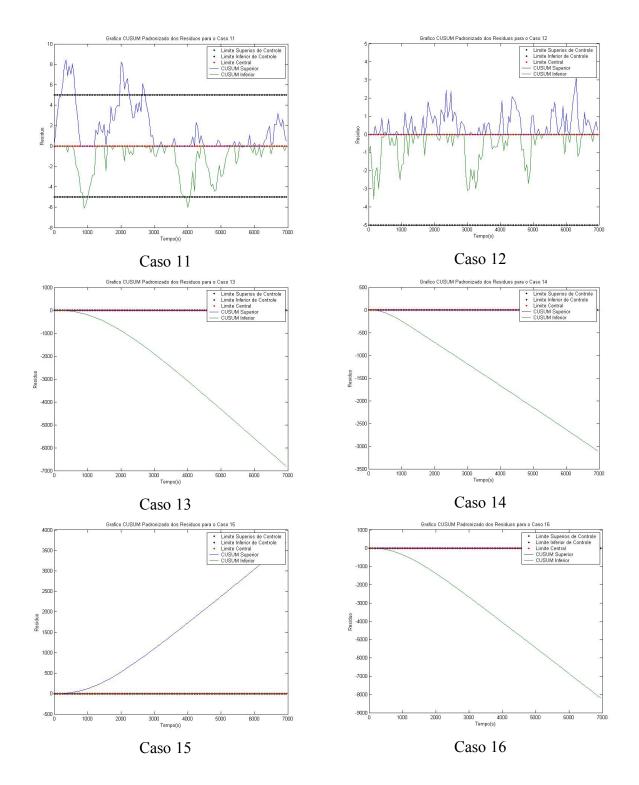
Apêndice 2 – Cartas de CUSUM Tabular





Apêndice 3 – Cartas de CUSUM Padronizado





Apêndice 4 – Cartas de MMEP

